EARTH OBSERVATION WITH ESA MISSIONS

KATARÍNA PUKANSKÁ KAROL BARTOŠ ĽUBOMÍR KSEŇAK



Technická univerzita v Košiciach Fakulta baníctva, ekológie, riadenia a geotechnológií

Katarína Pukanská, Karol Bartoš, Ľubomír Kseňak

EARTH OBSERVATION WITH ESA MISSIONS Diaľkový prieskum Zeme misiami ESA

Košice

2022

Táto vysokoškolská učebnica bola finančne podporená agentúrou ESA v rámci projektu PECS (Plan for European Cooperating States), agentúrou VEGA MŠVVaŠ počas riešenia projektu č. 1/0340/22 a agentúrou KEGA č. 055/TUKE-4/2021.

© doc. Ing. Katarína Pukanská, PhD., Ing. Karol Bartoš, PhD., Ing. Ľubomír Kseňak, PhD.

Earth observation with ESA missions Diaľkový prieskum Zeme misiami ESA

Recenzenti: doc. Mgr. Michal Gallay, PhD. Ing. Juraj Papčo, PhD.

> Vydavateľ: © TU v Košiciach, Vydanie: prvé Košice 2022

ISBN 978-80-553-4166-8

Tento materiál je autorské dielo chránené Autorským zákonom SR a súvisiacimi zákonmi. Všetky práva vyhradené. Okrem zákonom povolených prípadov, žiadna časť tohto materiálu nesmie byť reprodukovaná a šírená akoukoľvek formou a prostriedkami bez predošlého písomného súhlasu autora. Za odbornú stránku textu zodpovedá autor.

Content

The Autors		10
Preface		12
1. ESA,	Earth Observation, Data Access	
1.1.	History of ESA	14
1.2.	ESA missions – past, recent, future	15
1.2.1	Past ESA missions	
1.2.2	. Current ESA Earth Observation missions	
1.2.3	. Overview of planned ESA missions	
1.3.	Types of data provided and access to data	
1.3.1	ESA Hub, Open access to ESA data	
1.3.2	. Third party missions TPM	
1.3.3	. Other web services for browsing and downloading images	
1.4.	Copernicus - European Union's Earth Observation Programme	
2. Elect	romagnetic radiation	
2.1.	Introduction	47
2.2.	Interactions of electromagnetic radiation in the atmosphere	50
2.3.	Dispersion	51
2.4.	Absorption and transmission	53
2.5.	Interaction with the earth's surface	
3. Optio	al Remote Sensing	58
3.1.	Introduction	
3.2.	Panchromatic Image	
3.3.	Multispectral Image	60
3.4.	Combinations of spatial and spectral resolution: pansharpening	
3.5.	Sensors in Remote Sensing	
3.5.7	. Types of sensors	65
3.6.	Resolution of sensors	
3.6.	. Spatial resolution	67
3.6.2	2. Spectral resolution	71
3.6.	3. Radiometric resolution	75
3.6.	4. Temporal resolution	
4. Digit	al Image Analysis	
4.1.	Introduction	79
4.2.	Pre-processing	80
4.2.	I. Noise reduction	80
4.2.	2. Radiometric corrections	
4.2.	3. Geometric corrections	
4.2.	4. Pre-processing final adjustments	
4.3.	Image enhancement – radiometric	
4.3.	I. Contrast manipulation	
4.3.	2. Spatial Filtering	
4.3.	 spectral enhancement - multipand manipulations 	
5. Imag		
5.1.	Introduction	
5.2.	Supervised classification	
5.2.7	. Binary coding	

Earth Observation with ESA missions University textbook

5.2.2.	Minimum distance classifier			
5.2.3.	Mahalanobis distance classifier			
5.2.4.	Parallelepiped classification	111		
5.2.5.	Maximum likelihood classification	111		
5.2.6.	Random Forest Classifier			
5.2.7.	Support Vector Machine			
5.2.8.	Spectral Angle Mapper SAM			
5.2.9.	k-Nearest Neighbours (kNN)			
5.3.	Unsupervised classification	122		
5.3.1.	K-means classifier	123		
5.3.2.	H-α classification	125		
6. Basics	of Radar Remote Sensing	129		
6.1.	Introduction to radar RS			
6.1.1.	A brief history of radar systems development			
6.2.	Classification of radar systems			
6.2.1.	Passive radar systems			
6.2.2.	Active radar systems			
6.3.	SAR signal characteristics			
6.3.1.	Internal parameters			
6.3.2.	External parameters			
6.4.	SAR image characteristics			
6.4.1.	Thermal noise			
6.4.2.	Calibration			
6.4.3.	Speckle effect			
6.4.4.	Geometric correction			
7. SAR Ar	oplications – Interferometry, Polarimetry	156		
71		157		
7.1.	SAD Interferometry	157		
7.2.	SAR Interferometry	150		
7.2.1.				
7.2.2.	For the state of t			
7.2.3.	SAD Delarimetry	162		
7.3.	SAR Polarinetry			
/.J.I. 772	Polarization descriptors	ססו		
7.3.2.	SAR polarimetry and Theoreman			
7.5.5. 7 /.	Applications of SAD systems and their data	172		
7.4.	Applications of SAR systems and their data			
7.4.1.	Applications of SAD Delarimetry			
7.4.2.	Applications of SAR Polarimetry	1/6		
8. Applica	ations of RS – Land use/Land cover, Agriculture			
8.1.	Land Cover			
8.1.1.	Evironmental aspects of land cover and its use			
8.1.2.	Needs and possibilities for land cover mapping			
8.1.3.	Definition of land cover, land cover use and land use change			
8.2.	CORINE Land Cover (CLC)			
8.2.1.	Definition, history and content of CLC	191		
8.2.2.	Corine Land Cover in Slovakia			
8.3.	Remote Sensing in Agriculture			
8.3.1.	Use of RS for crop and biomass assessment			
8.3.2.	Qualitative crop monitoring			
8.3.3.	Identification of production zones from RS data	211		
8.4.	Radar Remote Sensing in Agriculture			
8.4.1.	Identification and mapping of areas for crop production	212		
8.4.2.	Crop and cropland parameters	217		

8.4.3.	Sentinel-1 Interferometric Coherence for Vegetation and Mapping (SINCOHMAP)	220	
8.5.	Applications of RS in Agriculture using ESA missions		
8.5.1.	Sentinel-2 for Agriculture (Sen2-Agri)	227	
8.5.2.	Sentinels for Common Agricultural Policy (Sen4CAP)	231	
8.5.3.	ESA Climate Change Initiative Land_Cover project (ESA CCI LC)	232	
8.5.4.	High Resolution (HR) Land Cover (LC) project	234	
9. Applica	ations of RS – geologic and mining activities	238	
9.1.	Geologic mapping	239	
9.2.	Hyperspectral geological mapping	244	
9.3.	Application of SAR in geology	247	
9.3.1.	Suitability of RS data for applications in geology	247	
9.4.	Applications in Slovakia	248	
9.4.1.	Geological structures on satellite images of Slovakia		
9.5.	Applications and projects using ESA satellite missions in Geology	251	
9.5.1.	Sentinels help with mineral mapping		
9.5.2.	Earth Observation for the Mining of Raw Materials (EO4RM)		
9.5.3.	EIT Raw Materials	256	
9.5.4.	Geological Remote Sensing Group (GRSG)	259	
9.6.	Monitoring mining activities	260	
9.6.1.	Activities within the EO4RM project	260	
9.6.2.	Other examples of using RS data for monitoring mining activities	270	
10. Appl	ications of RS – Forestry	279	
10.1.	Introduction		
10.2	BS in forest management	283	
10.21	Complexity of forest ecosystems	284	
10.3	Use of DS in Forestry	286	
10.5.	Forest fires	286	
10.3.1	Pest infestation	287	
10.3.3.	Droughts		
10.3.4	Damage caused by storms		
10.3.5.	Deforestation / illegal logging		
10.3.6.	Phenological changes		
10.4.	Mapping forest fires	294	
10.4.1.	Identification of the burned area		
10.4.2	Burn severity classification		
10.4.3.	Estimation of the total area burned	298	
10.5.	Global Wildfire Information System	299	
10.6.	Deforestation / illegal logging	302	
10.6.1.	What RS data to use for deforestation monitoring?		
10.6.2.	Using optical data for monitoring deforestation and forest degradation	308	
10.6.3.	Using radar data for monitoring deforestation and forest degradation		
10.6.4	Deforestation and forest degradation from a SAR data perspective		
10.6.5.	SAR data processing for forestry applications		
10.6.6.	Change detection using SAR data		
10.6.7.	Combining radar and optical data for monitoring deforestation and forest degradation	330	
10.6.8	SAR vegetation index		
10.7.	Global Forest Watch	334	
10.7.1.	Origin and evolution of GFW		
10.7.2.	Destruction of primary rainforests to increase by 12% from 2019 to 2020		
10.7.3.	New radar alerts monitor forests through clouds (Senitel-1)	338	
10.8.	Deforestation in Slovakia	340	
11. Applica	ations of RS – Water, Ice, Snow	344	
11.1.	Water	345	

Earth Observation with ESA missions University textbook

11.1.1.	Water quantity and distribution	
11.1.2.	Water quality	
11.2.	Importance of water	
11.3.	Main tasks of RS in water monitoring	355
11.3.1.	Monitoring water quality	
11.4.	Flood mapping and monitoring	
11.4.1.	Flood monitoring using optical sensors	
11.4.2.	Flood monitoring using active radar sensors	
11.4.3.	Flood monitoring using passive radar sensors	
11.4.4.	Flood monitoring using a combination of optical and radar data	
11.4.5.	Flood mapping using Sentinel-3 OLCI	
11.5.	Drought monitoring	
11.5.1.	Meteorological drought	
11.5.2.	Agricultural drought	
11.5.3.	Hydrological drought	
11.5.4.	Drought monitoring in ESA mission applications	
11.6.	Space4Water portal	393
11.7.	Snow and Ice	395
11.7.1.	Optical RS of Snow Cover	
11.7.2.	Methods of Radar RS of Snow Cover	
11.7.3.	Ice movement monitoring with RS	
11.7.4.	Applications of Ice monitoring	415
12. App	lications of RS – Environment and Natural Disasters	
12.2.	Introduction	425
12.2.1.	Types of disasters and their impact on the environment	
12.2.2.	RS methods for disaster management	
12.3.	Copernicus Emergency Management Service	433
12.4.	Global Disaster Alert and Coordination System (GDACS)	435
12.5.	Use of RS for earthquake monitoring	
12.5.1.	Application of RS	
12.5.2.	Mapping the 2019 California earthquakes with the Copernicus S-1 and 2 missions	
12.5.3.	Earthquake mapping on a fault in France	
12.5.4.	. New look at the 2016 Italy earthquake thanks to Sentinel-1	
12.6.	Application of RS for monitoring volcanic activity	
12.6.1.	Monitoring volcanic activity using DinSAR and Short Baseline Subset	453
12.6.2.	Satellite monitoring of the volcanic activity of Mount Etna volcano	457
12.7.	Application of RS for landslide monitoring	
12.7.1.	Landslides in Slovakia	
12.7.2.	RS technologies for landslide monitoring	
12.7.3.	RS data for landslide detection and registration	
12.7.4	. Monitoring landslides in the Alps with Sentinel-1	477
12.7.5.	Monitoring landslides in California with Sentinel-1	
12.7.6.	Using Sentinel-2 time series to monitor slope movements	

Obsah

Autori		10
Predhov	Or	
1. ESA, P	ozorovanie Zeme, Prístup k dátam	
1.1.	História ESA	14
1.2.	Misie ESA - minulé, aktuálne a budúce	
1.2.1.	Ukončené misie ESA	16
1.2.2.	Aktuálne misie ESA	20
1.2.3.	Prehľad plánovaných misií ESA	
1.3.	Typy poskytovaných údajov a prístup k nim	
1.3.1.	ESA Hub, Otvorený prístup k dátam	
1.3.2.	Misie tretích strán TPM	
1.3.3.	Webové služby na prehliadanie a získavanie snímok	
1.4.	Copernicus – európsky program pre pozorovanie Zeme	
2. Elektro	omagnetické žiarenie	
2.1.	Úvod	47
2.2.	Interakcie EMŽ v atmosfére	50
2.3.	Rozptyl	51
2.4.	Absorbcia a transmisia	
2.5.	Interakcia s povrchom zeme	
3. Optick	ý diaľkový prieskum Zeme	
3.1.	Úvod	
3.2.	Panchromatická snímka	
3.3.	Multispektrálna snímka	60
3.4.	Kombinácie priestorového a spektrálneho rozlíšenia: pansharpening	
3.5.	Senzory v diaľkovom prieskume Zeme	63
3.5.1.	Typy senzorov	
3.6.	Rozlíšenie senzorov	66
3.6.1.	Priestorové rozlíšenie	67
3.6.2.	Spektrálne rozlíšenie	71
3.6.3.	Rádiometrické rozlíšenie	75
3.6.4.	Temporálne rozlíšenie	76
4. Digitál	ne obrazové analýzy	78
4.1.	Úvod	
4.2.	Predspracovanie obrazu	80
4.2.1.	Odstránenie šumu	80
4.2.2.	Rádiometrické korekcie	
4.2.3.	Geometrické korekcie	
4.2.4.	Finálne úpravy predspracovania	
4.3.	Vylepšenie obrazu – rádiometrické zvýraznenie	
4.3.1.	Manipulácia s kontrastom	
4.3.2.	Priestorove zvyrazenie – filtracia obrazu	
4.3.3.	spektraine zvyraznenie- viacpasmove manipulacie	
5. Klasifik	(acia snimok	
5.1.		
5.2.	Riadena klasifikacia	
5.2.1.	Binarne Kodovanie	

Earth Observation with ESA missions University textbook

5.2.2.	Klasifikátor minimálnej vzdialenosti	109	
5.2.3.	. Klasifikátor Mahalanobisovej vzdialenosti		
5.2.4.	Klasifikátor pravouholníkov	111	
5.2.5.	Klasifikátor maximálnej pravdepodobnosti	111	
5.2.6.	Random forest klasifikátor	114	
5.2.7.	Support Vector Machine klasifikátory	116	
5.2.8.	Spectral Angle Mapper SAM	118	
5.2.9.	k-Nearest Neighbours (kNN)		
5.3.	Neriadená klasifikácia	122	
5.3.1.	K-means klasifikátor	123	
5.3.2.	H - α klasifikácia	125	
6. Základ	y radarového DPZ	129	
6.1.	Úvod	130	
6.1.1.	Stručná história vývoja radarových systémov	131	
6.2.	Rozdelenie radarových systémov	132	
6.2.1.	Pasívne radarové systémy		
6.2.2.	Aktívne radarové systémy		
6.3.	Charakteristika SAR signálu		
6.3.1.	Vnútorné parametre		
6.3.2.	Vonkajšie parametre	141	
6.4.	Charakteristika SAR obrazu		
6.4.1.	Tepelný šum		
6.4.2.	Kalibrácia		
6.4.3.	Speckle efekt		
6.4.4.	Geometrická korekcia		
7. Aplikád	cie SAR systémov - interferometria, polarimetria	156	
71	lívod	157	
7.1.	SAD interforometria	157	
7.2.		150	
7.2.1.			
7.2.2.	Folloar	160	
7.2.3.	SAD polorimotrio	166	
7.3.	SAR polalifiet la		
/.3.1.	Deskriptory polarizacie		
7.3.Z. 7.7.7	SAR polarimetria a interferometria	וריו 1/0	
/.ɔ.ɔ.	SAR polarimetria a tomografia.	ו/וו/ו	
7.4.	Aplikacie vyuzitia SAR systemov a ich dat	۲/۱	
7.4.1.	Aplikačné oblasti SAR Interferometrie	1/Z	
/.4.2.	Aplikache oblasti SAR polarimetrie	1/5	
8. Aplika	cie DPZ – vyuzitie krajiny, krajinna pokryvka, Polnonospodarstvo		
8.1.	Krajinna pokrývka	184	
8.1.1.	Environmentálne aspekty krajinnej pokrývky a jej využitia		
8.1.2.	Potreby a možnosti mapovania krajinnej pokrývky		
8.1.3.	Definicia krajinnej pokrývky, využitia krajinnej pokrývky a zmeny využitia krajiny		
8.2.	CORINE Land Cover (CLC)	190	
8.2.1.	Definícia, história a obsah CLC		
8.2.2.	CORINE Land Cover na Slovensku		
8.3.	DPZ v poľnohospodárstve	194	
8.3.1.	Využitie DPZ pre hodnotenie úrody a biomasy	197	
8.3.2.	Kvalitativne monitorovanie plodín		
8.3.3.	Identifikacia produkčných zón z dát DPZ		
8.4.	Radarový DPZ v poľnohospodárstve		
8.4.1.	Identifikácia plodín a mapovanie oblastí pre pestovanie plodín	211	
8.4.2.	Parametre plodin a ornej pödy	216	

8/3	Interferometrická koherencia Sentinel-1 pre vegetáciu a manovanie (SINCOHMAD)	210
0.4.5.	Aplikácia DDZ v poľpobospodárstvo s v užitím micií ECA	215
0.5.	Aplikacie DPZ v pomonospodarstve s vydzicim misii ESA	
8.5.1.	Sentinel-2 pre poinonospodarstvo (Senz-Agri)	
0.J.Z.	sentinely pre spolocnu politonospodarsku politiku (sen4CAP)	230
0.5.5.	Hindlativa ESA pre Zhena kiiniy - projekt Land_Cover (ESA CCI EC)	
0.3.4.		770
9. Арнка	cie DPZ – geologicke mapovanie a monitoring banskej cinnosti	
9.1.	Geologické mapovanie	
9.2.	Hyperspektrálne geologické mapovanie	
9.3.	Využitie SAR v geológii	
9.3.1.	Vhodnosť údajov DPZ pre geologické aplikácie	
9.4.	Aplikácie na Slovensku	
9.4.1.	Geologické štruktúry satelitných snímkach Slovenska	248
9.5.	Aplikácie a projekty využívajúce satelitné misie ESA v geológii	
9.5.1.	Sentinely pomáhajú s mapovaním minerálov	250
9.5.2.	Pozorovanie Zeme na účely ťažby nerastných surovín (EO4RM)	251
9.5.3.	EIT Raw Materials	255
9.5.4.	Geological Remote Sensing Group (GRSG)	258
9.6.	Monitorovanie banskej činnosti	259
9.6.1.	Aktivity v rámci projektu EO4RM	259
9.6.2.	Ďalšie príklady využitia dát z DPZ pre monitorovanie banskej činnosti	
10. Aplil	rácie DPZ – Lesníctvo	
10.1.	Úvod	
10.2	DP7 v lesnom hospodárstve	282
10.21	Zložitosť lesných ekosystémov	283
10.2.1.	Využitie DD7 v lesníctve	285
10.5.		205
10.3.1.	Zamarania čkodcami	205
10.3.2		200
10.5.5	Škody snôsobené býrkou	288
10.3.4	Odlesňovanie / nelegálna ťažba dreva	289
10.3.5	Eenologické zmeny	205
10.5.0	Mapovanio požiarov	207
10.4.	Identifikevania spálapai ablasti	206
10.4.1		
10.4.2	Odbad calkovci spálanci plachy	
10.4.5		
10.5.		
10.6.	Odlesnovanie / nelegalna tazba dreva	
10.6.1.	Ake data DPZ pouzit pre monitorovanie odlesnovania?	
10.6.2	Pouzitie optických dat pre monitorovanie odlesnovania a degradacie lesa	
10.6.3	Pouzitie radarovych dat pre monitorovanie odlesnovania a degradacie lesa	
10.6.4	. Deforestacia a degradacia iesa z poniadu SAR dat	
10.6.5	 Spracovanie SAR dat pre lesnicke aplikacie 	
10.6.6	. Detekcia zmien pomocou SAR dat	
10.6.7	. Kombinacia SAR a optických dat pre monitorovanie odlesnovania a degradacie lesa	
10.6.8	Clab flow manifesting leases. Clab - 1 5 - 1 - 1 - 1 - 1	
10.7.	Giopainy monitoring lesov - Giopai Forest Watch	
10.7.1.		
10.7.2	 Znicenie primarnych dazdovych pralesov sa medzi 2019-2020 zvysilo o 12% 	
10.7.3	. Nove "radarove vystrany" monitoruju lesy cez oblaky – Senitel-I	
10.8.	Udiesnovanie na Slovensku	
11. Apliká	cie DPZ – Voda, Ľad, Sneh	
11.1.	Voda	

Earth Observation with ESA missions University textbook

11.1.1.	Množstvo a rozloženie vody	
11.1.2.	Kvalita vody	
11.2.	Význam vody	353
11.3.	Hlavné úlohy DPZ pri monitorovaní vody	
11.3.1.	Monitorovanie kvality vody	
11.4.	Monitorovanie a mapovanie záplav	
11.4.1.	Monitorovanie záplav pomocou optických senzorov	
11.4.2.	Monitorovanie záplav pomocou aktívnych radarových senzorov	
11.4.3.	Monitorovanie záplav pomocou pasívnych mikrovlnných senzorov	
11.4.4.	Monitorovanie záplav pomocou kombinácie optických a radarových dát	
11.4.5.	Monitorovanie záplav pomocou misie Sentinel-3 OLCI	
11.5.	Monitorovanie sucha	
11.5.1.	Meteorologické sucho	
11.5.2.	Poľnohospodárske sucho	
11.5.3.	Hydrologické sucho	
11.5.4.	Monitorovanie sucha v aplikáciách ESA misií	
11.6.	Portál Space4Water	
11.7.	Sneh a lad	
11.7.1.	Optický DPZ snehovej pokrývky	
11.7.2.	Metódy radarového DPZ snehovej pokrývky	
11.7.3.	Monitorovanie pohybu ľadu v Antarktíde pomocou DPZ	
11.7.4.	Aplikácie DPZ pre monitorovanie ľadu	414
12. Aplik	ácie DPZ – životné prostredie a živelné pohromy	
12.2.	Úvod	
12.2.1.	Typy živelných pohrôm a ich vplyv na životné prostredie	
12.2.2.	Metódy DPZ pre zvládanie pohrôm	
12.3.	Služba riadenia núdzových situácií Copernicus	432
12.4.	Globálny systém varovania a koordinácie pri pohromách (GDACS)	
12.5.	DPZ pre monitorovanie zemetrasení	
12.5.1.	Využitie metód DPZ	
12.5.2.	Mapovanie zemetrasení v Kalifornii v roku 2019 pomocou misií Copernicus S-1 a S-2	
12.5.3.	Mapovanie zemetrasenia na zlomovej línii vo Francúzsku	
12.5.4.	Nový pohľad na zemetrasenie v Taliansku 2016 vďaka Sentinel-1	
12.6.	DPZ pre monitorovanie vulkanickej činnosti	
12.6.1.	Monitorovanie vulkanickej činnosti pomocou DinSAR a Short Baseline Subset	452
12.6.2.	Satelitné monitorovanie vulkanickej činnosti sopky Etna	
12.7.	DPZ pre monitorovanie zosuvov pôdy	
12.7.1.	Zosuvy na Slovensku	
12.7.2.	Metódy DPZ pre monitorovanie zosuvov	
12.7.3.	Údaje DPZ pre detekciu a evidencia zosuvov	
12.7.4.	Monitorovanie zosuvov v Alpách pomocou Sentinel-1	
12.7.5.	Monitorovanie zosuvov v Kalifornii pomocou Sentinel-1	
12.7.6.	Použitie časovej rady Sentinel-2 pre monitorovanie svahových pohybov	

The Autors



Katarína Pukanská works as an associate professor at the ÚGKaGIS, FBERG, TUKE. At the Faculty of BERG, TU Košice, she leads lectures and exercises in subjects Remote Sensing, Photogrammetry I., II. and Space Geodesy. She specialises in laser scanning and digital photogrammetry in creating spatial models of surface and underground objects, digital terrain models, mapping, and using these methods in special industrial applications.

Karol Bartoš works as an assistant professor at ÚGKaGIS, FBERG, TU Košice. He leads the subject Surveying at the Faculty of Civil Engineering, and exercises in subjects Photogrammetry I. and Surveying I. In his professional activities, he specialises in digital photogrammetry technologies, terrestrial laser scanning and remote sensing, and their use in the creation of spatial models of underground and surface objects, mapping of natural and anthropogenic objects and phenomena.



L'ubomír Kseňak He is an assistant professor at ÚGKaGIS, FBERG, TU Košice. He leads exercises from Spherical Geodesy, Remote Sensing, Surveying in Underground Spaces, and Field Exercises from Surveying. As part of his research activities, he deals with the issue of obtaining and processing data from remote sensing, specialising in various types of satellite data, while in this area, he has completed several foreign trainings and courses.

Preface

University textbook Earth Observation with ESA Missions is a textbook written primarily for students of the Faculty of Mining, Ecology, Process Control and Geotechnologies, the Technical University of Košice, in the field of study geodesy and geoinformatics. The textbook reflects the current needs and possibilities of education in these disciplines in higher education studies of the 1st and 2nd level of higher education. Within the preparation of the equivalent study subject, freely accessible lectures and tutorials for exercises are also prepared, which were created for the field of study Engineering Surveying and Cadastre of Real Estate in the 2nd level of higher education.

The course has been developed in the framework of the international project entitled University Course Earth Observation with ESA Missions within the framework of the activity Plan for European Cooperating States (PECS) launched by the European Space Agency ESA under the fifth call, Part E - Educational Activities. The PECS activity is aimed at the development of projects by research and commercial entities of the applicant country for membership of the European Space Agency in several areas: Flight Hardware, Preparatory Activities, Research and Development Activities, Space Applications, Products and Services and Educational Activities. The main objective of this course is to teach university students in the field of remote sensing, but more importantly, to get them interested in working in this field. The course curriculum allows students to acquire the latest knowledge in the use of space technologies offered by ESA and prepare them for future professional careers in these fields.

The textbook consists of 12 chapters, introducing ESA's historical, current, and planned Earth observation missions, online access to these data, and third-party data. The following chapters present the theory of electromagnetic radiation, its physical principles and interaction with the environment, and its use in optical and radar DPZ. A separate chapter covers image processing and enhancement, image analysis and classification needed for object detection. Two chapters are devoted to radar DPZ - fundamentals and SAR applications. A large part of the textbook consists of the use of data acquired primarily by ESA missions in areas such as land cover mapping, geological and mining mapping, forestry, water, snow and ice mapping, and use in monitoring and mapping natural disasters.

The text of the book is prepared in a combination of Slovak and English, with chapter titles, abstracts, table titles, figures and their titles in English.

All the materials produced to support this course - the university textbook, lectures and tutorials - are available on the website created for this purpose https://eo-esa.fberg.tuke.sk.

We believe that the prepared textbook and other supporting materials will be a useful and beneficial learning tool for students and possibly other practitioners.

Predhovor

Vysokoškolská učebnica Diaľkový prieskum Zeme misiami ESA je učebnica napísaná primárne pre študentov *Fakulty baníctva, ekológie, riadenia a geotechnológií Technickej univerzity v Košiciach*, v odbore geodézia a geoinformatika. Učebný text reflektuje aktuálne potreby a možnosti vzdelávania v týchto odboroch vo VŠ štúdiu I a II. stupňa. V rámci prípravy rovnomenného študijného predmetu sú pripravené aj voľne prístupné prednášky a návody na cvičenia, ktoré boli vytvorené pre študijný odbor Inžinierska geodézia a kataster nehnuteľností v II. stupni VŠ vzdelávania.

Predmet bol vytvorený v rámci riešenia medzinárodného projektu s názvom Univerzitný predmet Diaľkový prieskum Zeme misiami ESA v rámci activity Plan for European Cooperating States PECS vypísaný Európskou vesmírnou agentúrou ESA v rámci 5. výzvy, časť E - Vzdelávacie aktivity. Aktivita PECS je zameraná na tvorbu projektov výskumných a komerčných entít uchádzajúcej sa krajiny o členstvo v Európskej vesmírnej agentúre vo viacerých oblastiach: Letový hardware, Prípravné aktivity, Výskumné a vývojové aktivity, Vesmírne aplikácie, produkty a služby a Vzdelávacie aktivity. Hlavným cieľom tohto predmetu je vyučovať vysokoškolských študentov v oblasti diaľkového prieskumu Zeme, ale hlavne získať ich záujem o prácu v tomto odbore. Učebné osnovy predmetu umožňujú študentom získať najnovšie poznatky vo využívaní vesmírnych technológií, ktoré ESA ponúka a pripraviť ich na budúcu profesionálnu kariéru v týchto oblastiach.

Učebný text sa skladá z 12 kapitol, pričom v úvode sú predstavené historické, aktuálne, ale aj plánované misie ESA určené pre pozorovanie Zeme, online prístup k týmto dátam, a aj k dátam z tretích strán. V ďalších kapitolách je predstavená teória elektromagnetického žiarenia, jeho fyzikálne princípy a interakcia s prostredím, jeho využitie v optickom a radarovom DPZ. Samostatnou kapitolou je spracovanie a vylepšenie obrazu, obrazové analýzy a klasifikácie potrebné pre detekciu objektov. Dve kapitoly sú venované radarovému DPZ – základom a SAR aplikáciám. Veľkú časť učebného textu tvorí využitie dát získaných v prvom rade misiami ESA v oblastiach ako je mapovanie krajinnej pokrývky, geologické a banské mapovanie, lesníctvo, mapovanie vody, snehu a ľadu a využitie pri monitorovaní a mapovaní prírodných katastrof.

Text knihy je pripravený v kombinácii slovenského a anglického jazyka. Obsahuje názvy kapitol, ich abstrakty, názvy tabuliek, obrázky a ich názvy v anglickom jazyku.

Všetky materiály vytvorené ako podklad k tomtuto predmetu - vysokoškolská učebnica, prednášky a návody na cvičenia sú prístupné na web stránke https://eo-esa.fberg.tuke.sk zriadenej pre tieto potreby.

Veríme, že pripravený učebný text, ako aj ďalšie podklady, budú vhodným a prínosným nástrojom pri štúdiu pre študentov a prípadne aj ďalších pracovníkov z praxe.

Autori

ESA and its space activities

The history of the European Space Agency began many years ago. After World War II, many European scientists left Western Europe and decided to pursue scientific careers in the US or the Soviet Union, as they saw more potential in working with the superpowers. In 1958, two prominent members of the Western European scientific community -Pierre Auger and Edoardo Amaldi proposed to European governments to set up a purely scientific joint organisation for space research along the lines of CERN.

In 1960, scientists from 10 European countries of the "Groupe d'etudes europeen pour la Collaboration dans le domaine des recherches spatiales" (GEERS) formed a commission to decide on the possibilities of European cooperation in space. In 1962, two agencies were created: the European Launch Development Organisation (ELDO) and the European Space Research Organisation (ESRO) to develop spacecraft. In 1975, ESA in its present form was created by the merger of ELDO and ESRO. It has 10 founding members: Belgium, Germany, Denmark, France, Italy, the Netherlands, Spain, Sweden, Switzerland, the United Kingdom and the United States.

Since 2008, ESA has become a fully responsible partner in the operation and exploitation of the ISS and therefore has the right to fly its own astronauts on long-term missions as members of the ISS resident crew.

As ESA is involved in many activities, not only in remote sensing but also in planetary missions, and participates in the International Space Station ISS operation, it is challenging to mention all the activities fully.

This chapter is devoted to the characteristics of past, present and future ESA Earth observation satellite missions. It also includes information on the basic types of images and data from each mission, as well as how to access these data and data from third-party missions.

1.1. History of ESA

História Európskej vesmírnej agentúry sa začala písať pred mnohými rokmi. Po 2. svetovej vojne mnoho európskych vedcov opustilo západnú Európu a rozhodli sa ďalej vedecky pôsobiť v USA, alebo v Sovietskom zväze, nakoľko v spolupráci so superveľmocami videli väčší potenciál. V roku 1958 dvaja prominentní členovia západoeurópskej vedeckej komunity Pierre Auger a Edoardo Amaldi ponúkli európskym vládam, aby zriadili čisto vedeckú spoločnú organizáciu pre vesmírny výskum podľa vzoru CERNu.

V roku 1960 vedci z desiatich európskych krajín "*Groupe d'etudes europeen pour la Collaboration dans le domaine des recherches spatiales*" (GEERS) vytvorili komisiu, aby rozhodovala o možnostiach európskej spolupráce vo vesmíre. V roku 1962 vznikli dve agentúry: Európska organizácia pre rozvoj štartu (ELDO) a Európska organizácia pre výskum vesmíru (ESRO), pre vývoj kozmických lodí.

V roku 1966 vzniká spoločnosť ESRIN ako súčasť ESRO vo Frascatti, neďaleko Ríma, ktorá sa začína venovať činnostiam v pozorovaní Zeme. V 70. rokoch sa získavajú prvé satelitné snímky Zeme enviromentálneho charakteru. Riadia sa tu operácie misií a užitočného zaťaženia satelitov ESA na pozorovanie Zeme a zároveň je ESRIN primárnym zdrojom na získavanie, distribúciu a využívanie údajov z týchto a iných satelitov mimo ESA. V súčasnosti je ESRIN jedným z piatich špecializovaných centier ESA nachádzajúcich sa v Európe. Medzi ďalšie patrí európske stredisko pre vesmírne operácie (ESOC) založené v Nemecku, ktoré doposiaľ spravovalo 50 satelitov počas 40 ročnej histórie.

V roku 1968 sa ESTEC sťahuje na svoje súčasné miesto v Noordwijku v Holandsku. V roku 1975 vzniká ESA v súčasnej podobe zlúčením ELDO s ESRO. Má desať zakladajúcich členov: Belgicko, Nemecko, Dánsko, Francúzsko, Spojené kráľovstvo, Taliansko, Holandsko, Švédsko, Švajčiarsko a Španielsko. Írsko sa pripojilo neskôr v tomto roku. ESA spustila svoju prvú veľkú vedeckú misiu, Cos-B, satelit monitorujúci emisie gama žiarenia vo vesmíre. Jedna z najúspešnejších vesmírnych misií fungovala viac ako šesť rokov, o štyri roky dlhšie, ako sa plánovalo. V roku 1978 sa Kanada stala spolupracujúcim štátom. ESA sa pripojila k NASA a Veľkej Británii pri spustení IUE, prvého ďalekohľadu na svete na vysokej obežnej dráhe. V roku 1979 Rakúsko podpísalo asociačnú dohodu s ESA. Vypustila sa aj prvá raketa Ariane. V roku 1980 sa založila francúzska spoločnosť Arianespace, ktorá vyrába, prevádzkuje a predáva raketu Ariane 5 ako súčasť programu ESA Ariane. Ako nástupca ELDO začala ESA vyrábať rakety pre vedecké a komerčné využitie bez posádky. Úlohou Ariane je prenášať na obežnú dráhu komerčné náklady. Pokročilejší štartovací systém, Ariane 4 sa využíval v rokoch 1988 až 2003 a etabloval ESA ako svetového lídra v komerčných vesmírnych štartoch v 90. rokoch.

V roku 1983 Ulf Merbold z Nemecka sa stal prvým astronautom ESA, ktorý letel na americkom raketopláne počas misie STS-9 Spacelab. Giotto, prvá misia ESA do hlbokého vesmíru, študovala kométy Halley a Grigg-Skejllerup v roku 1986.

Vesmírne teleskopy SOHO, Ulysses a Hubbleov vesmírny teleskop boli spoločne konštruované s NASA v 90. rokoch. Medzi nedávne vedecké misie v spolupráci s NASA patrí Cassini-Huygens, do ktorej ESA prispela úspešnou sondou Huygens. V roku 1996 sa prvý let Ariane-5 skončil neúspechom. Neskoršie lety ustanovili Ariane na vysoko konkurenčnom trhu komerčných vesmírnych štartov s 25 úspešnými štartmi do roku 2006.

Od počiatku 21. storočia sa vypúšťali na orbitálne dráhy Mars Express a jej pristávacia stanica Beagle 2. Mars Express je prvá plne európska misia na akejkoľvek planéte, ktorá hrá kľúčovú úlohu v medzinárodnom prieskumnom programe, ktorý trvá nasledujúce dve desaťročia. V roku 2005 Sonda ESA Huygens pristála na povrchu Titanu, najväčšieho mesiaca Saturna – vôbec prvého, ktorý pristál vo vonkajšej slnečnej sústave. Dňa 22. mája 2007 bola podpísaná Európska vesmírna politika, čím sa zjednotil prístup ESA s prístupom jednotlivých členských štátov Európskej únie. Spoločne navrhnutá Európskou komisiou a generálnym riaditeľom ESA Jeanom-Jacquesom Dordainom po prvýkrát vytvára spoločný politický rámec pre vesmírne aktivity v Európe.

Od roku 2008 sa ESA stala plne zodpovedným partnerom pri prevádzke a využívaní ISS, a preto má právo lietať s vlastnými astronautmi na dlhodobé misie ako členovia rezidentskej posádky ISS. V tomto roku bolo skonštruované aj prvé automatizované prepravné zariadenie ESA ATV Jules Verne, ktoré bolo určené na prepravu životne dôležitých zásob na ISS.

V októbri 2009 sa astronaut ESA Frank De Winne pripojil k prvej šesťčlennej posádke ISS a stal sa tak prvým európskym veliteľom expedície na ISS. ESA si po prvý raz od roku 1992 vyberá nových astronautov, aby sa pripojili k Európskemu zboru astronautov a začali výcvik pre budúce misie na Medzinárodnej vesmírnej stanici a mimo nej. Na ISS sú naištalované European Node-3 a Cupola. Spustila sa prvá európska misia zameraná na štúdium ľadovej pokrývky Zeme, CryoSat-2. Vývoj vesmírnych technológii neustále napredoval prevádzkovaním množstva misií, operačných a vedeckých.

ESA spolupracuje aj s množstvom iných vedeckých agentúr ako napr. JAXA-Japonská vesmírna agentúra, CNES- Národné centrum pre vesmírne štúdie, ASI-Talianska vesmírna agentúra, DLR - Nemecké centrum pre letectvo a vesmír, NASA -Národný úrad pre letectvo a vesmír, CNSA - Čínsky národný vesmírny úrad. Misie ESA majú charakter verejno-súkromného partnerstva, z ktorých sú mnohé satelitnými operátormi (EUMETSAT, Eutelsat, Inmarsat). V súčasnosti program vesmírnych letov zahŕňa lety ľudí do vesmíru (ISS), prevádza bezpilotné prieskumné misie na planéty a Mesiac, diaľkový prieskum Zeme, vedecké a telekomunikačné misie, navrhovanie nosných rakiet a udržovanie vesmírneho strediska v Kourou vo Francúzskej Guyane (Guyana Space Centre, Kourou). Do roku 2020 prevádzkovala cca 85 historických a aktuálnych misií.

Nakoľko ESA zahŕňa množstvo aktivít nielen v diaľkovom prieskume Zeme, ale aj v planetárnych misiách, spolupodieľa sa na prevádzkovaní Medzinárodnej vesmírnej stanice ISS, je nesmierne ťažké plne spomenúť všetky aktivity.

1.2. ESA missions – past, recent, future

Európska vesmírna agentúra v rámci svojej činnosti, ktorá trvá už viac ako 46 rokov, skonštruovala mnoho vedeckých a telekomunikačných satelitných misií, ktoré viac či menej zaznamenali úspech a výsledky ich činností slúžia dodnes. Svojím zameraním ESA vyslala a sprevádzkovala nielen satelity určené pre diaľkový prieskum Zeme, ale aj viacero medziplanetárnych misií smerujúcim k výskumu viacerých oblastí vo vesmíre.

ESA prevádzkovala a prevádzakuje misie, ktoré postavili Európu na miesto predvoja disciplín ako napr. astronómia röntgenového, gama a infračerveného žiarenia; astrometria; vedy o Slnečnej sústave (najmä kometárne), slnečná a heliosférická fyzika, ako aj fyzika vesmírnej plazmy. V rámci programu Horizont 2000 bol navrhnutý vesmírny výskum tak, aby Európa hrala kľúčovú úlohu do konca storočia. Horizont 2000 zahŕňal misie ako Hubbleov vesmírny teleskop, Ulysses, Hipparcos a ISO.

V roku 2005 agentúra ESA vypracovala nový plán vesmírnych aktivít, ako napr. výskum iných svetov a života vo vesmíre, skúmanie ranného vesmíru, jeho vývoja, výskum kvantovej gravitácie, výskum vesmírnych gravitačných vĺn, výskum pôvodu Slnka a pod. V oblasti diaľkového prieskumu Zeme sa stala ESA významným prispievateľom dát z diaľkového prieskumu Zeme. Životné prostredie a klíma Zeme sú komplex interakcií medzi atmosférou, oceánmi, pevninou, kryosférou a schopnosťou ľudstva ovplyvňovať ich. Medzi prvými meteorologickými satelitmi ESA bol v roku 1977 skonštruovaný geostacionárny satelit Meteosat, ktorý stál za vznikom Organizácie pre využívanie meteorologických satelitov Eumetsat v roku 1986. Misia prešla mnohými vylepšeniami a v súčasnosti údaje poskytujú družice Meteosat 3. generácie.

1.2.1. Past ESA missions

Misie diaľkového prieskumu Zeme, ukončené, pôsobiace v rokoch 1991 až 2012 boli štyri: ERS-1, ERS-2, Envisat a GOCE. Prvá satelitná misia ESA European remote sensing ERS pokračovala v napredovaní získavania dát v rôznorodých oblastiach, ako výskumu globálneho a regionálneho oceánu a vedy o atmosfére, morskom ľade, výskumu glaciologickej a snehovej pokrývky, štúdie povrchu pôdy a dynamiku Zemskej kôry. Napríklad globálne mapy vetrov na morskej hladine v týchto rokoch poskytovali vstupy pre číselné údaje predpovede počasia. Po štarte v roku 1991 ERS-1 nasledoval v roku 1995 ERS-2, v roku 2002 veľký satelit ESA 2. generácie Envisat, ktorý bol významným prispievateľom k monitorovaniu a porozumeniu životného prostredia hlavne v oblastiach chémie atmosféry a oceánskych biologických procesov. Medzi ďalšími jadrovými misiami ESA sa začali od roku 1994 formovať myšlienky na monitoring zemskej radiácie: Earth Radiation Mission ERM, gravitačného poľa a cirkulácie oceánu GOCE, procesov povrchu Zeme a ich interakcií Land Surface Processes and Interaction Mission LDPIM a misie dynamiky atmosféry Atmospheric Dynamics Mission ADM Aeolus.

1.2.1.1. ERS-1 satellite

ERS-1 (Obr. 1.1) bol prvým programom v pozorovaní Zeme a monitorovania životného prostredia v mikrovlnnej časti EMŽ. Pokrývala široké spektrum odborov a tém: pozorovanie oceánov, polárneho ľadu, ekológie krajiny, geológie, lesníctva, vlnové javy, batymetrie (meranie hĺbka vody), fyziky atmosféry, meteorológia, atď. V roku 2000 spôsobilo zlyhanie gyroskopu ukončenie misie.



Obr. 1.1 ERS-1 družica. **Fig. 1.1** ERS-1 satellite. Source: www.asi.it/en/earth-science/ers-1

ΑΜΙ	Active Microwave Instrument			
RA-1	Radar Altimeter-1			
ATSR-1	Along-Track Scanning Radiometer and Microwave Sounder-1			
LRR	Laser Retro-Reflector			
PRARE	Precise Range And Range-Rate Equipment			

1.2.1.2. ERS-2 satellite

Družica ERS-2 bola druhou EO misiou takmer identickou s ERS-1, vypustenou v roku 1995. Obe družice niesli senzory radaru so syntetickou apertúrou (SAR) a radarovým senzorom pre altimetrické merania pre štúdium teplôt na povrchu mora a rýchlosti vetra a zároveň niesla senzor na výskum atmosférického ozónu. V čase vypustenia boli ERS-1 a ERS-2 najsofistikovanejšie družice vo vesmíre, pričom vôbec ako prvá tandemová misia pracovali spolu 9 mesiacov. Obežné dráhy oboch družíc boli nafázované tak, aby mali 24 – hodinový interval záznamu. Aj keď bola životnosť družice naplánovaná na 3 roky, svoju plnú funkčnosť si zachovala viac ako 10 rokov, čím sa misia výrazne predĺžila. Družica ERS-2 niesla senzory:

TSR-2	Along-Track Scanning Radiometer and Microwave Sounder-2
GOME	Global Ozone Monitoring Experiment
PRARE	Precise Range And Range-Rate Equipment tracking system

	ERS - 1	ERS - 2	GOCE	Envisat
Orbita	Helio synchrónna, nízka polárna	Helio synchrónna, nízka polárna	Helio synchrónna, nízka polárna	Helio synchrónna nízka polárna
Výška letu	782 - 785 km	782-785 km	278 – 254 km	772-774 km
Inklinácia	98.5°	98.5°	96.7°	98.371°
Perióda obehu	100 min	100 min		100.16 min
Temporálne rozlíšenie	35 dní	35 dní	30-40 dní	35 dní
Váha	2 384 kg	2 516 kg	1 052 kg	8 211 kg
Štart misie	17 Júl 1991	1 Marec 2002	17 Marec 2009	1 Marec 2002
Ukončenie misie	10 Marec 2000	5 September 2011	11 November 2013	9 Máj 2012

Tab. 1.1 Porovnanie už neaktívnych družicových systémov ESA. **Tab. 1.1** Comparison of ESA satellite systems no longer active.

1.2.1.3. ENVISAT satellite

Družica ENVISAT (Obr. 1.2) poskytovala nepretržité pozorovanie Zeme od roku 2002. Išlo o komplexnú družicu, ktorá poskytovala dáta pre štúdium a monitorovanie životného prostredia Zeme v rôznych mierkach, od lokálnej cez regionálnu až po globálnu, monitorovanie a riadenie zdrojov Zeme, obnoviteľných aj neobnoviteľných, meteorologických údajov. Prispela k pochopeniu štruktúry a dynamiky zemskej kôry a Zemského telesa. Misia zahŕňala hlavné vedné disciplíny ako meteorológia, klimatológia, životné prostredie, chémia atmosféry, vegetácia, hydrológia, využitie pôdy, procesy oceánov a ľadu – pevniny, atmosféry, oceánov a ľadovcov na polárnej obežnej dráhe. Išlo o najväčšiu satelitnú misiu s váhou viac ako 8 ton a rozmermi 26 x 10 x 5 m, ktorá pozostávala z desiatich senzorov – radarov, radarových výškomerom, rádiometrov, multispektrálneho senzora a spektrometra so stredným rozlíšením a dva atmosférické senzory monitorujúce stopové plyny.



Obr. 1.2 ENVISAT družica. **Fig. 1.2** ENVISAT satellite. Source: www.onda-dias.eu/cms/data/catalogue/envisat

Družica Envisat spolu s družicou ERS – 2 slúžila pre rôzne interferometrické merania ako napr. pozorovania rýchlo sa pohybujúcich ľadovcov a pre vytvorenie presných digitálnych výškových modelov s nízkym reliéfom (Severná Kanada, severné Rusko), kde nie sú dostupné dáta SRTM DEM.

Senzory Envisatu:

MERIS	Medium Resolution Imaging Spectrometer		
MIPAS	Michelson Interferometer for Passive Atmospheric Sounding		
RA-2	Radar Altimeter-2, a Laser Retro-Reflector (LRR) is included		
MWR	Microwave Radiometer		
ASAR	(Advanced SAR) pracujúci v C-pásme pre zaistenie kontinuity údajov po ERS-2		
GOMOS	Global Ozone Monitoring by Occultation of Stars, skúmajúci chémiu a dynamiku hornej atmosféry		
SCIAMACHY	Scanning Imaging Absorption Spectrometer for Atmospheric Cartography, riadené Nemeckom a Holanskom		
AATSR	Advanced Along Track Scanning Radiometer, riadené UK a Austrália		
DORIS	riadené Francúzskom		
12.1.4. GOCE satellite			

Tretí z radu satelitov pozorujúcich Zem bol satelit GOCE (Gravity filed a Ocean Circulation Explorer, Obr.1.3), ktorý pracoval od roku 2009 do 2013. Jeho cieľom bolo merať

gravitačné pole Zeme a modelovať geoid s veľmi vysokou presnosťou na veľmi nízkej obežnej dráhe iba 224 km. Vysoko presný gravitačný gradiometer mapoval geoid a získal informácie o vnútornej štruktúre Zeme, ako aj o prúdoch cirkulujúcich v hlbinách oceánov.



Obr. 1.3 GOCE družica. **Fig. 1.3** GOCE satellite. Source: earth.esa.int/eogateway/missions/goce

Gravitačná mapa a model geoidu poskytli používateľom na celom svete dobre definované dátové produkty, ktoré sú nápomocné pri napredovaní vedy a aplikácií v širokom rade disciplín. Hoci sa jeho let skončil, množstvo údajov z GOCE sa naďalej využíva na zlepšenie nášho chápania geodézie, geofyziky, prieskumu, cirkulácie oceánov, oceánografie, hladiny morí, dynamiky ľadu a vnútra Zeme. Vedecké ciele misie boli:

1. Poskytovať nové chápanie fyziky zemského vnútra vrátane geodynamiky spojenej s litosférou, zložením plášťa a reológiou, procesmi zdvíhania a subdukcie.

- 2. Poskytovať presný odhad geoidu v podmorských oblastiach, potrebného na kvantitatívne určovanie absolútnych morských prúdov a ich prenosu tepla a iných vlastností v kombinácii so satelitným výškopisom.
- 3. Poskytovať lepší globálny výškový referenčný systém pre referenčné spojenie, ktoré môže slúžiť ako referenčný povrch na štúdium topografických procesov, ako je vývoj ľadových štítov a povrchu Zeme.
- Poskytovať odhad hrúbky polárnych ľadových štítov kombináciou topografie podložia odvodenej z gradiometrie a topografie povrchu ľadovej pokrývky z výškového merania.



Obr. 1.4 Rozloženie globálnej Mohorovičićovej plochy diskontinuity a tvar geoidu získaný na základe misie GOCE.

Fig. 1.4 Distribution of the global Mohorovičić discontinuity surface and the shape of the geoid obtained from the GOCE mission.

Source: ©GEMMA project; ©ESA

GOCE niesol senzory:

- **ECG** The Electrostatic Gravity Gradiometer, ktorý meral stacionárne gravitačné pole a gravitačné anomálie s vysokým priestorovým rozlíšením a vysokou presnosťou,
- SSTI The Satellite to Satellite Tracking Instrument,
- **STR** The Star Trackers,
- MGM 3-osí magnetometer,
- LRR The Laser Retroreflector pre satelitnú službu laserových meraní,

1.2.2. Current ESA Earth Observation missions

Aktuálne pracujúce misie diaľkového prieskumu Zeme sú Aeolus, Cloudsat, Sentinel,1, 2, 3, 5P a SWARM. V Tab. 1.2 sú uvedené technické špecifikácie týchto misií.

Tab. 1.2 Technické parametre aktuálnych misií.

Tab. 1.2 Technical parameters of current missions.

	AEOLUS	CRYOSAT	SWARM
Orbita	Helio synchrónna, nízka polárna	Helio nesynchrónna, polárna	Polárna
Výška letu	320 km	717 km	SWARM A, C 460 km SWARM B 530 km
Inklinácia	97°	92°	SWARM A, C 87,4° SWARM B 88,0°
Perióda obehu	90 min	-	-
Váha	1366 kg	720 kg	468 kg
Štart misie	22 August 2018	8 Apríl 2010	22 November 2013
Trvanie misie	3 roky a 3 mesiace	11 rokov 8 mesiacov	4 roky

1.2.2.1. Aeolus mission

Misia Aeolus (Obr. 1.5) odštartovala v auguste 2018. Poskytuje vertikálne profily troposférických a nižších stratosférických prúdov vetra na zlepšenie predpovede počasia a výskumu dynamiky atmosféry. Pomocou senzora dopplerovského veterného lidaru Atmospheric Laser Doppler Instrument (ALADIN) umožňuje určiť cirkuláciu najmä v tropických oblastiach a na južnej pologuli, nad oceánmi a v polárnych oblastiach, kde nie je dostatok informácií z iných satelitných misií. Rovnako poskytuje informácie o vertikálnej distribúcii aerosólu a oblačnosti.



Obr. 1.5 Veterný profil z družice Aeolus 6.mája 2020. **Fig. 1.5** Wind profile from the Aeolus satellite on 6 May 2020. Source: ©ESA/VirES

Misia pracuje na princípe krátkych a silných pulzov UV žiarenia z lasera, pričom meria Dopplerov posun od veľmi malého množstva svetla, aby vytvoril vertikálne profily horizontálnej rýchlosti svetových vetrov do 26 km výšky atmosféry. Obr. 1.6 a 1.7 zobrazujú transport údajov každých 90 minút do pozemnej stanice vo Svalbarde, pričom sú tieto údaje následne odoslané do Tromso v Nórsku. Následne dáta putujú do Európskeho centra pre strednodobé predpovede počasia v Readingu vo Veľkej Británii a do centra pozorovania Zeme ESRIN v talianskom Frascati, ktoré údaje distribuuje používateľom.



Obr. 1.6 Systém transportu údajov z družice Aeolus do pozemnej stanice vo Svalbarde a následne do celej Európy.

Fig. 1.6 Data transport system from the Aeolus satellite to the Svalbarde station and then to the whole of Europe. Source: ©ESA/ATG medialab



Obr. 1.7 Misia Aeolus a monitoring globálnej atmosféry. **Fig. 1.7** Aeolus mission and monitoring of global atmosphere. Source: ©ESA/ATG medialab; directory.eoportal.org/web/eoportal/satellite-missions/a/aeolus

1.2.2.2. Cryosat-2 mission

Misia ESA Earth Explorer Cryosat (Obr. 1.8) je zameraná na meranie hrúbky polárneho morského ľadu a hrúbky kontinentálnych ľadovcových štítov, ktoré pokrývajú Grónsko a Antarktídu. Jeho hlavným užitočným zaťažením je interferometrický radarový výškomer SAR, ktorý je navrhnutý pre meranie ľadu, pričom meria zmeny na okrajoch rozsiahlych ľadových štítov a plávajúceho ľadu v polárnych oceánoch. Zároveň je špeciálne navrhnutý na monitorovanie najdynamickejších úsekov kryosféry Zeme. Pôvodný satelit Cryosat-1 zlyhal pri štarte v roku 2005.

CryoSat používa syntetické apertúrne radarové a interferometrické techniky zo štandardných zobrazovacích radarových misií, aby zlepšila svoju presnosť na drsných okrajoch ľadových vrstiev a morského ľadu v polárnych vodách. Meria "voľný bok" – rozdiel vo výške medzi morským ľadom a priľahlou vodou – ako aj nadmorskú výšku ľadovej pokrývky, pričom sleduje zmeny hrúbky ľadu.



Obr. 1.8 Pohľad na družicu Cryosat -2. **Fig. 1.8** View of the Cryosat-2 satellite. Source: ©ESA/ATG medialab



Obr. 1.9 Medziročná a sezónna zmena nadmorskej výšky Grónskeho ľadového štítu z radarového výškopisu CryoSat-2, 2011–2020. **Fig. 1.9** Interannual and seasonal change in elevation of the Greenland Ice Sheet from CryoSat-2 radar altimetry, 2011-2020. Source: Slater et al., 2021

Obr. 1.9 znázorňuje medziročnú a sezónnu zmenu nadmorskej výšky Grónskeho ľadovcového štítu a rýchlosť zmeny nadmorskej výšky povrchu medzi rokmi 2011 a 2020. Fialové kontúry zobrazujú oblasti dlhodobej dynamickej nerovnováhy z opakovaných optických snímok (1985–2018) a dynamických výškových trendov určených zo satelitných výškomerov a Inštitútu pre morský a atmosférický výskum Utrecht Firn Densification Model (2011–2017). Priemerné rýchlosti zmeny nadmorskej výšky počas mája až augusta a medzi rokmi 2011 a 2020. Fialové kontúry zobrazujú rozsah použitej zóny ablácie ľadového štítu v tejto štúdii. Priemerná miera zmeny nadmorskej výšky počas septembra až apríla medzi rokmi 2011 a 2020.

Ciele misie CryoSat sú:

- 1. Zmerať rozsah rednutia arktického ľadu v dôsledku zmeny klímy.
- 2. Určiť kolísanie hmotnosti hlavných pevninských a morských ľadových polí Zeme.
- 3. Určiť regionálne trendy v hrúbke a hmotnosti trvalého morského ľadu v Arktíde.
- 4. Určiť, akým spôsobom antarktické a grónske ľadové štíty znamenajú globálne zvýšenie hladiny morí.
- 5. Sledovať sezónny cyklus a medziročnú variabilitu arktického a antarktického morského ľadu a jeho hrúbky.
- 6. Pozorovať zmeny v hrúbke ľadovcov.

Senzory nesené misiou Cryosat-2:

SIRAL	The SAR/Inteferometric Radar Altimeter,
DORIS	(Doppler Orbitography and Radiopositioning Integration by Satellite),

LRR (Laser Retroreflector)

1.2.2.3. SWARM mission

Swarm je trojsatelitná konštelácia (Swarm Bravo, Swarm Alpha a Swarm Charlie) Európskej vesmírnej agentúry (ESA) konštruovaná pre štúdium dynamiky magnetického poľa Zeme a jeho interakcií so systémom Zeme. Cieľom misie (Obr. 1.10) je poskytnúť doposiaľ najlepší prieskum geomagnetického poľa a jeho vývoja v čase a získať pritom nové poznatky o systéme Zeme zlepšením chápania vnútra a prostredia Zeme.

Každý z troch satelitov vykonáva presné meranie sily, smeru a variácií zemského magnetického poľa s vysokým rozlíšením, doplnené o presnú navigáciu a merania elektrického poľa. Poskytujú údaje pre modelovanie geomagnetického poľa a jeho interakcie s inými fyzikálnymi aspektmi Zeme. Swarm získava časopriestorovú charakteristiku vnútorných zdrojov poľa Zeme a ionosféricko-magnetosférických systémov prúdov. Výsledky ponúkajú pohľad do vnútra Zeme z vesmíru. Umožňujú detailné štúdium zloženia a procesov vo vnútri a zvyšujú naše znalosti o atmosférických procesoch a vzorcoch oceánskej cirkulácie, ktoré ovplyvňujú klímu a počasie.



Obr. 1.10 Družica SWARM. **Fig. 1.10** SWARM satellite. Source: www.satnews.com/story.php?number=1951047189

Ciele výskumu pridelené misii sú:

- 1. štúdie dynamiky jadra, procesov geodynama a interakcie jadro-plášť;
- 2. mapovanie litosférickej magnetizácie a jej geologická interpretácia;
- 3. stanovenie 3-D elektrickej vodivosti plášťa;
- 4. skúmanie elektrických prúdov prúdiacich v magnetosfére a ionosfére.

Magnetické pole Zeme je pole (Obr. 1.11 a 1.12), v ktorom pôsobí magnetická sila a je dôležitým ochranným faktorom pre biosféru. Má dipólový charakter. Jeho tvar silne ovplyvňuje slnečný vietor, ktorý na náveternej strane pôsobí tlakom. Magnetosféra Zeme nedovoľuje elektricky nabitým časticiam slnečného vetra dostať sa k povrchu Zeme. Nabité častice musia pri svojom pohybe sledovať siločiary magnetického poľa. Plní teda ochrannú funkciu, bez ktorej by život na Zemi nebol možný. Nesené senzory misiou SWARM:

- VFM Vector Field Magnetometer;
- ASM Absolute Scalar Magnetometer;
- EFI Electric Field Instrument;
- ACC Accelerometer;
- LRR Laser Range Reflect;



Obr. 1.11 Zobrazenie dynamiky magnetického poľa zeme na základe družíc SWARM. **Fig. 1.11** SWARM satellite imaging of the Earth's magnetic field dynamics. Source: ©ESA/ATG medialab



Obr. 1.12 Znázornenie dynamiky magnetického poľa Zeme, vplyvu zemského jadra a plášťa. **Fig. 1.12** An illustration of the dynamics of the Earth's magnetic field, the influence of the Earth's core and mantle. Source: ©ESA/DTU Space

1.2.2.4. SMOS mission

Družica SMOS (Obr. 1.13); vytvorená ESA je súčasťou programu Living Planet Programme. Ide o prvú misiu, ktorá z mikrovlnných meraní v L-pásme poskytuje globálne pozorovania premenlivosti pôdnej vlhkosti a slanosti morského povrchu v dôsledku nepretržitej výmeny vodného cyklu Zeme medzi oceánmi, atmosférou a pevninou. Tieto kľúčové geofyzikálne parameter ako je vlhkosť pôdy pre hydrologické štúdie a slanosť pre lepšie pochopenie oceánskej cirkulácie, sú pre modely klimatických zmien životne dôležité. Telo družice nesie senzor MIRAR Microwave Imaging Radiometer using Aperture Synthesis, ktorý zachytáva slabé mikrovlnné emisie z povrchu Zeme na mapovanie úrovní pôdnej vlhkosti, slanosti morského povrchu, hrúbky morského ľadu a iných geofyzikálnych premenných, ako je rýchlosť vetra nad oceánom a stav pôdy zmrazovania/topenia. Hoci bola misia plánovaná na päť rokov, Programová rada pre pozorovanie Zeme odporučila schváliť predĺženie operácií misie SMOS na základe jej vynikajúceho technického a vedeckého výkonu do konca roku 2021. To umožňuje vylepšenú analýzu dlhodobejšieho procesu a nové synergické príležitosti z nových pozorovacích systémov.



Obr. 1.13 Družica SMOS. **Fig. 1.13** SMOS satellite. Source: ©ESA - P. Carril

1.2.2.5. Sentinel-1 mission

Misia Sentinel-1 (Obr. 1.14) pozostáva z konštelácie dvoch satelitov (A, B) na polárnych obežných dráhach, ktoré nepretržite vykonávajú radarové snímanie v pásme C so syntetickou apertúrou SAR (Synthetic Aperture Radar).



Obr. 1.13 Družica Sentinel-1. **Fig. 1.13** Sentinel-1 satellite. Source: ©ESA/P. Carril

Misia Sentinel-1 je navrhnutá tak, aby poskytovala zvýšenú frekvenciu opakovaných návštev, pokrytie, včasnosť a spoľahlivosť pre prevádzkové služby a aplikácie vyžadujúce dlhé časové rady. Bude poskytovať operačnú interferometriu prostredníctvom prísnych požiadaviek kladených na presnosť polohy, znalosti o polohe a obežnej dráhe a presnosť časovania zberu údajov.

Úlohou tejto misie je plniť potreby programu Copernicus a členských štátov EÚ pre vedecké, ale aj komerčné ciele s tým, že dáta z tejto misie môžu v otvorenom bezplatnom režime využívať všetci používatelia SAR technológie a zároveň zabezpečuje kontinuitu satelitných SAR dát získaných v misiách ERS a Envisat.

Sentinel-1 poskytuje služby dodávania údajov pre aplikácie v prioritných oblastiach programu Copernicus, ako je monitorovanie oceánov a morí, monitorovanie krajiny a núdzový manažment. Družica zobrazuje globálne pevniny, pobrežné zóny a lodné trasy v európskych vodách vo vysokom rozlíšení a globálne pokrýva oceány. Hlavný prevádzkový režim získava snímky v zábere 250 km (20 m rozlíšenie Level-1).

Tab. 1.3 Technical parameters of current Sentinel missions. Sentinel - 1 Sentinel - 2 Sentinel - 3 Orbita Blízko polárna Helio-synchrónna, Helio-synchrónna,

Tab. 1.3 Technické parametre aktuálnych misií Sentinel.

Orbita	Blízko polárna	Helio-synchrónna, blízko polárna	Helio-synchrónna, blízko polárna
Výška letu	693 km	786 km	814,5 km
Inklinácia	98,18°	98,62°	98,65°
Perióda obehu	98,6 min	100 min	101 min
Cyklus	5 dní	5 dní	27 dní
Váha	2 300 kg	1140 kg	1 250 kg
Štart misie	S1-A 3.4.2014 S1-B 25.4.2016	S2-A 23.6.2015 S2-B 7.3.2017	S3-A 106.2.2016 S3-B po roku 2021
Trvanie misie	aktívna	aktívna	aktívna

Misia získava SAR dáta v štyroch režimoch a v štyroch úrovniach (Obr. 1.15):

- 1. Interferometric Wide Swath Mode (IW);
- 2. Extra Wide Swath Mode (EW);
- 3. Stripmap (SM);
- 4. *Wave* (WV).
- Level-0 sú nepracované raw data,
- Level-1 SLC (Single Look Complex) obsahujú komplexné snímky s amplitúdou a fázou,
- Level-1 GRD (Ground Range Detected),
- Level-2 OCN (Ocean) poskytujú dáta o geofyzikálnych parametroch oceánu.

1 ESA, Earth Observation, Data Access



Obr. 1.15 Grafické znázornenie základných produktov Sentinel-1. **Fig. 1.15** Graphical representation of Sentinel-1 basic products. Source: ©ESA

Level 0

Produkty SAR úrovne 0 pozostávajú zo sekvencie komprimovaných nespracovaných údajov SAR s flexibilnou dynamickou blokovou adaptívnou kvantizáciou (FDBAQ). Aby boli údaje použiteľné, je potrebné ich dekomprimovať a spracovať pomocou procesora SAR.

Level 1

Údaje úrovne I sú všeobecne dostupné produkty určené pre väčšinu používateľov údajov. Produkty úrovne I sú vyrábané ako Single Look Complex (SLC) a Ground Range Detected (GRD). Produkty Single Look Complex (SLC) úrovne I pozostávajú zo sústredených údajov SAR georeferencovaných pomocou údajov o obežnej dráhe a polohe zo satelitu a poskytovaných v geometrii sklonu s nulovým Dopplerom. Produkty obsahujú jediný vzhľad v každej dimenzii využívajúci celú šírku pásma prenosového signálu a pozostávajú z komplexných vzoriek uchovávajúcich fázovú informáciu.

Produkty úrovne 1 Ground Range Detected (GRD) pozostávajú zo sústredených údajov SAR, ktoré boli detekované, viacnásobne sledované a premietnuté na dosah zeme pomocou modelu zemského elipsoidu. Informácie o fáze sa stratia. Výsledný produkt má približne štvorcové priestorové rozlíšenie pixelov a štvorcový rozostup pixelov so zníženou škvrnitosťou za cenu horšieho priestorového rozlíšenia.

Level 2

Pozostáva z geograficky odvodených geofyzikálnych produktov SM úrovne Level I a síce produkt Ocean 2 (OCN), ktorý obsahuje nasledovné komponenty: oceánske veterné polia (OWI Ocean Wind Field), spektrá vĺn (OSW Ocaen Swell sprectra),informácie o povrchovej radiálnej rýchlosti (RVL Surface radial Velocity) ako odvodené z údajov SAR.

1.2.2.6. Sentinel-2 mission

Misia Sentinel-2 (Obr. 1.16) pozostáva z konštelácie dvoch satelitov (A, B) nesúcich multispektrálny sensor, obiehajúcich po blízko polárnych obežných heliosynchrónnych dráhach, ktoré sú fázované o 1800. Optický senzor sníma trinásť pásem s 10 m, 20 m a 60 m priestorovým rozlíšením. Stopa záberu senzora je 290 km.



Obr. 1.16 Družica Sentinel-2. **Fig. 1.16** Sentinel-2 satellite. Source: ©ESA

Misia Sentinel-2 je svojím systematickým pokrytom a vysokým rozlíšením senzora (Tab 1.4) významným prispievateľom dát v službách mapovania a monitorovania Zeme - ako mapovanie stavu vegetácie, vodných cyklov, prírodných hazardov akými sú zemetrasenia a záplavy. Podporuje aplikácie priestorového plánovania, vodného a lesného manažmentu (odlesňovania), poľnohospodárstva a bezpečnosti, klimatických zmien a množstva aplikácii pre monitoring pobrežia, morí a oceánov.

Sentinel-2	Vlnová dĺžka (mm)	Priestorové rozlíšenie (m)	
Band 1 - Coastal aerosol	443	60	
Band 2 - Blue	492	10	
Band 3 - Green	560	10	
Band 4 - Red	665	10	
Band 5 - Vegetation red edge	704	20	
Band 6 - Vegetation red edge	740	20	
Band 7 - Vegetation red edge	783	20	
Band 8 - NIR	833	10	
Band 8A - Vegetation red edge	865	20	
Band 9 - Water vapour	945	60	
Band 10 - SWIR - Cirrius	1373	60	
Band 11 - SWIR	1614	20	

Tab. 1.4 Spektrálne pásma družice Sentinel-2. **Tab. 1.4** Sentinel-2 satellite spectral bands.

Produktové typy

Level 0 sú komprimované nespracované údaje. Produkt Level-0 obsahuje všetky informácie potrebné na generovanie Level-1 (a vyšších) úrovní produktu.

Level-1A sú nekomprimované, nespracované údaje so spektrálnymi pásmami, ktoré sú nahrubo registrované s pripojenými pomocnými údajmi.

Level-1B sú rádiometricky korigované údaje. Fyzický geometrický model je spresnený pomocou dostupných pozemných kontrolných bodov a pripojený k produktu.

Produkty úrovne 0, úrovne 1A a úrovne 1B nie sú určené pre bežných používateľov.

Level-1C poskytuje ortorektifikovanú odrazivosť hornej atmosféry (Top-Of-Atmosphere – TOA) so subpixelovou multispektrálnou registráciou.

Produkt úrovne 2A poskytuje ortorektifikovanú odrazivosť spodnej časti atmosféry (BOA) so subpixelovou multispektrálnou registráciou. Súčasťou produktu je mapa klasifikácie scén (oblaky, tiene mrakov, vegetácia, pôdy/púšte, voda, sneh atď.).

Produkty Level-1C a Level-2A sú sprístupnené používateľom prostredníctvom Copernicus Open Access Hub (SciHub).

1.2.2.7. Sentinel-3 mission

Sentinel-3 (Obr. 1.17) je európska satelitná misia na pozorovanie Zeme vyvinutá na podporu aplikácií Copernicus v oceánoch, zemi, atmosfére, núdzových, bezpečnostných a kryosférických aplikáciách. Hlavným cieľom misie Sentinel-3 je merať topografiu morského povrchu, povrchovú teplotu morí a pevniny a farbu povrchu oceánov a pevniny s vysokou presnosťou a spoľahlivosťou na podporu systémov predpovedí oceánov, monitorovania životného prostredia a monitorovania klímy. Misiu Sentinel-3 spoločne prevádzkujú ESA a EUMETSAT s cieľom poskytovať operačné služby pozorovania oceánov a pevniny.



Obr. 1.17 Družica Sentinel-3. **Fig. 1.17** Sentinel-3 satellite. Source: www.onda-dias.eu/cms/data/catalogue/sentinel-3

Družica nesie štyri hlavné prístroje:

OLCI Ocean and Land Colour Instrument, prístroj na záznam farby oceánu a povrchu,

- **SLSTR** Sea and Land Surface Temperature Instrument, Prístroj na meranie povrchovej teploty mora a súše,
- SRAL SAR Radar Altimeter, SAR Radarový výškomer,
- MWR Microwave Radiometer, MikrovInný rádiometer,

Dopĺňajú ich tri nástroje na presné určenie obežnej dráhy (POD):

- **DORIS** Doppler Orbit Radio positioning system, Dopplerov orbitálny rádiový polohovací systém,
- **GNSS** prijímač GPS, ktorý poskytuje presné určenie obežnej dráhy a sledovanie viacerých satelitov súčasne,
- LRR Laser Tero Reflector, na presnú lokalizáciu satelitu na obežnej dráhe pomocou laserového reflexného systému.

1.2.2.8. Sentinel-5 mission

Misie Sentinel-4, -5 a -5 prekurzor (S4, S5, S5P, v tomto poradí) sú koncipované ako doplnkové prvky konštelácie slúžiace špecifickým potrebám služieb monitorovania atmosféry Copernicus (CAMS). Tieto služby budú poskytovať ucelené informácie o atmosférických premenných na podporu európskych politík a v prospech európskych občanov. Budú zahŕňať aplikácie ozónu a povrchového UV žiarenia, kvality ovzdušia a klímy. Sentinel-5 (Obr. 1.18) je zameraný na získavanie informácií o kvalite ovzdušia a interakcii medzi zložením a klímou, pričom hlavnými dátovými produktmi sú O₃, NO₂, SO₂, HCHO, CHOCHO a aerosóly. Sentinel-5 navyše poskytuje kvalitatívne parametre pre atmosférické zlúčeniny CO, CH₄ a stratosférický O₃ s denným globálnym pokrytím pre klímu, kvalitu ovzdušia a ozónové/povrchové UV aplikácie.



Obr. 1.18 Družica Sentinel-5p. **Fig. 1.18** Sentinel-5p satellite. Source: ©ESA/ATG medialab

Misia Sentinel-5 pozostáva zo systému spektrometra s vysokým rozlíšením, ktorý pracuje v ultrafialovom až krátkovlnnom infračervenom rozsahu so 7 rôznymi spektrálnymi pásmami: UV-1 (270 - 300nm), UV-2 (300 - 370nm), VIS (370 - 500nm), NIR-1 (685 - 710nm), NIR-2 (745 - 773nm), SWIR-1 (1590 - 1675nm) a SWIR-3 (2305 - 2385nm). Prístroj bude prenášaný na satelite MetOp-SG A. Prehľad aktuálnych a plánovaných misií Sentinel znázorňuje Obr. 1.19.

1 ESA, Earth Observation, Data Access



Obr. 1.19 Prehľad aktuálnych a plánovaných misií Sentinel. **Fig. 1.19** Overview of current and planned Sentinel missions. Source: ©ESA

1.2.3. Overview of planned ESA missions

1.2.3.1. EarthCARE mission

Od misie ESA EarthCARE (Cloud, Aerosol and Radiation Explorer, Obr. 1.20) sa očakáva, že bude spustená v roku 2021. Je doteraz najväčšou a najkomplexnejšou družicou Zeme a posunie porozumenie tomu, akú úlohu zohráva oblačnosť a aerosóly pri odrážaní dopadajúceho slnečného žiarenia späť do vesmíru a zároveň zachytáva infračervené žiarenie vyžarované z povrchu Zeme. EarthCARE predstavuje spoločný výskum medzi agentúrami ESA a JAXA (Japan Aerospace Exploration Agency).



Obr. 1.20 Satelit EarthCARE. **Fig. 1.20** EarthCARE satellite. Source: ©ESA–P. Carril

EarthCARE bude využívať vysokovýkonnú lidarovú a radarovú technológiu, s cieľom poskytnúť také súbory údajov, ktoré umožnia vedcom študovať vzťah oblačnosti, aerosólov a žiarenia na úrovni presnosti, ktorá výrazne zlepší naše chápanie týchto údajov.

Senzory nesené misiou EarthCARE:

- ATLID Atmospheric Lidar,
- **CPR** Cloud Profiling Radar,
- MSI Multi-Spectral Imager,
- BBR Broad-Band Radiometer.

1.2.3.2. Biomass mission

Plánovaná misia Biomass (Obr. 1.21) by mala poskytovať kľúčové informácie o stave našich lesov a o ich zmene. Údaje sa použijú na ďalšie poznatky o úlohe, ktorú lesy zohrávajú v cykle uhlíka. Družica Biomass taktiež poskytne základnú podporu zmluvám OSN o znížení emisií z odlesňovania a degradácie lesov. Spustenie tejto duržice sa očakáva koncom roka 2022 a plánuje sa ako päťročná misia. Cieľom misie Biomass je určiť globálnu distribúciu lesnej biomasy znížením neistoty pri výpočte zásob uhlíka a tokov spojených s pozemskou biosférou.

Senzory nesené družicou Biomass:

PolSARpro Polarimetric SAR data Processing and Education,

ESOV Earth Observation Swath and Orbit Visualisation,

BioPAL Biomass Product Algorithm Laboratory,



Obr. 1.21 Družica Biomass. **Fig. 1.21** Biomass satellite. Source: ©Airbus Defence and Space

1.2.3.3. FLEX mission

Misia FLuorescence EXplorer (FLEX, Obr. 1.22) poskytne globálne mapy fluorescencie vegetácie, ktoré môžu odrážať fotosyntetickú aktivitu a zdravie rastlín a stres. Na druhej strane je to dôležité nielen pre lepšie pochopenie globálneho uhlíkového cyklu, ale aj pre riadenie poľnohospodárstva a potravinovú bezpečnosť. Toto je obzvlášť dôležité vzhľadom na dopyt, ktorý rastúca svetová populácia kladie na výrobu potravín.

Misia FLEX bude lietať v tandeme s misiou Copernicus Sentinel-3, najmä v kombinácii s nástrojmi OLCI a SLSTR, ktoré Sentinel-3 nesie.



Obr. 1.22 Družica FLEX. **Fig. 1.22** FLEX satellite. Source: ©Thales Alenia Space

Misia FLEX bude mapovať fluorescenciu vegetácie na kvantifikáciu fotosyntetickej aktivity. Kvantifikáciou fluorescencie vegetácie, indexu fotochemickej odrazivosti, povrchovej teploty, poskytne koncepcia misie FLEX najinovatívnejšiu a jedinečnú sadu meraní na zvýšenie nášho chápania skutočnej účinnosti fotosyntézy a stavu zdravia vegetácie a výkonnosti rastlín.

Senzory družice FLEX:

FLORIS Fluorescence Imaging Spectrometer, ktorý bude získavať údaje v spektrálnom rozsahu 500 - 780 nm., bude mať vzorkovanie 0,1 nm v kyslíkových pásmach (759 – 769 nm a 686 – 697 nm) a 0,5 – 2,0 nm v červenom okraji, absorpciu chlorofylu a PRI (Photochemical Reflectance Index) pásma.

1.3. Types of data provided and access to data

1.3.1. ESA Hub, Open access to ESA data

Copernicus Open Access Hub (predtým známy ako Sentinels Scientific Data Hub) poskytuje úplný, bezplatný a otvorený prístup k užívateľským produktom Sentinel-1, Sentinel-2, Sentinel-3 a Sentinel-5p, počnúc prehľadom uvedenia do prevádzky na obežnej dráhe (IOCR). Údaje Sentinel sú dostupné aj prostredníctvom služieb Copernicus Data and Information Access Services (DIAS) prostredníctvom niekoľkých platforiem. Možnosť zaregistrovať sa online prostredníctvom vlastnej registrácie je umožnené akýmkoľvek záujemcom (Obr. 1.23). Proces samoregistrácie je automatický a okamžitý. Registrácia udeľuje prístupové práva na vyhľadávanie a sťahovanie produktov Sentinel. Produkty Sentinel sú dostupné bezplatne pre kohokoľvek. Údaje dostupné prostredníctvom dátového centra sa riadia právnym oznámením o používaní údajov a informácií o službe Copernicus Sentinel, na ktoré používateľ využívaním údajov Sentinel dal súhlas.


Obr. 1.23 Okno prehliadača ESA hub s vybranými snímkami v rámci záujmového územia. **Fig. 1.23** ESA hub viewer window with selected images within the area of interest. Source: own processing

ESA Hub umožňuje online kontrolu hľadaných produktov prehliadaním a prezeraním metadát produktu a meraní bez ich sťahovania. Panel náhľadu zobrazuje informácie o obsahu a štruktúre produktu (Obr. 1.24). Produkty Sentinel sú poskytované na stiahnutie cez HTTP vo formáte archívneho súboru *.ZIP. Kliknutím a stiahnutím sa dostávajú do nákupného košíka na hromadné sťahovanie. Na jedného používateľa sú povolené maximálne 2 súbežné sťahovania , aby sa zabezpečila kapacita sťahovania pre všetkých používateľov.

1 ESA, Earth Observation, Data Access



Obr. 1.24 Nahlad vybranej snimky s metadatami o snimke. **Fig. 1.24** A preview of the selected image with its metadata. Source: own processing

1.3.2. Third party missions TPM

Okrem toho, že ESA poskytuje satelitné dáta používateľom zo svojich vlastných satelitných zdrojov na pozorovanie Zeme (EO), poskytuje ESA používateľom prístup z niekoľkých misií EO mimo ESA – takzvané "misie z tretích strán" (Third Party Missions (TPM) - Obr. 1.25 a 1.26). Pri vedeckom využití dát je nutné kombinovať satelitné zdroje, aby sa zvýšila udržateľnosť ich služieb a aby sa rozšíril rozsah sledovaných parametrov, aby sa maximalizovalo využitie dát ESA a TPM a aby sa stimuloval rozvoj vedy. Aktuálne zoznamy misií tretích strán je možné nájsť na stránkach ESA:

https://earth.esa.int/eogateway/missions/third-party-missions

O údaje z tretích strán môže požiadať kdokoľvek, v závislosti od licenčných podmienok pre užívateľov z niektorých krajín s ohľadom na národnú legislatívu v poskytovaní údajov.

Typy dát prístupných cez ESA TPM:

- Radarové snímky mikrovlnné znímky zemského povrchu, produkty SAR,
- **Optické/multispektrálne snímky** viditeľné a IR snímky s najvyšším rozlíšením od 1m, stredné a nízke rozlíšenie,
- Atmosférické dáta údaje o zložení atmosféry.

1 ESA, Earth Observation, Data Access

			CURRENT	CURRENT			
CURRENT				Mission	Instrument		
	Mission	Instrument	Atmospheric Data	Aura	OMI		
Optical (Very High Resolution)	Deimos-2	HIRAIS		GOSAT	TANSO-CAI / TANSO-FTS		
	GeoEye-1	GIS		Odin	OSIRIS / SMR		
	Ikonos-2	OSA (PAN and MS)		SciSat-1/ACE	ACE-FTS / MAESTRO		
	KOMPSAT-2	MSC	Optical	PROBA-V	Vegetation		
	Pleiades 1A/1B	HiRI	(Low/Med Resolution)	Landsat-8	TIRS		
	QuickBird	BGIS2000		Oceansat-2	0CM-2		
	SPOT 6/7	NAOMI	Optical	ALOS	AVNIR-2 / PRISM		
	WorldView-1/2/3	WV-110	(Med/High Resolution)	CartoSat-1 (IRS-P5)	PAN		
Other	GRACE	GRACE Instrument		Deimos-1	SLIM-6		
Radar	ALOS	PALSAR		DMC	SLIM-6		
	JERS-1	L-band SAR		IRS-1C/D	LISS-III / PAN / WiFS		
	QuikSCAT	SeaWinds		JERS-1	OPS		
	SeaSat	L-band SAR		KOMPSAT-1	EOC		
Radar (Very High Resolution)	COSMO-SkyMed	SAR 2000		Landsat-4/5	TM		
	RADARSAT-1/2	C-band SAR		Landsat-7	ETM+		
	TerraSAR-X	X-band SAR		Landsat-8	OLI		
	TanDEM-X	X-band SAR		Proba-1	CHRIS / HRC		
DOTENTIAL				RapidEye	REIS		
Optical (Low/Med Resolution)	Mission	Instrument		ResourceSat-1 (IRS-P6)	LISS-III/IV / AWIFS		
	Nimbus-7	0705		ResourceSat-2	LISS-III/IV / AWiFS		
	OrbView-2	SeaWiFS		SPOT 1 to SPOT 3	HRV		
Ontical (Mod/High Resolution)	Landcat 1-5	MSS		SPOT 4	HRVIR		
optical (mea/right Resolution)	Lanusat 1-3	1055 1055		SDOT 5			

Obr. 1.25 Aktuálne poskytované dáta v rámci TPM. **Fig. 1.25** Data currently provided within the TPM. Source: Symbios Spazio UK, 2018



Obr. 1.26 Prehľad dĺžky trvania aktuálnych a historických misií. **Fig. 1.26** Overview of the duration of current and historical missions. Source: Symbios Spazio UK, 2018 Pre získanie dát zo satelitných misií tretích strán je zriadený webový prístup cez hlavný bod webovej stránky ESA:

-) C A 1 + THE EUROPEAN SPACE AGENCY eesa Find something on Earth Online earth online TQT EARTH ONLINE Farth Obs rvation information disc **Copernicus Sentinel Data** ESA and TPM Earth Observation Data ADDITIONAL EFI TII CROSS TRACK FLOW DATASET 0302 AVAILABLE al TII c **Explore our Missions**

Obr. 1.27 Prístupový bod pre dáta tretích strán na portáli ESA. **Fig. 1.27** Access point for third party missions data on the ESA portal. Source: © ESA

Odkaz ESA and TPM Earth Observation Data užívateľa presmeruje na stránku s výberom dostupných satelitov:



https://eocat.esa.int/sec/#data-services-area

Obr. 1.28 Výber záujmovej oblasti a požadovanej satelitnej misie v ESA portáli EO-CAT. **Fig. 1.28** Selection of the area of interest and the satellite mission in the ESA portal EO-CAT. Source: own processing

Používatelia tu môžu nájsť:

http://earth.esa.int

- novinky a popisy misií a ich prístrojov,
- popisy zbierok,
- technický popis produktu,
- prepojenia na prístup k údajom,

• informácie o vybraných témach Zeme, resp. životného prostredia a aplikácie satelitných údajov.

V ponuke Prístup k údajom/Prehľadávanie údajových produktov, používatelia môžu prehliadať podľa typu satelitu, prístroja, aplikácie, úrovni spracovania a typu produktu.

Ako požiadať o údaje?

Portál umožňuje tri spôsoby prístupu:

1. Okamžitý prístup cez MyEarthNet:

https://earth.esa.int/web/guest/pi-community/myearthnet

 Podaním návrhu, kde požiadavky na údaje podliehajú špecifickému získavaniu alebo obmedzeniu šírenia. Návrh je hodnotený počas 6-8 týždňov a ak je akceptovaný, žiadateľovi sa pridelí kvóta produktov na projekt. Podanie návrhu je možné realizovať na adrese:

https://earth.esa.int/webiguest/pi-community/

3. Oznámenie o príležitosti (Announcement of Opportunity (AO)) znamená, že ESA vydá oznámenie pre konkrétne misie, resp. výskumné témy. Ak požadované údaje spadajú do konkrétneho subjektu, na ktorý sa vzťahuje oznámená špecifická príležitosť, po doručení a prijatí žiadosti bude potvrdenie doručené do niekoľkých týždňov. Informácie o aktuálnych oznámených príležitostiach je možné nájsť na adrese:

https://earth.esa.int/webiguest/pi-community/apply-for-data/ao-s.

Prístup k archívnym dátam a historickým misiám ESA je možné nájsť na adrese:



https://earth.esa.int/eogateway

Obr. 1.29 Prístup k dátam historických misií ESA a iných. **Fig. 1.29** Access to data from historical ESA and other missions. Source: ©ESA

1.3.3. Other web services for browsing and downloading images

Prístup k dátovým službám zo satelitných a leteckých zdrojov umožňujú viaceré svetové portály. Tak ako aj pri ESA Hub, aj tu je možné na základe interaktívnej mapy zadávať požiadavky na výber záujmovej oblasti, dátumu a zdroja snímok.

Dátový portál Geologického prieskumu US **USGS Earth Explorer** (Obr. 1.30) je vynikajúcou pomôckou pre zdroj nielen satelitných dát, ale aj rozsiahlych zbierok leteckých snímok. Zo satelitných dát poskytuje údaje z misií NASA Landsat 1-9, Sentinel 2, EO, IKONOS, OrbView 3, ale aj údaje z UAV, digitálne výškové modely, letecké snímky, digitálne mapové údaje a mnoho ďalších údajov.

Dáta USGS sú prístupné na adresách:

https://imagery.geocento.com/

https://earthexplorer.usgs.gov/



Obr. 1.30 Portály Earth Explorer USGS a Earth Images. **Fig. 1.30** Explorer USGS and Earth Images portals. Source: own processing

Alaska Satellite Facility (ASF) spája, spracováva, archivuje a distribuuje údaje z DPZ vedeckým pracovníkom z celého sveta (Obr. 1.31). ASF podporuje rozvoj DPZ na podporu národného a medzinárodného výskumu vied o Zemi. Poskytuje množstvo údajov a služieb. Prevádzkuje archív NASA údajov z radarového snímkovania so syntetickou apertúrou SAR z rôznych satelitov a lietadiel. Poskytuje tiež podporné služby výskumníkom na podporu dátového a informačného systému NASA o Zemi.

Dáta z ASF sú dostupné na adrese:

https://asf.alaska.edu/



Obr. 1.31 Portál ASF Data Search Vertex. **Fig. 1.31** ASF Data Search Vertex Portal. Source: own processing

EO Browser je výkonný nástroj na prehliadanie a spracovávanie satelitných snímok v plnom rozlíšení z poskytovaných zbierok údajov (Obr. 1.32). Obsahuje veľké množstvo doplňujúcich funkcií. Výberom oblasti svojho záujmu a požadovaného časového rozpätia a pokrytia oblačnosti sa v prehliadači zobrazia výsledné údaje. Je možné vytvoriť si rôzne vizualizácie alebo si stiahnuť snímky vo vysokom rozlíšení s vytvorením časových radov. EO Browser poskytuje bezplatné používanie, aby boli tieto funkcie dostupné takmer každému. Zároveň umožňuje okamžite vizualizovať satelitné dáta z mnohých satelitov a dátových kolekcií. Proces na pozadí sa stará o výber vhodných scén, sťahovanie a spracovanie dát, ako aj tvorbu mozaiky. Satelitné snímky v prehliadači EO browser je možné vizualizovať na základe želanej konfigurácie používateľa, ale aj podľa pripravených vizualizácií s legendami a popismi ako true color, false color, NDVI, EVI atď. Výhodou je možnosť vytvorenia si vlastných indexov z kombinácií spektrálnych pásem. EO browser navyše umožňuje tvorbu vlastného skriptu ako výkonného nástroja na vizualizáciu satelitných údajov.



Obr. 1.32 Portál EO Browser. **Fig. 1.32** EO Browser portal. Source: www.sentinel-hub.com/explore/eobrowser/

Snímky je možné porovnávať, vytvárať si vlastné časové rady, štatistické analýzy, užívateľské konfigurácie a 3D zobrazenia.

AIRBUS prevádzkovateľa Airbus Defence and Space / Airbus Defence and Space GmbH (Obr. 1.33) poskytuje vlastný prístup k najväčšej komerčnej satelitnej konštelácii kombinujúcej optické snímky z Pléiades, SPOT, Vison – 1 a DMC, ako aj radarovej konštelácii TerraSAR-X, TanDEM-X a PAZ. Rozširujú aj možnosti senzorov o konšteláciu Pléiades Neo s vyšším priestorovým a temporálnym rozlíšením. Kombináciou vlastných údajov a údajov z tretích strán spolu s možnosťami získavania, spracovania šírenia a získavnia spracovateľských informácií poskytujú široké portfólio produktov a služieb geoinformácií.



Obr. 1.33 Portál AIRBUS. **Fig. 1.33** AIRBUS portal. Source: terrasar-x-archive.terrasar.com

Globe Portal System G-Portal japonskej spoločnosti JAXA ,Japonskej agentúry pre letecký prieskum, poskytuje bezplatné dáta z vesmírnych senzorov, ktoré vyvinula, resp. do ktorých sa zapojila v rámci svojej činnosti (Obr. 1.34). K dispozícii sú dáta hlavne z družíc GPM, TRMM, ALOS, ALOS-2, MODIS, CIRC, MOS-1, MS- 1B, JUER-1 ADEOS, GMOS-W, ADOES-II, Aqua, SLATS.



Obr. 1.34 G-Portal spoločnosti JAXA. **Fig. 1.34** JAXA G-portal. Source: gportal.jaxa.jp/gpr/

1.4. Copernicus - European Union's Earth Observation Programme

Copernicus je európsky program informačných služieb pozorovania Zeme, v minulosti známy ako program globálneho monitorovania životného prostredia a bezpečnosti GMES (Obr. 1.35 a 1.36). Poskytuje presné, včasné a ľahko dostupné informácie na zlepšenie riadenia životného prostredia, pochopenie a zmiernenie účinkov zmeny klímy a zabezpečenie civilnej bezpečnosti. Iniciatívu vedie Európska komisia (EK) v partnerstve s Európskou vesmírnou agentúrou (ESA), Európskou organizáciou pre využívanie meteorologických satelitov (EUMETSAT), Európskym centrom pre strednodobé predpovede počasia (ECMWF), agentúrami EÚ a so strediskom Mercator Océan.

ESA koordinuje a zabezpečuje v tomto programe získavanie a prenos údajov z viac ako 30 satelitov. V rámci Copernicus programu ESA vyvíja novú skupinu satelitov s názvom Sentinel tak, aby vyhovovali potrebám špeciálnych služieb programu Copernicus.

Program Copernicus je rozdelený do šiestich tematických skupín:

- 1. atmosféra,
- 2. morské prostredie,
- 3. pevnina,
- 4. klimatické zmeny,
- 5. bezpečnosť,
- 6. núdzové situácie.

Prehľad štruktúry programu Copernicus a ním poskytovaných služieb:



Obr. 1.35 Program Copernicus a rozdelenie jeho služieb. **Fig. 1.35** Copernicus programme and its services. Source: www.copernicus.eu/en/about-copernicus/copernicus-detail

Informácie, ktoré poskytujú služby programu Copernicus, využívajú občania a inštitúcie EU v širokom spektre aplikácií v rôznych oblastiach – vo verejnom, komerčnom a výskumnom sektore. Takýmito oblasťami môžu byť napríklad riadenie mestských oblastí, trvalo udržateľný rozvoj a ochrana prírody, regionálne a miestne plánovanie, poľnohospodárstvo (podmienky plodín, prognózovanie výnosov, mapovanie obrábaných plôch, hospodárenie s vodami, monitoring sucha a kontrola dotácií), lesníctvo

(mapovanie zalesnenia, inventarizácia lesov, monitoring lesných požiarov, nezákonnej ťažby dreva) a rybolov, zdravie, civilná ochrana (bezpečnosť plavby, znečisťovanie mora, monitoring kritickej infraštruktúry), doprava a mobilita (kontrola dopravných tokov námorných, leteckých a s tým spojené narúšanie enviromentálnymi hrozbami a pirátstvom), ako aj cestovný ruch, zmena klímy a jej dopady (poskytuje kľúčové ukazovatele pre sledovanie rovnováhy premeny uhlíka, premeny medzi zemou, morom, ovzduším a množstvom slnečného žiarenia).



Obr. 1.36 Vesmírny komponent programu Copernicus. **Fig. 1.36** Copernicus Space Component. Source: www.copernicus.eu/en/about-copernicus/copernicus-detail

Copernicus poskytuje jednotný systém, prostredníctvom ktorého sa obrovské množstvá údajov vkladajú do radu tematických informačných služieb navrhnutých tak, aby boli prínosom pre životné prostredie, spôsob nášho života, humanitárne potreby a podporu efektívnej tvorby politiky pre udržateľnejšiu budúcnosť.

References

Books

European Space Technology master plan 2017

Wilson, A. (2005). ESA achievements : more than thirty years of pioneering space activity (3rd ed., pp. 1–202). ESA Publications Division. ISBN 92-9092-493-4

Papers, manuals, reports

Slater, T., Shepherd, A., McMillan, M., Leeson, A., Gilbert, L., Muir, A., Munneke, P. K., Noël, B., Fettweis, X., van den Broeke, M., & Briggs, K. (2021). Increased variability in Greenland Ice Sheet runoff from satellite observations. Nature Communications, 12(1). DOI: 10.1038/s41467-021-26229-4

Olsen, N., Friis-Christensen, E., Floberghagen, R., Alken, P., Beggan, C. D., Chulliat, A., Doornbos, E., da Encarnação, J. T., Hamilton, B., Hulot, G., van den IJssel, J., Kuvshinov, A., Lesur, V., Lühr, H., Macmillan, S., Maus, S., Noja, M., Olsen, P. E. H., Park, J., & Plank, G. (2013). The Swarm Satellite Constellation Application and Research Facility (SCARF) and Swarm data products. Earth, Planets and Space, 65(11), 1189–1200. DOI: 10.5047/eps.2013.07.001

"ESA's GOCE mission comes to an end" (Press release). European Space Agency. 21 October 2013. No. 33-2013. Retrieved 10 July 2017

Straume-Lindner, A. G. (2018). Aeolus Sensor and Product Description. In earth.esa.int (pp. 1–20). European Space Research and Technology Centre. https://earth.esa.int/eogateway/documents/20142/37627/Aeolus-Sensor-and-Product-Description.pdf

Symbios Spazio UK. (2018). ESA'S Earth Observation Third Party Missions - Data Access Guide (p. 92). European Space Agency.

Web sources

https://www.esa.int/About_Us/ESOC/Mission_history https://www.esa.int/Enabling_Support/Operations/Current_and_future_missions https://www.esa.int/ESA/Our_Missions https://earth.esa.int/eogateway/missions/goce https://www.esa.int/Enabling_Support/Operations/GOCE https://gportal.jaxa.jp/gpr https://terrasar-x-archive.terrasar.com https://apps.sentinel-hub.com/eo-browser https://imagery.geocento.com https://earthexplorer.usgs.gov https://asf.alaska.edu

Electromagnetic radiation

RS is a technology for observing the Earth's surface or atmosphere from space using satellite or airborne vehicles. RS uses a portion or several portions of the electromagnetic spectrum that are reflected as electromagnetic energy from the Earth's surface. The radiation source is the Sun, or electromagnetic radiation emitting (EMR) device directly on the satellite carrier, or the radiated energy of the Earth's body is measured directly. The amount of radiation reflected by an object is influenced by both the properties of the object and the radiation incident on the object. Various types of sensors and devices are used for remote sensing of the Earth, sensing visible EMW in wavelengths from 400 to 700 nm, but also near-infrared (Near Infrared NIR - 0.7 to 1.3 µm), mid-IR (mid-IR, or shortwave IR SWIR - 1.3 to 3 µm), thermal IR (thermal IR, long IR - 3 to 14 µm) and microwave radiation (microwave 1mm -1m). The images thus acquired have many applications in land use and land cover mapping, agriculture, soil mapping, forestry, urban planning, archaeological research, military applications, geomorphological surveys, land cover change, deforestation, vegetation dynamics, water quality dynamics, urban growth, etc.

Detection of objects or surface features is dependent on the detection of radiant energy reflected or emitted by objects or surface materials. Different objects reflect different amounts of energy in different spectral bands of the incident electromagnetic spectrum. This depends on the material properties, surface roughness, angle of incidence, intensity and wavelength of the radiant energy. RS is a multidisciplinary science involving different disciplines such as optics, spectroscopy, photographic imaging, computer science, electronic and telecommunication, rocket technology, etc. All these technologies are integrated to work as one complete system.

This chapter is devoted to the physical basis of electromagnetic radiation, its properties, and its interaction with the atmosphere and the Earth's surface.

2.1. Introduction

DPZ je veda a súbor technologických komponentov na pozorovanie zemského povrchu alebo atmosféry z vesmíru pomocou satelitných alebo leteckých nosičov. Diaľkový prieskum využíva časť alebo niekoľko častí elektromagnetického spektra, ktoré je odrazené ako elektromagnetická energia zo zemského povrchu. Zdrojom žiarenia je Slnko alebo zariadenie emitujúce elektromagnetické žiarenie (EMŽ), ktoré sa nachádza priamo na satelitnom nosiči, alebo sa meria priamo vyžiarená energia zemského telesa (teplotná bilancia morí a oceánov, lesné požiare, a pod.). Množstvo žiarenia odrazené objektom je ovplyvnené vlastnosťami objektu aj žiarením dopadajúcim na objekt. Pre diaľkový prieskum Zeme sa využívajú rôzne druhy senzorov a zariadení snímajúce viditeľné EMŽ vo vlnových dĺžkach od 400 do 700 nm, ale aj blízke infračervené (Near Infrared NIR - 0,7 až 1,3 µm), stredné infračervené (mid IR, resp. shortwave IR SWIR - 1,3 až 3 μm), termálne infračervené (thermal IR, long IR 3 – 14 μm) a mikrovlnné žiarenie (microwave 1mm -1m) (Obr. 2.1). Takto získané snímky majú mnoho aplikácií pri mapovaní využitia krajiny a pokrytia, poľnohospodárstvo, mapovanie pôdy, lesníctvo, mestské plánovanie, archeologický výskum, vojenské aplikácie, geomorfologický prieskum, zmeny krajinnej pokrývky, odlesňovanie, dynamika vegetácie, dynamika kvality vody, rast miest a pod.



Obr. 2.1 Spektrum elektromagnetického žiarenia a atmosférické okná. **Fig. 2.1** Electromagnetic radiation spectrum and atmospheric windows. Source: science.nasa.gov/ems/01_intro

Detekcia objektov alebo povrchových prvkov je závislá od zaznamenania žiarivej energie odrazenej alebo vyžarovanej predmetmi alebo povrchovými materiálmi. Rôzne predmety odrážajú rôzne množstvo energie v rôznych spektrálnych pásmach elektromagnetického spektra, ktoré naň dopadajú. Toto závisí od vlastnosti materiálu (štrukturálna, chemická a fyzikálna), drsnosti povrchu, uhlu dopadu, intenzity a vlnovej dĺžky žiarivej energie. Diaľkový prieskum Zeme je v multidisciplinárna veda, ktorá zahŕňa kombináciu rôznych disciplín ako optika, spektroskopia, fotografické snímkovanie, počítačové vedy, elektronické a telekomunikačné, raketové technológie atď. Všetky tieto technológie sú integrované tak, aby pracovali ako jeden kompletný systém. Diaľkový prieskum Zeme má niekoľko fáz procesu a každý z nich je dôležitý pre jeho úspešnosť.

Žiarenie je tok elektromagnetickej energie medzi Slnkom a zemským povrchom, resp. aktívnou družicou a povrchom, pretože je ovplyvnený mrakmi, aerosólmi a plynmi

v zemskej atmosfére. Zahŕňa slnečné žiarenie (slnečné svetlo) aj dlhovlnné (tepelné) žiarenie. Množstvo slnečného žiarenia dopadajúceho na zemský povrch a množstvo žiarenia opúšťajúceho zemskú atmosféru ovplyvňuje viacero faktorov. Medzi tieto faktory patria atmosférické prvky, ako sú kvapky oblakov, vlhkosť, teplota, atmosférické plyny, aerosólové častice a dokonca aj vlastnosti povrchov pevniny a oceánov.

Viditeľné svetlo je len jednou z mnohých foriem elektromagnetickej energie (Obr. 2.1). EMŽ je šírené formou elektromagnetických vĺn, ktoré sa šíria časom a priestorom v smeroch kolmých na smer ich pohybu (okrem polarizovaného žiarenia) a má sínusový priebeh. Vlnenie je charakterizované dvoma základnými parametrami: vlnová dĺžka a frekvencia (alebo perióda). Vlnová dĺžka λ je vzdialenosť medzi dvoma po sebe nasledujúcimi vrcholmi vĺn. Frekvencia v je počet kmitov (cyklov) dokončených za periódu 1 s. Perióda T vlny je T = 1/v s frekvenciou v v cykloch/s. Vo vákuu sa EM vlny šíria konštantnou rýchlosťou c, rýchlosťou svetla (c = 299792458 m/s), čo je súčin vlnovej dĺžky a frekvencie:

$$c = \lambda . v \approx 300.000 \text{ km/s}, \qquad (2.1)$$

takže frekvencia a vlnová dĺžka sú pre EM vlnu navzájom nepriamo úmerné.



Obr. 2.2 Charakteristika EMŽ. **Fig. 2.2** Characteristics of electromagnetic radiation. Source: Emery & Camps, 2017

Kvantová elektrodynamika (QED), kvantová teória poľa matematicky popisuje nielen všetky interakcie svetla s hmotou, ale aj interakcie nabitých častíc navzájom. Všetky hmotné telesá vo vesmíre vyžarujú energiu v podobe elektromagnetického žiarenia. Množstvo takto emitovanej (vyžiarenej) energie závisí od niekoľkých faktorov, napríklad od teploty či farby povrchu telesa. Zloženie spektra vyžiareného telesom v závislosti od jeho teploty. Pre výpočty žiariaceho telesa sa používa zjednodušený model telesa, tzv. absolútne čierne teleso. Absolútne čierne teleso je hypotetické teleso, ktoré musí spĺňať dve podmienky:

- 1. Pohlcuje všetko elektromagnetické žiarenie naň dopadajúce nakoľko ostatné telesá pohlcujú iba časť elektromagnetického žiarenia a zvyšné svetlo odrážajú.
- 2. So svojím okolím zostáva v termodynamickej rovnováhe, t. j. má rovnakú teplotu ako ostatné telesá uzavretej sústavy, v ktorej sa nachádza. V rámci tejto sústavy teda neprebieha tepelná výmena. Čierne teleso je hypotetický, ideálny žiarič, ktorý absorbuje a emituje všetku energiu, ktorá naň dopadá.

V roku 1900 nemecký fyzik Max Planck objavil, že telesá nevyžarujú elektromagnetické žiarenie spojite, ale po tzv. kvantách. Veľkosť energie *E* týchto energetických kvánt je daná Planckovou konštantou $h \approx 6,626 \cdot 10^{-34}$ Js vynásobenou frekvenciou žiarenia *v*:

$$E = h.v \tag{2.2}$$

Elektromagnetická vlna je v podstate súbor kvánt, ktorých celková energia určuje energiu tejto vlny. Pre každú frekvenciu má energetické kvantum špecifickú veľkosť. Z rovnice vyššie je vidieť, že žiarenie s vyššími frekvenciami sa skladá z väčších kvánt než žiarenie s nižšími frekvenciami. Ak dáme do súvisu vzťah medzi rýchlosťou šírenia EMŽ a veľkosťou emitovanej energie získame vzťah:

$$E = \frac{h.c}{\lambda} \tag{2.3}$$

Zo vzťahu vyplýva, že enegia kvanta je nepriamo úmerná jeho vlnovej dĺžke. Toto zistenie má dôležitý vplyv na záznam v diaľkovom prieskume, nakoľko emitované dlhovlnné žiarenie (mikrovlnné) je ťažšie zaznamenateľné ako žiarenie z kratších vlnových dĺžok (ako napr. termálne, NIR žiarenie). Akokoľvek, všetky objekty vo vesmíre, ktorých teplota je vyššia ako absolútna 0 (0K, resp. -273°C), nepretržite emitujú EMŽ. Koľko energie vyžaruje objekt závisí od jeho povrchovej teploty, čo popisuje Stefan-Boltzmannov zákon:

$$I = \sigma T^4 , \qquad (2.4)$$

kde

/ je celková intenzita žiarenia čierneho telesa materiálu [Wm⁻²],

 σ je Stefan-Bolzmannova konštanta, σ = 5,6697x10⁻⁸ Wm⁻²K⁻⁴,

T je termodynamická teplota [K] emitujúceho telesa.

Zo vzťahu (2.4) vyplýva, že celková emitovaná energia telesom sa rýchlo zvyšuje so stúpajúcou teplotou.

V prípade žiarenia tzv. šedého telesa (nedokonalého) je vzťah (2.4) modifikovaný pomocou premennej ϵ vyjadrujúcej emisivitu šedého telesa nasledovne:

$$I = \epsilon \sigma T^4 . \tag{2.5}$$

Žiarenie nedokonalého čierneho telesa popisuje Obr. 2.3. Na obrázku sú znázornené distribučné krivky čierneho telesa od 3000K do 6000K, ktoré potvrdzujú Stefan-Boltzmannov zákon, že čím je vyššia teplota, tým je vyššia intenzita žiarenia čierneho telesa. Vrchol jednotlivých kriviek je posunutý smerom ku kratším vlnovým dĺžkam, čo potvrdzuje, že žiarenie čierneho telesa s kratšími vlnovým dĺžkami emituje viac energie *E*.



Obr. 2.3 Žiarenie čierneho telesa. **Fig. 2.3** Blackbody radiation. Source: http://hyperphysics.phy-astr.gsu.edu/hbase/wien.html

2.2. Interactions of electromagnetic radiation in the atmosphere

Elektromagnetické žiarenie zo Slnka, resp. z iných emitujúcich zdrojov interaguje v atmosfére javmi ako pohltenie (absorbcia), prepustenie (transmisia) a odraz (reflexia). Slnečné žiarenie dopadajúce na topografický povrch je výsledkom zložitej interakcie medzi atmosférou a povrchom Zeme. Jeho množstvo závisí od mnohých faktorov. Emitovaná energia zo zdroja je prepustená atmosférou, čiastočne je absorbovaná a následne je odrazená zemským povrchom naspäť do atmoféry a tak je zachytená senzorom.

Na Obr. 2.4 je znázornený vplyv atmostéry na emitované slnečné žiarenie, ktoré musí prejsť atmosférou dráhu k senzoru dvakrát, pričom je žiarenie prepustené oblačnosťou, aerosolmi, interaguje s molekulami v atmosfére, dopadá na topografický povrch, kde je absorbovavé a odrazené naspäť do atmostéry. Vplyv atmosféry sa mení rozdielmi počas dráhy vplyvom panujúcich atmosférických podmienok v dráhe EMŽ. Atmosféra má preto veľký vplyv na intenzitu a spektrálne zloženie snímaného signálu. Samotné zemské teleso ale rovnako emituje vlastné tepelné žiarenie, ktoré slúži hlavne na určenie tepelnej bilancie morí a oceánov, ale aj na lokalizáciu lesných požiarov.

2 Electromagnetic radiation



Obr. 2.4 Interakcia EMŽ v atmosfére. **Fig. 2.4** Interaction of electromagnetic radiation in the atmosphere. Source: own processing

2.3. Dispersion

Modré nebo ako výsledok interakcie slnečného EMŽ s atmosférou popisuje Rayleigh rozptyl. EMŽ interaguje s časticami v atmosfére, ktoré sú menšie ako vlnová dľžka svetla. Počas transmisie atmosférou sa fotóny EMŽ zrážajú s atómami a molekulami, v dôsledku čoho sa zmení smer ich šírenia. Vlnová dĺžka žiarenia sa tým nemení, ale zmení sa smer jeho šírenia. Rayleighov rozptyl slnečného svetla v zemskej atmosfére popisuje difúzne žiarenie oblohy, čo je dôvodom modrej farby dennej a súmrakovej oblohy, ako aj žltkastého až červenkastého odtieňa nízkej polohy Slnka pri jeho vychádzaní a pri jeho západe. Slnečné svetlo tiež podlieha Ramanovmu rozptylu, ktorý mení rotačný stav molekúl a vyvoláva polarizačné efekty.



Obr. 2.5 Obrázok znázorňujúci vyššiu početnosť interakcií žiarenia s kratšou vlnovou dĺžkou. **Fig. 2.5** Figure showing the higher frequency of shorter wavelength radiation interactions. Source: gfycat.com/inconsequentialmeanbackswimmer

Rayleigh rozptyl nastáva, ak je veľkosť častíc menšia ako veľkosť vlnoných dĺžok $r < \lambda$ (napr. molekuly plynov NO₂, O₂), a tak sa na nich odrážajú pomerne viac modré vlnové dĺžky (Obr. 2.6). Rayleighov rozptyl je nepriamo úmerný štvrtej mocnine vlnovej dĺžky, takže fialové a modré svetlo s kratšou vlnovou dĺžkou sa rozptýli viac ako dlhšie vlnové dĺžky (žlté a najmä červené svetlo).

Intenzita *Rayleighovho* roztylu na molekulách je vyjadrením závislosti indexu lomu v zmysle molekulovej polarizovateľnosti *α*, úmernej dipólovému momentu indukovanému elektrickým poľom svetla. V tomto prípade je intenzita Rayleighovho rozptylu pre jednu časticu daná ako:

$$I = I_0 \frac{8\pi^4 \alpha^2}{\lambda^4 R^2} (1 + \cos^2 \theta)$$
 (2.6)

Sčervenanie slnka sa zintenzívni, keď je blízko horizontu, pretože svetlo, ktoré priamo od neho prijíma, musí prechádzať väčšou časťou atmosféry. Účinok sa ešte zvyšuje, pretože slnečné svetlo musí prechádzať väčšou časťou atmosféry bližšie k zemskému povrchu, kde je hustejšie. Tým sa odstráni významná časť svetla s kratšou vlnovou dĺžkou (modrá) a svetlom so strednou vlnovou dĺžkou (zelená) z priamej cesty k pozorovateľovi. Zostávajúce nerozptýlené svetlo má preto väčšinou dlhšie vlnové dĺžky a javí sa viac červené (Obr. 2.7).



Obr. 2.6 Modrá časť EMŽ sa odráža pod väčším uhlom ako červená časť EMŽ. **Fig. 2.6** The blue part of electromagnetic radiation is reflected at a greater angle than the red. Source: Tempfli et al., 2009



Obr. 2.7 Rayleigh rozptyl spôsobuje modrú alebo červenú oblohu v závislosti od polohy Slnka. **Fig. 2.7** Rayleigh scattering causes a blue or red sky depending on the position of the Sun. Source: Tempfli et al., 2009

Ak sú v atmosfére molekuly pevných a kvapalných častíc a ich polomer je rovnaký alebo väčší ako dĺžky EMŽ, čiže $r \ge \lambda$, nastáva *Mie rozptyl*. Ten vzniká hlavne na molekulách aerosolov, ako napríklad na molekulách zmesi plynov, vodných častíc a prachu. Tento rozptyl nastáva väčšinov v nižších častiach atmosféry, kde sa tieto častice nachádzajú vo väčšej miere. Mie rozptyl má väčší vplyv na dlhšie vlnové dĺžky ako *Rayleigh* rozptyl.

Neselektívny rozptyl nastáva na časticiach, ktoré sú omnoho väčšie ako vlnové dĺžky EMŽ. Ide hlavne o kvapky vody a veľké prachové častice (príklad oblaky sa javia ako biele mnohotvaré telesá, EMŽ sa odráža v rovnakej miere, preto sa zdajú oblaky biele). Neselektívny rozptyl je nezávislý od vlnových dĺžok v časti viditeľného žiarenia.

2.4. Absorption and transmission

Elektromagnetické spektrum prechádzajúce atmosférou je čiastočne pohlcované rôznymi molekulami – najčastejšie molekulami oxidu uhličitého (CO₂), molekulami vody (H₂O), a ozónom (O₃).



Obr. 2.8 Priepustnosť atmosféry. **Fig. 2.8** Atmospheric transmittance. Source: Itb.itc.utwente.nl/page/498/concept/81484

Obrázok 2.8 zobrazuje schematické znázornenie priepustnosti atmosféry v rozsahu vlnových dĺžok 0 – 22 µm. Z obrázku je zrejmé, že mnohé z vlnových dĺžok nie sú využiteľné pre DPZ, nakoľko niektoré vlnové dĺžky nemôžu preniknúť do atmosféry. Pre DPZ možno použiť iba vlnové dĺžky mimo hlavného absorpčného rozsahu atmosférických plynov. Užitočné rozsahy sa označujú ako *atmosférické okná*:

- Optické okno od 0,4 do 2 µm (Obr. 2.1). Žiarenie v tomto rozsahu (viditeľné, NIR, SWIR) je hlavne odrazené žiarenie. Pretože tento typ žiarenia sa riadi zákonmi optiky, diaľkové senzory pracujúce v tomto rozsahu sa často označujú ako optické senzory.
- Dve okná v rozsahu TIR a rádiového žiarenia (Obr. 2.1), konkrétne dve úzke okienka okolo 3 a 5 μm a tretie, relatívne široké okno siahajúce od približne 8 μm do 14 μm – tzv. rádiové okno.

V dôsledku prítomnosti atmosférickej vlhkosti dochádza k silnej absorbcii pri dlhších vlnových dĺžkach. Takmer k žiadnemu prenosu EM žiarenia nedochádza v rozsahu od 22 µm do 1 mm. Slnečné žiarenie pozorované s vplyvom a aj bez vplyvu zemskej atmosféry je znázornené na Obr. 2.9. Slnečné žiarenie merané mimo atmosféry sa podobá žiareniu čierneho telesa pri 6000 K. Meranie slnečného žiarenia na zemskom povrchu ukazuje, že spektrálne rozloženie slnečného žiarenia je veľmi nerovnomerné. Relatívne poklesy v tejto krivke naznačujú absorpciu rôznymi plynmi v atmosfére. Z obrázku 2 je tiež zrejmé, že celková intenzita v tomto rozsahu (t. j. plocha pod krivkou) sa znížila v čase, keď slnečná energia dosiahla zemský povrch po prechode atmosférou.



Obr. 2.9 Krivky vyžarovania Slnka a čierneho telesa pri teplote Slnka. **Fig. 2.9** Radiation curves of the Sun and a black body at the temperature of the Sun. Source: ltb.itc.utwente.nl/page/498/concept/81484

2.5. Interaction with the earth's surface

Pri dopade EMŽ na topografický povrch nastávajú tri javy – odraz (reflection), pohltenie (absorbtion) a prienik (transmission). Aplikovaním zákona o zachovaní energie sa stanovuje vzťah medzi týmito intrakciami nasledovne:

$$E_I(\lambda) = E_R(\lambda) + E_A(\lambda) + E_T(\lambda), \qquad (2.7)$$

xkde $E_l(\lambda)$ je energia dopadajúceho žiarenia, $E_R(\lambda)$ je energia odrazeného žiarenia, $E_A(\lambda)$ je energia absorbovaného žiarenia a $E_T(\lambda)$ energia prechádzajúceho žiarenia. Pomer odrazeného, absorbovaného a prechádzajúceho žiarenia sa mení v závislosti od typu povrchu Zeme, tj. materiálov na Zemskom povrchu a ich fyzikálnom stave. Rovnako aj v závislosti od vlnovej dĺžky sa mení pomer odrazeného, absorbovaného a prechádzajúceho žiarenia. To znamená, že odrazená energia sa rovná energii dopadajúcej na daný povrch znížená o energiu, ktorá je buď absorbovaná alebo prenášaná týmto povrchom:

$$E_R(\lambda) = E_I(\lambda) - (E_A(\lambda) + E_T(\lambda))$$
(2.8)

Charakteristiky odrazivosti prvkov zemského povrchu možno kvantifikovať pomocou merania časti dopadajúcej energie, ktorá sa odráža. Toto sa meria funkciou vlnovej dĺžky a nazýva sa spektrálna odrazivosť p_{λ} (vyjadrená v %), ktorá je matematicky definovaná ako:

$$\rho_{\lambda} = \frac{E_R(\lambda)}{E_I(\lambda)} * 100 , \qquad (2.9)$$

pričom v čitateli je uvedená energia odrazeného žiarenia, v menovateli je energia dopadajúceho žiarenia. Grafické znázornenie spektrálnej odrazivosti sa nazýva krivka spektrálnej odrazivosti, ktorá poukazuje na spektrálne charakteristiky objektu v závislosti od vlnovej dĺžky. Odrazivosť materiálov sa v rôznych vlnových dĺžkach mení a citlivo znázorňuje rozdiely aj v podobných typoch povrchoch (Obr. 2.10).



Fig. 2.10 Spectral reflectance curves of selected materials. Source: ©USGS

Rozlíšenie rôznych vlastností povrchov je možné vďaka ich spektrálnym krivkám odrazivosti. Napríklad pre vegetáciu a vodu, ako je môžné vidieť na Obr. 2.10, je obrovský rozdiel medzi červeným a blízkym infračerveným (NIR) pásmom. Vegetácia má nízku odrazivosť vo viditeľných vlnových dĺžkach, ale určitá odrazivosť je v zelenej vlnovej dĺžke a potom silná odrazivosť vegetácie je v NIR pásme. Zatiaľ čo voda vykazuje nízku odrazivosť vo viditeľnom pásme EMŽ, ale nemá zas žiadnu odrazivosť v NIR pásme. Tieto krivky ukazujú, koľko by bolo dopadajúcej energie odrazené od povrchu a následne zaznamenané senzormi DPZ. Pri danej vlnovej dĺžke čím vyššia je odrazivosť, tým sa javí objekt jasnejšie na snímke.



Obr. 2.11 Zmena spektrálnej odrazivosti piatich minerálnych pôd: (a) s prevahou organických pôd, (b) minimálne zmenená, (c) zmenená železom, (d) ovplyvnená organickou pôdou, (e) s prevahou železa.

Fig. 2.11 Change in spectral reflectance of five mineral soils (a) dominated by organic soils, (b) minimally altered, (c) altered by iron, (d) influenced by organic soils, and (e) dominated by iron. Source: ltb.itc.utwente.nl/498/concept/81713

Pôdna krivka na obrázku 2.11 ukazuje podstatne menšie variácie vrcholov a údolií v odraze. To znamená, že faktory, ktoré ovplyvňujú odrazivosť pôdy, pôsobia menej špecifické spektrálne pásma. Niektoré z faktorov ovplyvňujúcich odrazivosť pôdy sú obsah vlhkosti, obsah organickej hmoty, štruktúra pôdy (podiel piesku, bahna a ílu), drsnosť povrchu a prítomnosť oxidov železa. Tieto faktory sú zložité, premenlivé, a vzájomne prepojené. Napríklad znížením prítomnosti vlhkosti v pôde sa zvýši jej odrazivosť. Obsah pôdnej vlhkosti silne súvisí s textúrou pôdy: hrubé, piesčité pôdy sú zvyčajne dobre odvodnené, čo má za následok nízku vlhkosť obsah a relatívne vysokú odrazivosť; zle odvodnené pôdy s jemnou štruktúrou budú mať vo všeobecnosti nižšiu odrazivosť. Odrazové vlastnosti pôdy sú teda konzistentné len v rámci určitých rozsahových podmienok. Dva ďalšie faktory, ktoré znižujú odrazivosť pôdy sú drsnosť povrchu a obsah organickej hmoty. Prítomnosť oxidov železa v pôde tiež výrazne znižuje odrazivosť - aspoň teda vo viditeľných častiach EMŽ.





Fig. 2.12 Typical effects of chlorophyll and sediments on water reflectance: (a) ocean water, (b) turbid water, (c) water with chlorophyll.

Source: ltb.itc.utwente.nl/498/concept/81713

Zakalená (naplavená) voda má najvyššiu odrazivosť. Voda obsahujúca rastliny alebo riasy má výrazný vrchol odrazivosti v zelené svetle práve kvôli prítomnému chlorofylu. Vzhľadom na spektrálnu odrazivosť vody asi najvýraznejšou charakteristikou je absorpcia energie na vlnových dĺžkach blízkych IR a ďalších. Voda absorbuje energiu v týchto vlnových dĺžkach, či už vo vodných prvkoch (ako sú jazerá a potoky) alebo vo vode obsahujúcej vegetácie alebo pôdy. Vo viditeľných vlnových dĺžkach sa prejavujú rôzne stavy vodných plôch.

References

Books

Emery, W., & Camps, A. (2017). Basic Electromagnetic Concepts and Applications to Optical Sensors. Introduction to Satellite Remote Sensing, p.43–83. DOI: 10.1016/B978-0-12-809254-5.00002-6

Tempfli, K., Kerle, N., Huurneman, G. C., & Janssen, L. L. F. (Eds.). (2009). Principles of Remote Sensing: An introductory textbook (4th ed., pp. 1–591). The International Institute for Geo-Information Science and Earth Observation (ITC). ISBN 978–90–6164–270–1

Web sources

Itb.itc.utwente.nl gfycat.com/inconsequentialmeanbackswimmer USGS http://hyperphysics.phy-astr.gsu.edu/hbase/wien.html science.nasa.gov/ems/01_intro

Optical Remote Sensing

Optical RS uses visible, near-infrared, and shortwave infrared sensors to produce images of the Earth's surface by detecting solar radiation reflected from targets on the ground. Different materials reflect and absorb different wavelengths. Therefore, targets can be distinguished by their spectral reflectance features in remote sensing images. Depending on the number of spectral bands used in the imaging process, optical remote sensing systems are divided into basic types - panchromatic images, multispectral images, hyperspectral images.

This chapter is devoted to the introduction to optical remote sensing, describes the basic characteristics of panchromatic and multispectral images, types and distribution of optical sensors and their basic characteristics - spatial, spectral, radiometric and temporal resolution.

The panchromatic band (black and white) is a band that typically contains a bandwidth of a few hundred nanometres. Such an image can be acquired with a higher resolution because the spectral range allows the use of smaller detectors while maintaining a high signal-to-noise ratio. This capability allows smaller parts to be seen and still obtain strong signals. In optical remote sensing, the panchromatic image is a digital recording; one separate wavelength range is switched on, overlapping in the visible part of the spectrum by the amount of EM radiation measured in the pixel.

In the case of a multispectral image, the digital recording of the EM radiation received by each pixel is made over several wavelength ranges, often disjoint and narrower compared to the panchromatic mode. Thus, a multispectral image consists of several channels or bands, each containing a quantity of measured radiation in very specific wavelength ranges for each pixel (e.g., green, red, or near-infrared bands). A multispectral image is like a matrix, where it consists of multiple bands stacked and overlaid on top of each other.



3.1. Introduction

Digitálna optická snímka je pravidelne usporiadaná štruktúra pixelov – elementov snímky do matice pravidelných "j" radov a "i" stĺpcov (Obr. 3.1). Každý pixel obsahuje číslo - hodnotu (digitálne číslo alebo rádiometrickú hodnotu), čo je stredná hodnota "energie" vrátenej prvkami z povrchu zeme pokrytými týmto pixelom.



 \rightarrow *i* (stĺpce, pixely)

Obr. 3.1 Rastrová štruktúra digitálnej snímky. **Fig. 3.1** Raster structure of a digital image. Source: after Pavelka, 2009

3.2. Panchromatic Image

Panchromatické pásmo (čiernobiele) je pásmo, ktoré zvyčajne obsahuje šírku pásma niekoľko stoviek nanometrov. Takúto snímku je možné získať s vyšším rozlíšením, pretože spektrálny rozsah umožňuje použitie menších detektorov pri zachovaní vysokého pomeru signál-šum. Táto schopnosť umožňuje vidieť menšie časti a stále získavať silné signály.

Panchromatický obraz sa vytvorí vtedy, keď sa zobrazovací snímač stane citlivým na veľké množstvo vlnových dĺžok svetla, ktoré sa bežne rozprestiera na viditeľnej časti veľkého spektra. Výsledná snímka sa javí ako "čiernobiela" fotografia. Meranou fyzikálnou veličinou je zdanlivý jas cieľa, a preto sa "farba" cieľov alebo spektrálna informácia stratí.

Produkciu panchromatických snímok vykonávajú satelity, napríklad SPOT6/7 a satelity Landsat. Pásmo tejto snímky "zmieša" informácie o viditeľných modrých, zelených a červených pámach, kde sa vytvorí pomocou celkovej energie osvetlenia viditeľného spektra namiesto toho, aby sa rozdelil do iného spektra. Sústreďuje množstvo intenzity na pixel, ktoré sa potom vizualizuje na obrázku v odtieňoch šedej (Obr. 3.2). Informácie v každom pixeli sú teda priamo spojené s intenzitou slnečného žiarenia odrazeného objektmi, ktoré sú v tomto pixeli a senzor je ním detegovaný.

Panchromatické údaje sú zvyčajne reprezentované rozsahom vlnových dĺžok a pásiem, napríklad termálne infračervené alebo viditeľné, preto sa nazývajú "pan" chromatické. Tento obrázok je skôr kombináciou modrých, zelených a červených údajov

v miere odrazivosti. Niektoré však môžu zahŕňať aj žiarenie s dlhšou vlnovou dĺžkou ako červené svetlo, nazývané "blízke infračervené" žiarenie. Pri optickom diaľkovom snímaní je panchromatická snímka digitálnym záznamom, zapnutý je jeden samostatný rozsah vlnových dĺžok prekrývajúcich sa vo viditeľnej časti spektra množstvom EMŽ nameraného v pixeli. Panchromatický obraz je teda "jednokanálový" obraz.



Obr. 3.2 Snímka SPOT HRG, panchromatické zobrazenie. Dynamický rozsah snímky je roztiahnutý na hodnoty od 0 do 255. Hodnota pixelu zodpovedá percentu úrovne šedej medzi čiernou (0) a bielou (255).

Fig. 3.2 SPOT HRG image, panchromatic display. The dynamic range of the image is stretched to values from 0 to 255. The pixel value corresponds to the percentage of grey level between black (0) and white (255).

Source: Baghdadi & Mehrez Zribi, 2016

3.3. Multispectral Image

V prípade multispektrálneho obrazu digitálny záznam EMŽ, ktoré každý pixel prijíma, sa vykonáva cez niekoľko rozsahov vlnových dĺžok, často nesúvislých a užších v porovnaní s panchromatickým režimom. Multispektrálny obraz sa teda skladá z niekoľkých kanálov alebo pásem, z ktorých každý obsahuje množstvo meraného žiarenia vo veľmi špecifických rozsahoch vlnových dĺžok pre každý pixel (napríklad zelená,

červená alebo blízkeho infračerveného pásma). Multispektrálna snímka je ako matica, ktorá sa skladá z viacerých pásem navzájom poskladaných a prekrytých (Obr. 3.3). V prípade digitálneho multispektrálneho obrazu každý pixel obsahuje viacero digitálnych hodnôt intenzity (DN digital numbers) každé spektrálne pásmo. Pri prezeraní tohto viacpásmového obrazu je možné zobraziť iba jedno pásmo a zaobchádzať s ním ako s oddelenou snímkou s úmernými hodnotami jasu.



Obr. 3.3 Vrstvenie jednotlivých spektrálnych pásiem v multispektrálnej snímke. **Fig. 3.3** Layering of individual spectral bands in a multispectral image. Source: Baghdadi & Mehrez Zribi, 2016

V prípade troch pásem zo snímky je možné vybrať a zobraziť súčasne v odtieňoch červenej, zelenej a modrej na vytvorenie farebnej kompozitnej snímky. Ak boli pôvodne zobrazené tri pásma detekované senzorom v rozsahu červenej, zelenej a modrej vlnovej dĺžky - viditeľné spektrum, potom sa tento kompozit bude označovať ako skutočný farebný obraz, pretože sa bude približovať prirodzenej kombinácii farieb, ktorá by bola viditeľná ľudským okom. Akákoľvek iná kombinácia pásiem sa označuje ako snímka vo falošných farbách - napr. kombinácia falošných farieb spektrálnych pásov zahŕňa zobrazenie blízkeho IR, červeného a zeleného pásma (Obr. 3.4).

Hodnoty pixelov na snímke nadobúdajú veľkosti od 0 do 255, čo zodpovedá kódovaniu každej hodnoty pixelu jedným bytom. Počas procesu snímania obrazu, fotografické senzory, ktoré merajú informácie uložené neskôr v každom pixeli najskôr obnovia analógový signál, ktorý je potrebné previesť na číselné hodnoty. Počas tejto analógovo-digitálnej konverzie dochádza k diskretizácii informácií v rozsahu čísel hodnoty definované pri návrhu snímača.



Obr. 3.4 Vytvorenie farebného kompozitu snímok v prirodzených farbách a falošných IR farbách. **Fig. 3.4** Construction of a color composite of images in natural colors and false IR colors. Source: Baghdadi & Mehrez Zribi, 2016

Pri vytváraní produktov odvodených z počiatočných snímok (napr. tvorba masiek, výpočet indexov atď.) je otázka kódovania dôležitá, pretože existuje riziko priradenia vypočítanej hodnoty pixelov na nevhodné typy počítačových premenných. Napríklad, výpočet vegetačných indexov NDVI vytvára reálne čísla v rozsahu od –1 do 1. V súčasnosti majú používatelia k dispozícii snímky s vysokým priestorovým rozlíšením, takže snímkové súbory nadobúdajú veľkosť približne 1 gigabajt. Čím väčší je počet bajtov alebo bitov pre kódovanie hodnôt pixelov, tým väčší bude súbor snímky na pevnom disku: veľkosti v bajtoch, mimo hlavičky sú dané (pre nekomprimovanú snímku):

$$L * P * C * T$$
, (3.1)

kde L predstavuje počet riadkov v snímke; P počet stĺpcov v snímke; C počet spektrálnych kanálov snímky; a T počet bajtov na kódovanie.

3.4. Combinations of spatial and spectral resolution: pansharpening

Priestorové a spektrálne rozlíšenia sú úzko prepojené; lepšie priestorové rozlíšenie automaticky vedie k horšiemu spektrálnemu rozlíšeniu a naopak. Pri zohľadnení minimálneho množstva elektromagnetickej energie potrebnej na to, aby senzor fungoval, kde detektor je citlivý iba na jednu vlnovú dĺžku (jemné spektrálne rozlíšenie), bude musieť byť väčšie priestorové rozlíšenie - ako u detektora citlivého na širší rozsah vlnových dĺžok (súčet energie celej vlnovej dĺžky rozsahu). Pri spracovaní by sme ale radi využili možnosť práce so snímkami kombinujúcimi veľmi vysoké priestorové rozlíšenie panchromatického kanála s mnohými pásmami multispektrálneho obrazu. Preto boli vyvinuté techniky fúzie snímkových dát. Proces fúzie zahŕňa priestorové informácie z panchromatického pásma v rámci rôznych spektrálnych pásiem multispektrálnej snímky; hovoríme tu o "pan-sharpening" (refine, vylepšenie, Obr. 3.5). Na to sú vyvinuté viaceré techniky (Broveyho transformácia; transformácia ostrenia panvy Esri; metóda

Gram-Schmidtovho spektrálneho ostrenia; transformácia intenzity, odtieňa, sýtosti (IHS); a jednoduchá stredná transformácia). Napr. Broveyho transformácia je založená na spektrálnom modelovaní a bola vyvinutá na zvýšenie vizuálneho kontrastu v hornej a dolnej časti histogramu údajov. Používa metódu, ktorá vynásobí každý prevzorkovaný, multispektrálny pixel pomerom zodpovedajúcej intenzity panchromatického pixelu k súčtu všetkých multispektrálnych intenzít. Predpokladá sa, že spektrálny rozsah pokrytý panchromatickým obrazom je rovnaký ako rozsah pokrytý multispektrálnymi kanálmi.

V Broveyho transformácii všeobecná rovnica používa červené, zelené a modré (RGB) a panchromatické pásma ako vstupy na výstup nových červených, zelených a modrých pásiem, napríklad: používa pre výpočet vzťah zlúčených kanálov:

$$Spájanie_k = \frac{Multi_k}{Multi_{sum}} \times Pan$$
, (3.2)

kde *Multi_k* je spektrálny index pásma; a *Multi_{sum}* je suma červeného, modrého a zeleného pásma, ktoré musia byť prevzorkované na veľkosť pixla panchromatického pásma.

Každá z týchto metód využíva rôzne modely na zlepšenie priestorového rozlíšenia pri zachovaní farby a niektoré sú upravené tak, aby zahŕňali váhy, aby bolo možné zahrnúť aj štvrté pásmo (ako napríklad blízke infračervené pásmo dostupné v mnohých zdrojoch multispektrálneho obrazu). Pridaním váh a povolením infračervenej zložky sa zlepší vizuálna kvalita vo výstupných farbách.





Fig. 3.5 Example of pansharpening: left image in RGB with 2.5 m resolution, center image in panchromatic with 0.6 m spatial resolution. Right image after pan-shaping, in color and with 0.6 m spatial resolution.

Source: pro.arcgis.com/en/pro-app/latest/help/analysis/raster-functions/fundamentals-of-pan-sharpening-pro.htm

3.5. Sensors in Remote Sensing

Senzory, resp. snímacie zariadenia v DPZ zachytávajú EM energiu odrazenú zo zemského povrchu – vlastné žiarenie zemského telesa, alebo odrazené slnečné žiarenie, resp. vysielače emitujú vlastné žiarenie a odrazené ho prijímajú do snímacieho zariadenia (Obr. 3.6). Zariadenia snímajúce odrazené slnečné žiarenie sú závislé od slnečnej energie. Sú heliosynchrónne, pričom dráha týchto senzorov je prispôsobená tak, aby snímala iba osvetlenú časť planéty. Zariadenia snímajúce vlastné žiarenie zemského telesa nie sú závislé od slnečného žiarenia.

Časť senzorov v DPZ pracuje ale nezávisle od slnečného a terestrického žiarenia, pričom emitujú vlastné žiarenie o stanovenej vlnovej dĺžke, ktoré je následne odrazené a zachytené senzorom na tom istom nosiči. Takého zariadenia sa nazývajú aktívne senzory. Na rozdiel od pasívnych senzorov sú aktívne senzory nezávislé na dennej a nočnej hodine.



Obr. 3.6 Pasívne a aktívne senzory DPZ. **Fig. 3.6** Passive and active sensors in remote sensing. Source: Pettorelli et al., 2018

Niektoré senzory zachytávajú zmeny intenzity odrazu, alebo zmenu fázy EM žiarenia, niektoré merajú čas medzi emitovaným signálom a časom prijatého signálu. Radarové senzory merajú aj intezitu, aj fázu.

Atmosféra ovplyvňuje "jas" alebo vyžarovanie zaznamenané cez akýkoľvek daný bod na zemi dvoma takmer protichodnými spôsobmi. Po prvé, tlmí (znižuje) energiu osvetľujúcu pozemný objekt (a odrážajúcu sa od objektu). Po druhé, atmosféra pôsobí ako samotný reflektor a dodáva rozptýlené, cudzie žiarenie k signálu detekovanému snímačom. Vyjadrením týchto dvoch atmosférických efektov matematicky, celkové žiarenie zaznamenané snímačom môže súvisieť s odrazivosťou objektu na Zemi a prichádzajúceho žiarenia alebo ožiarenia pomocou rovnice:

$$L_{tot} = \frac{\rho ET}{\pi} + L_P , \qquad (3.3)$$

kde L_{tot} je celkové zachytené žiarenie senzorom; ρ je odrazivosť objektu; E je ožiarenie objektu prichádzajúcou energiou; T prenikanie energiu atmosférou; a L_p je žiarenie prichádzajúce z atmosféry, rozptýlené žiarenienie z objektu.

Zariadenia zaznamenávajúce odrazené slnečné žiarenie, resp. terestrické žiarenie sa nazývajú pasívne senzory. Jedná sa väčšinou o multispektrálne alebo hyperspektrálne senzory (Obr. 3.7) pracujúce v časti viditeľného a infračerveného pásma EMŽ.



Obr. 3.7 Spektrum EMŽ používané pri diaľkovom prieskume Zeme. **Fig. 3.7** The spectrum of electromagnetic radiation used in remote sensing. Source: Pettorelli et al., 2018

Senzory aktívne, pracujúce v oblasti mikrovlnného a rádiového žiarenia sú hlavne radarové družice a GNSS družice.

3.5.1. Types of sensors

V diaľkovom prieskume Zeme sa využíva množstvo záznamových zariadení. Rozdeľujú sa na základe toho, akú úlohu v DPZ plnia – na zobrazujúce a nezobrazujúce, na základe geometrických vlastností a spektrálnych vlastností: altimetre, spektrometre, a rádiometre (Obr. 3.8):

Altimetre sú laserové a radarové altimetre, ktoré sú nezobrazujúce, získavajúce informáciu o prevýšení vodného a topografického povrchu.

Rádiometre sú zariadenia zaznamenávajúce žiarenie v časti vybraných spektrálnych pásem s vysokým rádiometrickým rozlíšením, resp. panchromatické kamery a pasívne mikrovlnné senzory. Ich priestorové rozlíšenie závisí od vlnovej dĺžky pásma senzora.

Panchromatické rádiometre majú veľmi vysoké priestorové rozlíšenie, mikrovlnné rádioetre majú nízke priestorové rozlíšenie.

Spektrometre zaznamenávajú žiarenie v mnohých smeroch, kontinuálne spektrálne pásma s vysokým spektrálnym rozlíšením. Hlavnou úlohou spektrometrov je identifikovať povrchové materiály – minerálne kompozície pôdy, koncentráciu povrchovej vody a chlorofilu a pod.

Kamery – analogové a digitálne – sa využívajú hlavne na topografické mapovanie, katastrálne mapovanie, tvorbu ortofotosnímok väčších územných celkov, líniových stavieb v úzmenom plánovaní a pod.

Multispketrálne skenery – najčastejšie využívané senzory na družiciach a leteckých zariadeniach.

Hyperspektrálne senzory zaznamenávajú obraz v desiatkách až stovkách úzkych spektrálnych pásem.

Termálne skennery sú častokrát ako súčasť multispektrálnych kamier, zaznamenávajú žiarenie v časti IR žiarenia.

MikrovInné rádiometre detekujú EMŽ vo vlnových dĺžkach 10 až 1000 mm. Ich hlavné využitie je pri monitorovaní zmien vlhkosti pôdy, snehu, ľadu a pod.

Laserové skenery LiDAR Light Detection and Ranging sú hlavne letecké skenery s vysokým rozlíšením, zaznamenávajúce zemský povrch pri tvorbe DTM (digitálneho modelu terénu)

Radarové senzory Radio Detection and Ranging pracujú v spektrálnych pásmach 10 až 1000mm, sú to aktívne senzory, získavajúce informácie v akejkoľvek dennej dobe nezávisle od počasia. Radarové vlny prechádzajú (penetrujú) oblačnosťou, zoslabené sú len v prípade silných daždových zrážok.

Radarové altimetre sa využívajú na meranie prevýšení profilov zemského povrchu paralelne s dráhou družice. Snímajú v rozsahu 10 až 60mm.

Sonary (SOund NAvigation Ranging) sa využívajú pre mapovanie riečnych korýt, dna morí, detekovanie objektov pod vodou, pričom emitujú zvukové vlny pod plavidlom. Zvuk je odrazený od dna vodného telesa a zanenáva sa čas, ktorý je potrebný na príjem vyslaného pulzu.



Obr. 3.8 Schématické rozdelenie senzorov. **Fig. 3.8** Schematic categorisation of sensors. Source: own processing

3.6. Resolution of sensors

Schopnosť senzorov znázorniť prvky na snímke je rôzna (Obr. 3.9). Závisí od viacerých veličín, akými sú rozlišovacie schopnosti senzora. Rozlíšenie je detail, ktorý je schopný senzor zaznamenať na snímke. Vyššie rozlíšenie znamená viac detailov obrazu. V zásade rozoznávame štyri typy rozlíšení: **priestorové, spektrálne, rádiometrické a temporálne rozíšenie.**



Obr. 3.9 Schématické rozdelenie multispektrálnych satelitov/senzorov na pozorovanie Zeme s vysokým a stredným priestorovým rozlíšením.

Fig. 3.9 Schematic distribution of multispectral satellites/sensors for Earth observation with high and medium spatial resolution.

Source: Kurihara et al., 2018

3.6.1. Spatial resolution

Priestorové rozlíšenie snímača, je ukazovateľom toho, ako podrobne je snímač schopný zaznamenať priestorové detaily. V niektorých prípadoch je to veľkosť vzorky na zemskom povrchu (GSD – Ground Sampling Distance), resp. je to základná plocha reprezentovaná jedným pixelom na digitálnej snímke, ktorá môže zodpovedať priestorovému rozlíšeniu tohto snímača. V ostatných prípadoch vzorka na zemskom povrchu môže mať väčšiu vzdialenosť alebo menšiu ako priestorové rozlíšenie snímača, napríklad v dôsledku procesu Analog-to-Digital konverzie alebo digitálnej manipulácie s obrazom, ako je napríklad prevzorkovanie.

Jednoduchá definícia, ktorá sa používa už mnoho rokov pre určenie rozlíšenia kamery je "počet čiar na milimeter – angl. lines per mm" alebo lp/mm. Dá sa to prirovnať k rozlíšeniu ľudského oka, čo je 10 lp/mm, zatiaľ čo rozlíšenie typickej leteckej fotografie je 40 lp/mm; druhý je ekvivalentný 25 µm lp/mm, čo sa rovná pixelu o veľkosti 9 µm. Vzťah je definovaný ako:

$$\mu m \ln^{-1} = (\text{veľkosť pixelov v mierke obrázka}) / (2\sqrt{2})$$
(3.4)

Veľkosť pixelov nie je rovnaká ako rozlíšenie definované µm lp⁻¹, aj keď rozlíšenie sa často uvádza ako veľkosť pixelov. Veľkosť pixelov súvisí s okamžitou hodnotou zorného poľa (IFOV) pre digitálny snímač. Pixel je bunka v rastrovej snímke. Ground samplig distance (GSD) definovuje rozlíšenie senzora. Topan a kol. (2005) definujú GSD ako: "…vzdialenosť stredov susedných pixelov premietnutých na zemský povrch. Veľkosť pixelov na zemi je fyzická veľkosť premietaných pixelov." Poznamenávajú tiež, že "pixely môžu byť nadmerne vzorkované (projektované pixely sa prekrývajú) alebo podvzorkované (medzi susednými pixelmi je medzera). Veľkosť pixelu v smere stopy je definovaná intervalom vzorkovania.



Obr. 3.10 Vzťah zorného poľa a veľkosti pixla. **Fig. 3.10** Relationship between field of view and pixel size. Source: Dowman et al., 2012

Ako príklad sa dá uviesť družica SPOT-5, ktorá generuje snímky s 2,5 m GSD v superrežime, ale susedné pixely sa prekrývajú o 50 %, takže veľkosť pixelov na zemskom povrchu je 5m. GSD môže byť definované ako:

$$GSD = ISF * \left(\frac{H}{f}\right), \tag{3.5}$$

kde *ISF* je point spread function, ktorá je závislá na optickom systéme a atmosfére; *H* je výška letu; a *f* je konštanta fotokomory. ISF môže byť definované ako veľkosť pixla v senzore.

Rôzne typy senzorov na palubách družíc majú rôzne priestorové rozlíšenia, ktoré sú prispôsebné tak, aby zodpovedali poslaniu jednotlivých misií, ale častokrát aj s ohľadom na udržanie kontinuity s historickými misiami. V zásade platí, že čím je vyššia rozlišovacia schopnosť senzora, tým je viditeľnosť detailov vyššia (Obr. 3.11).



Obr. 3.11 Vzťah zorného poľa a veľkosti pixla. **Fig. 3.11** Example of different GSDs on the images and the resolution of corresponding details. Source: Kim & Yeom, 2015

Pri satelitnom diaľkovom prieskume Zeme sa rozlíšiteľnosť pohybuje rádovo od niekoľko decimetrov, metrov až desiatky a stovky metrov. Takto koncipované senzory slúžia na získavanie rôznych typov mapovaní, počnúc od vysokodetailných urbanistických štúdií, cez regionálne a globálne, až po kontinentálne mapovania.

Pri takto koncipovaných priestorových rozlíšeniach je potrebné pri spracovaní dát vykonávať prevzorkovanie (resampling) na spoločnú veľkosť pixla. Resampling sa vykonáva zväčša z menšieho rozlíšenia do väčšieho (napr. 60m pixel je prevzorkovaný na 10m pixel). Rozlíšiteľnosť objektov sa tým nezvýši, ale aj takto pripravená snímka má pixely geometricky totožné s druhou snímkou (Obr. 3.12).



Obr. 3.12 Snímka z družice Sentinel 2B, zobrazenie v pásmach B3 (10m), B8a (20m), B9 (60m) a v kompozícii B432 (10m). **Fig. 3.12** Sentinel 2B satellite image – display of bands B3 (10m), B8a (20m), B9 (60m); and B432 (10m) composite. Source: own processing

Tab. 3.1 Porovnanie satelitných misií s veľosťou pix ≤ 1m v PAN a pix ≥ 1m v MS režime.
Tab. 3.1 Comparison of satellite missions with pix size ≤ 1m in PAN and pix ≥ 1m in MS mode.
Source: own processing

Satelit	Agentúra Krajina Rok štartu	Výška letu (km)	GSD PAN/MS (m)	Šírka záberu v nadire (km)	Typ senzora	Rádiometrické rozlíšenie (bity)
IKONOS - 2	GeoEye Inc. USA, 1999	681	0,82/3,28	11,3	PAN/MS	11
QuickBird	DigitalClobe USA, 2001	450	0,61/2,44	16,5	PAN/MS	11
OrbView - 3	GeoEye Inc. USA, 2003	470	1/4	8	PAN/MS	11
EROS B	ImageSat Int. Izrael, 2006	508	0,7	7	PAN	10
KOMPSAT - 2	Kari Južná Korea, 2006	685	1/4	15	PAN/MS	10
Geoton-L1 Resurs-DK 1	Roscosmos Rusko, 2006	330-585 Eliptická dráha	1/3 na 350km	30	PAN/MS	10
WorldView - 1	DigitalClobe USA, 2007	494	0.45	17,6	PAN	11
WorldView - 2	DigitalGlobe USA, 2009	770	0,46/1,84	16,4	PAN/MS	11
GeoEye - 1	GeoEye Inc. USA, 2008	681	0,41/1,65	15,2	PAN/MS	11
Cartosat - 2	ISRO India, 2007 - 2010	631	0,82	9,6	PAN	10

Snímky v DPZ rozdeľujeme z hľadiska priestorového rozlíšenia do 4 skupín:

- <u>s nízkym priestorovým rozlíšením</u>, pix ≥ 30 m and < 300 m, ktoré sa využívajú hlavne na globálne a kontinentálne mapovanie, sledovanie ľadovcov, fytoplanktónu, globálnych teplôt zemského povrchu, plynov v atmosfére a pod.,
- so stredným priestorovým rozlíšením, pix ≥ 5 m and < 30 m, tieto snímky sa využívajú hlavne na globálne a kontinentálne mapovanie, sledovanie stavu a vývoja vegetácie, modelovanie vývoja poľnohospodárskych plodín a predpovedanie výnosov, monitorovanie rozsiahlych prírodných katastrof, sledovanie stavu a vývoja snehu a ľadovcov, sledovanie stavu a vývoja atmosféry a oceánov,
- 3. <u>s vysokým priestorovým rozlíšením</u>, pix ≥ 1.0 m and < 5 m, kde je veľkosť obrazového elementu pix ≤ 1-5 m. Tieto dáta sa využívajú hlavne na regionálne
mapovanie a plánovanie, mapovanie stavu, vývoja a zmeny v krajine, monitorovanie rozvoja miest, sledovanie stavu a vývoja vegetácie, mapovanie poľnohospodárskych plôch a klasifikácie plodín, sledovanie stavu lesných porastov a klasifikáce lesných ekosystémov, sledovanie lesnej ťažby, geologické mapovanie, geomorfologické mapovanie, mapovanie prírodných katastrof, DMT,

4. <u>s veľmi vysokým priestorovým rozlíšením</u>, pix < 1.0 m kde je veľkosť obrazového elementu pix ≤ 1 m. Tieto dáta sa využívajú na podrobné mapovanie, urbanistické študie, 3D modely miest, precízne poľnohospodárstvo, kontrola poľnohospodárskych aktivít, plánovanie a projektovanie líniových stavieb, mapovanie dopravných sietí, inventarizácia lesov, mapovanie rozptýlenej vegetácie, monitorovanie povrchových baní, skládok a rekultivácie, mapovanie erózie, plánovanie a organizácia humanitárnej pomoci, poisťovníctvo, DMT.</p>

3.6.2. Spectral resolution

Spektrálne rozlíšenie je schopnosť zaznamenať žiarenie v určitých spektrálnych pásmach. To je dané počtom, rozsahom a umiestnením spektrálnych regiónov senzora v rámci celej škály EMŽ, v ktorých dokáže zaznamenávať údaje. Senzory majú častokrát rôzne priestorové rozlíšenia v rôznych spektrálnych pásmach. Napríklad multispektrálna družica Sentinel 2 snímkuje v 13 spektrálnych pásmach, pričom má tri rôzne priestorové rozlíšenia (Tab. 3.2): 10 m, 20 m a 60 m. V pásmach V pásmach B2, B3, B4 a B8 je veľkosť pixla 10 x 10 m, v pásmach B5, B6, B7, B8a, B11 a B12 má senzor rozlíšenie 20 x 20 m a v pámach B1, B9 a B10 je priestorové rozlíšenie 60 m.

Spoktrálno pásmo	Vlnová dĺži	ka (mm)	Priestorové rozlíšenie (m)	
Spektraine pasmo	Landsat 8	Sentinel 2	Landsat 8	Sentinel 2
Band Coastal aerosol	433-453	443	30 m	60 m
Band Blue	450-510	492	30 m	10 m
Band Green	530-590	560	30 m	10 m
Band Red	640-670	665	30 m	10 m
Band Vegetation red edge	-	704	-	20 m
Band Vegetation red edge	-	740	-	20 m
Band Vegetation red edge	-	783	-	20 m
Band NIR	850-880	833	30 m	10 m
Band Vegetation red edge	-	865	-	20 m
Band 9 Water vapour	-	945	-	60 m
Band SWIR - Cirrus	1360-1380	1373	15 m	60 m
Band SWIR	1570-1650	1614	30 m	20 m
Band SWIR	2110-2290	2202	30 m	20 m
Band Panchromatic	500-680	_	15 m	-

Tab. 3.2 Spektrálne a priestorové rozlíšenie senzorov družíc Landsat 8 a Sentinel 2. **Tab. 3.2** Spectral and spatial resolution of Landsat 8 and Sentinel 2 sensors. Source: own processing Satelitné snímky rozdeľujeme z hľadiska spekrrálneho rozlíšenia na štyri základné skupiny:

- panchromatické dáta (kap. 3.2),
- multispektrálne dáta (kap. 3.3),
- hyperspektálne dáta,
- radarové dáta.

Hyperspektrálny diaľkový prieskum je známy aj ako zobrazujúca spektroskopia, ktorá dokáže zobraziť jemné spektrálne detaily na snímke. Využíva sa na detekciu, identifikáciu a mapovanie minerálov na zemskom povrchu, vo vode a v atmosfére v pevnom, kvapalnom alebo plynnom skupenstve. Ide o pokročilý nástroj v oblastia geológie, geomorfológie, pedológie, hydrológie, vegetácie a celých ekosystémov. V satelitnom diaľkovom prieskume Zeme v rokoch 2000 - 2017 snímkoval senzor Hyperion nesený na družici Earth Observing-1 (EO-1), ktorý disponoval 242 spektálnymi pásmami v rozsahu EMŽ 400-2577 nm s priestorovým rozlíšením 30 m (Obr. 3.13). 70 pásem bolo v rozsahu NIR a 171 pásem v rozsahu SWIR s rádiometrickým rozlíšením 12 bitov a temporálnym rozlíšením 16 dní. Stopa záznamu mala na zemskom povrchu šírku 7,5 km.



Obr. 3.13 Porovnanie počtu spektálnych pásiem MS družíc a hyperspektálneho senzora Hyperion na družici EO-1.

Fig. 3.13 Comparison of the number of spectral bands of MS satellites and the Hyperion hyperspectral sensor on the EO-1 satellite.

Source: www.usna.edu/Users/oceano/pguth/md_help/html/hyperion.htm

Medzi hlavné rozdiely medzi hyperspektrálnym a multispektrálnym zobrazovaním patria dva aspekty:

 hyperspektrálny snímač môže získať obrazové údaje v niekoľkých desiatkach až stovkách úzkych spektrálnych pásmach a súvislé spektrálne pásma pokrývajúce určité spektrálne rozsahy, zatiaľ čo multispektrálny senzor meria obrazové údaje v niekoľkých širokých a diskrétnych spektrálnych pásmach v rámci určitých spektrálnych rozsahov. čo je dôležitejšie, údaje hyperspektrálneho senzora možno použiť na extrakciu diagnostického spektra vlastnosti objektov, ktoré predstavujú jedinečné absorbčné pásy v 20 – 40 nm, pre väčšinu prírodných materiálov nie sú možné pre technológiu multispektrálneho zobrazovania.





Fig. 3.14 Hyperspectral image cube. AVIRIS images were acquired from Moffett Field, San Francisco Bay, California, on June 20, 1997, and the surface composite image of the cube in false colors was composited with the typical NIR/red/green vs. R/G/B. Source: Pu, 2017

Ako príklad rozdielneho využitia MS a HS snímok možno použiť mapovanie vegetačného pokrytu. Kým multispektrálne snímky možno použiť na mapovanie zalesnených oblastí, hyperspektrálne snímky sa dajú využiť na mapovanie drevín a iných biofyzikálnych parametrov v rámci lesa.



Obr. 3.15 Multispektrálna snímka Košíc a okolia z družice Sentinel 2 z júla 2021 v RGB kompozícii. **Fig. 3.15** Multispectral image of Košice city and surroundings from Sentinel 2 satellite in July 2021 in RGB composition.

Source: ©Contains modified Copernicus Sentinel data [2021] processed by Sentinel Hub



Obr. 3.16 Radarová snímka Košíc a okolia z družice Sentinel 1 v júli 2021 vo VV polarizácii s vykonanou rádiometrickou terénnou korekciou. **Fig. 3.16** Radar image of Košice city and surroundings from Sentinel 1 satellite in July 2021 in VV polarization with radiometric terrain correction.

, Source: ©Contains modified Copernicus Sentinel data [2021] processed by Sentinel Hub

Radarové dáta sú získavané mikrovlnným zobrazovacím systémom, nezávislým od osvetlenia zameského povrchu slnečným žiarením, nakoľko sú tieto systémy aktívne, emitujúce vlastné mikrovlnné žiarenie. V závislosti od použitej emitovanej vlnovej dĺžky žiarenia (v pásmach C, L, resp. X) prechádza (penetruje) toto žiadenie objektami na zemskom povrchu. Snímka je tvorená puixlami nesúcimi informáciu o amplitúde a fáze odrazeného žiarenia smerom k senzoru. Bližie informácie k radarovému diaľkovému prieskumu sú v Kapitole 6 a 7.

3.6.3. Radiometric resolution

Rádiometrické rozlíšenie vyjadruje schopnosť senzora rozlišovať medzi pixlami jemné zmeny jasu. Dynamický rozsah senzora zaznamenáva najsvetlejší a najtmavší pixel, ktorý je možné zaznamenať na snímke. Čím je rádiometrické rozlíšenie jemnejšie, tým väčšia je kvalita a interpretovateľnosť snímky. V 8-bitových dátach sa digitálne hodnoty pohybujú od 0 do 255 pre každý pixel. Rádiometrické rozlíšenie s vyššími hodnotami sa využíva pri detekcii zmien, štúdiách globálnych zmien a štúdiách monitorovania Zeme. Tu je rádiometrické rozlíšenie v rozsahu od 8 do 14 bitov, čo súvisí s 256 úrovňami odtieňov šedej a až 16 384 intenzít alebo odtieňov farieb v každom pásme. Rádiometrické rozlíšenie označuje dynamický rozsah alebo celkový počet diskrétnych signálov jednotlivých síl, ktoré môže senzor zaznamenať. Snímač Landsat-7 napr. používa na zaznamenávanie 8-bitových snímok; môže teda merať 256 jedinečných hodnôt šedej odrazenej energie, zatiaľ čo družica Ikonos-2 obsahuje 11-bitové rádiometrické rozlíšenie, čo je 2048 hodnôt šedej. Vyššie rádiometrické rozlíšenie umožňuje súčasné pozorovanie objektov s nízkym a vysokým kontrastom v scéne. Rádiometrické rozlíšenie sa zvyčajne vyjadruje ako počet bitov pre každé pásmo; je vyjadrené na základe počtu bitov alebo binárnych číslic na označenie rozsahu dostupných hodnôt jasu (Obr. 3.17).

(A) 8 bits (256 levels)



(C) 2 bits (4 levels)







Obr. 3.17 Zobrazenie územia na snímke v 1 až 8 bitovom rozlíšení. Fig. 3.17 1 to 8 bit resolution display of the territory in the satellite image. Source: Liang & Wang, 2020

3.6.4. Temporal resolution

Časové rozlíšenie poskytuje informáciu o časovej vzdialenosti medzi získaním dvoch snímok z tej istej oblasti, pričom priamo nesúvisí so snímačom. Zodpovedá frekvencii opätovných návštev na lokalite, a preto závisí od orbitografie platformy alebo satelitu, na ktorom je senzor umiestnený. Čím vyššie je časové rozlíšenie vyššie, tým kratšia je časová vzdialenosť medzi získaním snímok toho istého územia (Obr. 3.18). Mnoho satelitov má stredné časové rozlíšenie, ktoré je približne 14 dní. Najčastejšie sa tento výraz používa v súvislosti so snímačom, ktorý vytvára časový rad viacerých snímok. Môže to byť satelitný systém s definovaným 5- dňovým, 16-dňovým alebo 30-dňovým cyklom opakovania. Družice Sentinel 1 a 2 majú časové rozlíšenie 5 dní, družica Envisat mala časové rozlíšenie 30 dní.



Nominal spatial resolution

Obr. 3.18 Znázornenie oblastí využitia snímok družic s rôznym teporálnym a priestorovým rozlíšením.

Fig. 3.18 Illustration of the application areas of satellite imagery with different teporal and spatial resolutions.

Source: Kasampalis et al., 2018

References

Books

PAVELKA, K.: Fotogrametrie 1. ČVUT, 2009, Praha, 190 s., ISBN 978-80-01-04249-6

Baghdadi, N., & Mehrez Zribi. (2016). Optical remote sensing of land surfaces : techniques and methods (pp. 1– 388). Iste Press Ltd. and Elsevier Ltd. ISBN 978-1-78548-102-4

Dowman, I. J., Jacobsen, K., Konecny, G., & Sandau, R. (2012). High Resolution Optical Satellite Imagery (2nd ed., pp. 1–230). Whittles Publishing. ISBN 978-1849950466

Pu, R. (2017). Hyperspectral remote sensing : fundamentals and practices (1st ed., pp. 1–491). CRC Press Taylor & Francis Group. ISBN 978-1-4987-3159-1

Liang, S., & Wang, J. (2020). Advanced remote sensing : terrestrial information extraction and applications (2nd ed., p. 992). Academic Press, Elsevier inc. ISBN 978-0-12-815826-5

Papers, manuals, reports

Recommended Citation: Pettorelli, N., Schulte toBühne, H., Shapiro, A. C., & Glover-Kapfer, P. (2018). Satellite Remote Sensing for Conservation. WWF Conservation Technology Series 1(4). WWF. DOI: 10.13140/RG.2.2.25962.41926

Kurihara, J., Takahashi, Y., Sakamoto, Y., Kuwahara, T., & Yoshida, K. (2018). HPT: A High Spatial Resolution Multispectral Sensor for Microsatellite Remote Sensing. Sensors, 18(2), 619. DOI: 10.3390/s18020619

Topan, H., Buyuksalih G., Karelmas, Z. and Jacobsen K. (2005). "Information Contents of High Resolution Satellite Images", Proc. Conference: EARSeL Workshop on 3D Remote Sensing – Use of the Third Dimension for Remote Sensing Purposes, Porto, Portugal, 2005, unpaginated CD-ROM

Kasampalis, D., Alexandridis, T., Deva, C., Challinor, A., Moshou, D., & Zalidis, G. (2018). Contribution of Remote Sensing on Crop Models: A Review. Journal of Imaging, 4(4), 52. DOI: 10.3390/jimaging4040052

Kim, H.-O., & Yeom, J.-M. (2015). Sensitivity of vegetation indices to spatial degradation of RapidEye imagery for paddy rice detection: a case study of South Korea. GIScience & Remote Sensing, 52(1), 1–17. DOI: 10.1080/15481603.2014.1001666

Digital Image Analysis

The role of remote sensing is to identify features on the Earth's surface by measuring a portion of the reflected or emitted electromagnetic radiation from the Earth's surface with sensors onboard satellite launchers. The output is usually an image representing the observed scene. This requires many additional digital processing and image modelling steps to extract useful information from the image.

Digital image analysis is the manipulation of digital images with the help of a computer. It is a broad term that aims to extract image information from an image by enhancing its content using various techniques to maximise the final desired image. This can include simple techniques for example, to adjust the contrast and brightness of images from her digital camera or even classifications using neural networks to map mineral types in a hyperspectral image. Digital image analysis improves visibility in digital images, corrects errors, and improves image quality prior to further visual display interpretation or digital analysis. Enhancement, processing and analysis of digital images are extremely broad fields that often involve mathematically complex procedures.

This process involves an immense number of tasks - image pre-processing, image enhancement, image classification, change over time analysis, data fusion and integration into GIS, hyperspectral image analysis, biophysical modelling.

This chapter is devoted to the basic procedures in image data pre-processing and subsequent radiometric image enhancement.

4.1. Introduction

Úlohou diaľkového prieskumu Zeme je identifikovať prvky zemského povrchu meraním časti odrazeného alebo emitovaného elektromagnetického žiarenia zo zemského povrchu senzormi na palube satelitných nosičov. Výstupom je zvyčajne obraz predstavujúci pozorovanú scénu. Na to je potrebných mnoho ďalších krokov digitálneho spracovania a modelovania obrazu ako extrahovať užitočné informácie zo snímky.

Digitálna analýza obrazu je manipulácia s digitálnymi snímkami s pomocou počítača. Ide o veľmi široký pojem, ktorého cieľom získať zo snímky obrazovú informáciu vylepšením jej obsahu rôznymi technikami tak, aby sme maximalizovali výsledné požadované zobrazenie. Môže to zahŕňať jednoduché techniky napr. na úpravu kontrastu a jasu obrázkov z jej digitálnej fotokamery, alebo aj klasifikácie pomocou neurónových sietí na mapovanie typov minerálov na hyperspektrálnej snímke. Digitálne obrazové analýzy pozostávajú z na vylepšenie viditeľnosti na digitálnych snímkach, opravy chýb a všeobecne zlepšenie kvality obrazu pred ďalším vizuálnym zobrazením interpretácie alebo digitálnej analýza. Vylepšenie, spracovanie a analýza digitálnych obrazov predstavujú mimoriadne široké oblasti, ktoré často zahŕňajúcu matematicky zložité postupy.

Tento proces zahŕňa nesmierne množstvo úkonov, ktoré sa dajú kategorizovať do nasledovných operácií:

- Predspracovanie obrazu s cieľom upraviť skreslené resp. degradované obrazové dáta, aby sa vytvorilo vernejšie zobrazenie originálnej scény a zlepšiť užitočnosť snímky pre ďalšie spracovanie. To zvyčajne zahŕňa počiatočné spracovanie nespracovaných obrazových údajov, eliminácie šumu, rádiometrickej kalibrácie, na korekcie geometrických deformácií a na rozšírenie alebo zmenšenie rozsahu obrazu prostredníctvom mozaiky alebo podmnožín. Tieto postupy sú často predbežnéným spracovaním, pretože zvyčajne predchádzajú ďalším manipuláciám a analýze obrazových údajov s cieľom získať špecifické informácie.
- 2. Vylepšenie obrazu Tieto postupy sa aplikujú na obrazové údaje v s cieľom efektívnejšie poskytnúť údaje pre následnú interpretáciu. V mnohých prípadoch vylepšenie obrazu zahŕňa techniky na zvýšenie vizuálnych rozdielov medzi prvkami v scéne, čo v konečnom dôsledku zvyšuje množstvo informácií, ktoré možno z údajov interpretovať. Ide o manipuláciu kontrastu, manipuláciu s priestorovými prvkami (priestorové filtrovanie, konvolúcia, zvýraznenie hrán a Fourierova analýza).
- 3. Klasifikácia snímok s cieľom nahradiť vizuálnu interpretáciu obrazových údajov pomocou kvantitatívnych techník na automatizáciu identifikácie prvkov v scéne. To zvyčajne zahŕňa analýzu viacerých pásiem obrazových údajov (typicky multispektrálne, multitemporálne, polarimetrické alebo iné zdroje doplnkových informácií) a uplatňovanie štatisticky založených rozhodovacích pravidiel na určovanie identity krajinnej pokrývky každého pixelu na obrázku. Tieto rozhodovacie pravidlá sú založené výlučne na spektrálnych informáciách pozorovaných údajov, ale k tomu môžu byť rozhodovacie pravidlá založené aj na geometrických tvaroch, veľkostiach a vzoroch prítomných v obrazových dátach. V každom prípade zámerom procesu klasifikácie je kategorizovať všetky pixely v digitálnej snímke do jednej z niekoľkých tried krajinnej pokrývky alebo "tém".

- 4. Analýza zmien v čase častokrát je potrebné analýzovať dve alebo viacero snímok v rôznych časových bodoch na určenie rozsahu a charakteru zmien v čase, tzv. "detekcie zmien" na identifikáciu konkrétnych oblastí zmien. Môže sa jednať o analýzu časových radov snímok z DPZ, ako je analýza sezónnych cyklov, medziročná variabilita, a dlhodobé trendy v multitemporálnych súboroch údajov.
- 5. Fúzia dát a integrácia GIS tieto postupy sa používajú na kombinovanie obrazových údajov pre danú geografickú oblasť s inými geografickými oblasťami referenčnch súborov údajov pre rovnakú oblasť. Zámerom zlúčenia údajov je častokrát kombinovanie DPZ dá s inými pomocnými zdrojmi informácií. Napríklad obrazové údaje sa často kombinujú s pôdnymi, topografickými, vlastníckymi a pod. informáciami.
- 6. Hyperspektrálna analýza obrazu Všetky hore uvedené obrazové analýzy sa týkajú aj hyperspektrálnych dát. Avšak základná povaha a samotný objem súborov hyperspektrálnych údajov je taká, že boli vyvinuté rôzne postupy spracovania obrazu ako konkrétne analyzovať takéto údaje.
- 7. Biofyzikálne modelovanie Cieľom biofyzikálneho modelovania je kvantitatívne vzťahovať na digitálne údaje zaznamenané pomocou DPZ na biofyzikálne znaky a javy merané na Zemi. Na odhad parametrov možno použiť napríklad údaje z DPZ ako je výnos plodín, koncentrácia znečistenia alebo hĺbka vody.

4.2. Pre-processing

Na výsledný obrazový záznam v DPZ pôsobí množstvo vnútorných a vonkajších vplyvov, ktoré znižujú kvalitu výsledného obrazu. Ide o technické nedokonalosti snímacích zariadení, ale aj chyby v algoritmoch systémových korekcií, vplyv atmosféry a pod.

Takmer v každom prípade existujú určité operácie predbežného spracovania, ktoré sa vykonávajú na nespracovaných údajoch snímky pred jej použitím. Niektoré z týchto operácií sú určené na opravu chýb v údajoch, zatiaľ čo iné robia údaje prístupnejšími na ďalšie spracovanie. Niektoré z týchto operácií môže vykonávať poskytovateľ údajov predtým poskytnutím snímky, v iných prípadoch môžu používatelia potrebovať vykonať jeden alebo viacero samotné krokov predspracovania. Cieľom predspracovania obrazu je úprava geometrických a rádiometrických vlastností objektov. Geometrické korekcie transformujú súradnicovú sústavu obrazového záznamu a rádiometrické korekcie upravujú digitálny hodnoty pixlov napr. s cieľom minimalizovať vplyv atmosféry (atmosférické korekcie).

4.2.1. Noise reduction

Stripping

Stripping (pásy alebo tenká čiara) je anomáliou bežne pozorovanou na snímkach DPZ a iných geopriestorových dátových súborov v rastrových formátoch. Zdroje pruhovania obrazu zahŕňajú pokles čiar počas skenovania, rozdiely medzi dopredu a spätné skenovanie a variácie v kalibráciách naprieč snímačom polia v multisenzorových prístrojoch. Napríklad v Landsat Multispectral Scanner (MSS) a snímky Thematic Mapper (TM) sú spôsobené internými kalibračnými problémami ich snímačov (Obr. 4.1). Obrazový šum je akékoľvek nežiaduce rušenie v obrazových údajoch, ktoré je spôsobené obmedzeniami v procese snímania, digitalizácie signálu alebo zaznamenávania údajov. Zdroje šumu sú od periodického posunu alebo poruchy detektora až po elektronické interferencie medzi komponentmi snímača. Šum môže zhoršiť alebo úplne maskovať rádiometrický informačný obsah digitálneho obrazu.



Obr. 4.1 Snímka z družice Landsat 7 ETM+ s viditeľným striping efektom a opravená snímka. **Fig. 4.1** Landsat 7 ETM+ image with visible striping effect and the corrected image. Source: percyelbis.blogspot.com/2019/05/from-qgis.html

Odstránenie šumu preto zvyčajne predchádza akémukoľvek následnému vylepšeniu alebo klasifikácii zobrazovaných údajov. Povaha korekcie šumu, ktorá je potrebná v danej situácii, závisí od toho, či je šum systematický (periodický), náhodný alebo kombinácia oboch možností. Napríklad multispektrálne senzory, ktoré prechádzajú viacerými skenovacími čiarami súčasne, často vytvárajú údaje obsahujúce systematické pruhovanie. Vyplýva to z variácií odozvy jednotlivých použitých detektorov v rámci každého pásma. Zatiaľ čo viaceré detektory použité pre každé pásmo boli rádiometricky kalibrované pred štartom a spárované, jeden alebo viaceré mali tendenciu sa časom posúvať, čo malo za následok relatívne vyššie alebo nižšie hodnoty pozdĺž každého šiesteho riadku v obrazových údajoch. Na riešenie tohto typu bolo vyvinutých niekoľko destripčných postupov. Jednou z metód je zostaviť súbor histogramov pre snímku – jeden pre každý detektor zapojený v danom pásme. Tieto histogramy sú potom porovnávané z hľadiska ich popisných štatistík (priemer, medián, štandardná odchýlka atď.) na identifikáciu rádiometrických rozdielov alebo porúch medzi nimi. Potom je možné vypočítať empirický korekčný model na úpravu histogramov, aby sa línie nefunkčných detektorov podobali na tie normálne dátové linky.

Dobrý systém destrifikácie obrazu musí byť schopný eliminovať pruhované čiary alebo stĺpce v obraze bez toho, aby spôsobovali nežiaduce vedľajšie účinky. Ideálne sú hodnoty šedej čistých pixelov (nie ovplyvnené pruhmi), ktoré by sa po odstránení nemali meniť, spracovávať, aby sa zachovala autentickosť pôvodných údajov (Obr. 4.2).



Obr. 4.2 Destriping satelitnej snímky oceánu. (a)–(c) zobrazujú koncentráciu chlorofylu. (d)–(f) z družice MODIS-Aqua z 3.12.2013. Originálne dáta (b) a (e), korigované dáta sú na obrázku (c) a (f). **Fig. 4.2** Destriping of the ocean satellite images. (a)-(c) showthe chlorophyll concentration. (d)-(f) images from the MODIS-Aqua satellite on December 3, 2013. Original data (b) and (e), corrected data are shown in (c) and (f). Source: Mikelsons et al., 2014

"Salt and Pepper" noise

Šum "Salt and Pepper" sa niekedy vyskytuje v digitálnych dátach. V tejto situácii počet susedných pixelov pozdĺž línie (alebo celého riadku) môže obsahovať falošné digitálne čísla (Digital nurbers DN), často hodnoty 0 alebo "žiadne údaje" (Obr 4.3). Tento problém sa obyčajne rieši nahradením chybných DN priemerom hodnôt pre pixely vyskytujúce sa v riadkoch tesne nad a pod riadkom. Problémy s náhodným šumom v digitálnych dátach sa riešia trochu inak než pruhovanie. Tento typ šumu sa vyznačuje nesystematickosťou variácie odtieňov sivej od pixelu k pixelu, čiže sa nazývajú bitové chyby alebo "salt and peper". Takýto šum sa často označuje ako "špicatý" a spôsobuje, že obrázky majú anomálny vzhľad "soli a korenia" alebo "zasneženia" svetlých alebo tmavých pixelov rozptýlených na snímkach.

Bitové chyby sa riešia rozpoznaním, že hodnoty šumu sa normálne menia oveľa prudšie ako skutočné hodnoty obrazu. Šum teda možno identifikovať na základe porovnania každého pixelu na obrázku s jeho susedmi. Ak rozdiel medzi danými hodnotami pixelu a jeho okolitých hodnôt pixlov presahuje prahovú hodnotu stanovenú analytikom, predpokladá sa, že pixel obsahuje šum. Hodnota zašumených pixelov potom môže byť nahradená priemerom jeho susedných hodnôt.

4 Digital Image Analysis



Obr. 4.3 Snímka s 10% šumom "salt and pepper" a opravená snímka. **Fig. 4.3** Image with 10% "salt and pepper" noise and the corrected image. Source: Kolhe & Jain, 2013

4.2.2. Radiometric corrections

Pod rádiometrickými korekciami sa myslia také úpravy obrazu, ktoré odstraňujú zmeny osvetlenia scény, atmosférických podmienok, geometrie zobrazenia a charakteristiky odozvy prístroja. V priebehu roka dochádza k systematickým, sezónnym zmenám intenzity slnečného žiarenia dopadajúceho na zemský povrch (Obr. 4.4). Ak sa porovnávajú snímky zhotovené v rôznych obdobiach roka, je tu zvyčajne potrebné aplikovať korekciu nadmorskej výšky Slnka a korekciu vzdialenosti medzi zemou a Slnkom. Korekcia nadmorskej výšky Slnka zodpovedá sezónnej polohe Slnka vzhľadom na Zem. Prostredníctvom tohto procesu sú obrazové údaje získané pod rôznymi uhlami slnečného osvetlenia a normalizujú sa výpočtom hodnôt jasu pixelov za predpokladu, že slnko bolo v každý deň snímania v zenite.





Oprava sa zvyčajne používa vydelením každej hodnoty pixelu na scéne sínusom elevačný uhol Slnka (alebo kosínus slnečného zenitového uhla) pre konkrétny čas a umiestnenie snímkovania. Korekcia vzdialenosti Zem-Slnko sa používa na normalizáciu pre sezónne obdobie zmeny vzdialenosti medzi Zemou a Slnkom. Vzdialenosť Zem – Slnko je zvyčajne vyjadrená v astronomických jednotkách. Astronomická jednotka je ekvivalentná stredná vzdialenosť medzi Zemou a Slnkom, približne 149 : 6 3106 km. Ožiarenie zo Slnka klesá so štvorcom vzdialenosti Zem – Slnko. Zanedbanie atmosférických vplyvov, kombinovaný vplyv slnečného zenitového uhla a vzdialenosť Zem – Slnko na ožiarení dopadajúcom na zemský povrch môže byť vyjadrené ako:

$$E = \frac{E_0 \cos \Theta_0}{d^2},\tag{4.1}$$

kde:

E je normalizované slnečné žiarenie, E_0 je slnečné žiarenie v strednej vzdialenosti Zem – Slnko, $cos\theta_0$ je slnečný uhol od zenitu, d^2 je vzdialenosť Zem – Slnko, v astronomických jednotkách.

Zmena slnečného osvetlenia je znásobená atmosférickými vplyvmi. Atmosféra ovplyvňuje vyžarovanie merané v ktoromkoľvek bode scény dvoma protichodnými spôsobmi: tlmí (znižuje) energiu osvetľujúcu pozemný objekt a zároveň pôsobí ako samotný reflektor, pridáva rozptýlené, cudzie žiarenie k signálu detekovanému senzorom. Kompozitný signál pozorovaný na akomkoľvek mieste pixelu teda možno vyjadriť pomocou vzťahu:

$$EL_{tot} = \frac{\rho E T}{\pi} + L_p , \qquad (4.2)$$

kde:

L_{tot} je celkové spetrálne žiarenie merané senzorom,

 ρ je odrazivosť objektu,

E je ožiarenie objektu,

T je prepúšťanie atmosféry, transmissia,

 L_{ρ} je rozptýlené žiarenie dráhy, znižuje kontrast snímky.

4 Digital Image Analysis



Obr. 4.5 Porovnanie snímok pred rádiometrickou korekciou a po korekcii. a) Pôvodná snímka z novembra 2005 s kondenzačnými stopami (pásma 4, 3, 2). (b) Snímka z novembra 2005 so snímkou kondenzačných stôp po rádiometrickej korekcii (pásma 4, 3, 2). (c) Pôvodná snímka z februára 2006 bez kondenzačných stôp (pásma 4, 3, 2). (d) Snímka z februára 2006 bez kondenzačných stôp po rádiometrickej korekcii (pásma 4, 3, 2).

Fig. 4.5 Comparison of images before and after radiometric correction. a) Original image from November 2005 with condensation traces (bands 4, 3, 2). (b) November 2005 image with the image of the condensation traces after radiometric correction (bands 4, 3, 2). (c) Original image from February 2006 without condensation traces (bands 4, 3, 2). (d) February 2006 image without condensation traces after radiometric correction (bands 4, 3, 2). Source: Zhang et al., 2014

4.2.3. Geometric corrections

Nespracované digitálne snímky zvyčajne obsahujú geometrické skreslenia tak výrazné, že ich nemožno použiť priamo ako mapový podklad bez následného spracovania. Pôvod deformácií siaha od zmien nadmorskej výšky, polohy a rýchlosti senzorovej platformy cez faktory, ako je panoramatické skreslenie, zakrivenie Zeme, atmosférický lom, posunutie reliéfu a nelinearity v pohybe zorného poľa snímača. Účelom geometrickej korekcie je kompenzovať skreslenie získané týmito faktormi tak,

že opravený obraz bude mať najvyššiu geometrickú integritu. Čoraz častejšie sa niektoré alebo všetky potrebné geometrické opravy vykonávajú automaticky poskytovateľmi obrazových údajov. Inokedy zas spracovávateľ dát musí sám snímky geometricky korigovať – odstrániť deformácie v zobrazení a transformovať ich do požadovaného súradnicového systému.

Zdrojom skreslenia v multispektrálnom skenovaní satelitnými nosičmi je východná rotácia Zeme pod satelitom počas snímania - známe ako šikmé skreslenie. Náhodné skreslenia a zvyškové neznáme systematické skreslenia sú opravené analýzou dobre distribuovaných pozemných vlícovacích bodov (GCP) vyskytujúcich sa na snímke. Dobrými vlícovacími prvkami (prirodzenými vlícovacími bodmi) sú napr. diaľničné križovatky alebo zreteľné rysy pobrežia. Tieto hodnoty sa potom podrobia regresnej analýze najmenších štvorcov na určenie koeficientov pre dve rovnice transformácie súradníc, ktoré možno použiť na vzájomné prepojenie geometricky správnych (mapových) súradníc a skreslené súradnice obrazu.

Geometrická korekcia (niekedy skrátene aj geokorekcia) je proces transformácie v smere osí X a Y snímky tak, že priestorové skreslenia v pôvodnom obraze sú eliminované alebo minimalizované a výstupné smery osí X a Y zodpovedajú zvolenému geografickému referenčnému systému. Geometrická korekcia sa vykonáva:

- 1. mozaikovaním dvoch alebo viacerých snímok z DPZ do jedného kombinovaného obrazu,
- 2. porovnaním dvoch alebo viacerých snímok z DPZ tej istej oblasti z rôznych časov,
- 3. lokalizovaním bodov a prvkov záujmu na geometricky korigovanej snímky,
- 4. kombinovaním DPZ snímky s údajmi z iných zdrojov, ako sú mapové vrstvy národných parkov alebo údaje zo sčítania obyvateľstva v rámci GIS,
- 5. presne vypočítanou vzdialenosťou a plochou z geokorigovanej snímky.

Potrebná je najmä geometrická korekcia, pretože dráhy satelitných letov sa zvyčajne nezhodujú so skutočným severom a orientáciou mriežky väčšiny geografických referenčných systémov (Obr. 4.6).





Reality

How image is supplied

Obr. 4.6 Geometrická korekcia snímky. Fig. 4.6 Geometric correction of an image. Source: Zhang et al., 2014

4.2.4. Pre-processing final adjustments

Ako posledný krok počas predbežného spracovania obrazu je potrebné častokrát vytvoriť podmnožinu obrazu, tzv. subset na zníženie objemu dát, aby zjednodušil a skrátil čas spracovania. Častokrát je tým myslený výber záujmovej oblasti plogynóm, ktorý môže byť pravidelného alebo nepravidelného tvaru (Obr. 4.7).



Obr. 4.7 Vytvorenie subsetu z pôvodnej snímky. **Fig. 4.7** Creation of a subset from the original image. Source: Copernicus Sentinel data [2020]. Retrieved from Copernicus SciHub [07/12/2021], processed by FBERG TUKE

Ďalším z krokov je vrstvenie (stohovanie, stacking) (Obr. 4.8) na spájanie viacerých samostatných pásiem resp. vrstviev v jednom obrázku a mozaikovanie viacerých obrázkov na pokrytie širšej oblasti. Podmnožinu možno použiť na zmenšenie priestorového rozsahu, pričom môže zahŕňať aj výber len určitých spektrálnych pásem. Stohovanie umožňuje analýzu čaových sérií fenoménov ako sú povodne, odlesňovanie, ústup ľadovcov, alebo zmena pobrežia.



Obr. 4.8 Oblasť rieky Yukon pri meste Beaver na Aljaške. **Fig. 4.8** The Yukon river flats near Beaver, Alaska. Source: contains modified Copernicus Sentinel data 2017-2018, processed by ESA; asf.alaska.edu/how-to/data-tools/data-tools

Stohovanie vrstiev sa často používa, keď sú jednotlivé spektrálne pásma v samostatných súboroch, ale dá sa použiť aj na spojenie dvoch alebo viacerých rôznych snímok s rôznymi dátumami, alebo z rôznych senzorov.

4.3. Image enhancement – radiometric

Hlavným cieľom vylepšenia obrazu je zlepšiť vizuálnu interpretovateľnosť obrazu zvýšením zdanlivého rozlíšenia medzi objektami na scéne snímky. Najviac vylepšovacích techník možno kategorizovať ako bodové operácie, alebo operácie podľa najbližšieho suseda. Cieľom je vytvoriť "novú" snímku z pôvodnej snímky, aby sa zvýšilo množstvo informácií, ktoré je možné z údajov vizuálne interpretovať. Bodové operácie upravujú hodnotu jasu každého pixelu v súbore obrazových údajov nezávisle. Operácie susedstva upravujú hodnotu každého pixelu na základe susedných hodnôt jasu. Vylepšenie je možné vykonať formou vylepšenia jednopásmových (monochromatických) obrazov alebo na jednotlivých komponentoch viacobrazových snímok. Výsledné snímky môžu byť tiež zobrazené ako čiernobiele alebo farebné. Operácie vylepšenia sa zvyčajne vykonávajú na už prespracovaných snímkach (podľa Kapitoly 4.2).

Tieto techniky možno kategorizovať ako:

- 1. **Manipulácia s kontrastom** vylepšenie kontrastu, prahovanie úrovne šedi a hustotné rezy
- 2. **Manipulácia priestorových objetov** priestorové filtrovanie, vylepšenie hrán a Fourierové ananlýzy
- Multi-image manipulácie pomery a rozdiely medzi pásmami z multispektrálnych senzorov, vegetačné a iné indexy, určenie hlavných a vedľajších zložiek, vegetečných zložiek, IHS intezita – odtieň (hue) – sýtosť (saturation), a iné transformácie farebného priestoru.

4.3.1. Contrast manipulation

4.3.1.1. Gray-Level Thresholding

Prahovanie úrovni šedi sa používa na segmentovanie vstupnej snímky do dvoch tried – jednej pre tie pixely, ktoré majú hodnoty nižšie ako úroveň šedi definovanej analytikom, a jednu pre tieto pixely nad touto hodnotou. Prahovanie šedi je jedna z mnohých metód ako vytvoriť binárnu masku snímky. Prahovanie je jedným z najpoužívanejších prístupov k vymedzeniu rozsahu objektov na snímke práve kvôli svojej účinnosti a efektívnosti. Pri digitálnom spracovaní obrazu je prahovanie najjednoduchšou metódou segmentovania obrazov.

Prahová (Tresholding) hodnota pixela *T* je určená ako:

$$g(x,y) = 0$$
 ak $f(x,y) < T$, (4.3)

а

$$g(x, y) = 1$$
 ak $f(x, y) \ge T$. (4.4)

Takto vytvorené masky sa používajú na rozdelenie obrazu do dvoch tried tak, že dodatočné spracovanie potom možno aplikovať na každú triedu nezávisle. Klasické prahové metódy používané pri extrakcii záplavového pokrytia z radarových údajov zahŕňajú metódu Otsu (maximalizácia medzitriedneho rozptylu), metódu prahu entropie, a metódu bimodálneho histogramu.

Výber optimálnej prahovej hodnoty je dôležitý proces pre presnú extrakciu útvarov na snímke. Hoci niektorí výskumníci určujú optimálnu prahovú hodnotu interpretáciou histogramu vizuálne, v literatúre bolo zavedených mnoho účinných algoritmov automatického prahovania (Obr. 4.9 a Obr. 4.10).

4 Digital Image Analysis



Obr. 4.9 Prahovanie šedi. Jazero Salda (Turecko) a vznik bitového obrazu vodnej plochy metódami prahovania šedi na podklade MS snímky Sentinel – 2 a vytvorením jej NDWI indexu. Mapy vody extrahované z klasifikácie SVM a hustotného delenia prahových hodnôt: a) klasifikácia Support Vector Machine SVM, b) Huangova a Wangova metóda fuzzy prahovania, c) metóda

intermodálneho prahovania, d) metóda prahovania izodát, e) metóda prahovania Li a Tam, f) metóda prahovania maximálnej entropie, g) metóda stredného prahovania, h) metóda prahovania minimálnej chyby, i) metóda minimálneho prahovania, j) metóda prahovania so zachovaním momentu, k) Otsuova metóda prahovania, l) metóda prahovania percentilu (Pdlaždice), m) metóda prahovania Renyiho entropie, n) Shanbhagova metóda prahovania, o) metóda trojuholníkového prahovania, p) Yenova metóda prahovania.

Fig. 4.9 Lake Salda (Turkey) and the creation of a bitmap image of the water surface by grey thresholding methods based on the Sentinel-2 MS image and the creation of its NDWI index. Water maps extracted from SVM classification and density division thresholding: (a) Support Vector Machine SVM classification, (b) Huang and Wang fuzzy thresholding method, (c) intermodal thresholding method, (d) isodate thresholding method, (e) Li and Tam thresholding method, (f) maximum entropy thresholding method , (g) mean thresholding method, (h) minimum error thresholding method, (i) minimum thresholding method, (j) momentum conservation thresholding method, (k) Otsu thresholding method, (l) percentile (P-tile) thresholding method, (m) Renyi entropy thresholding method, (n) Shanbhag thresholding method, (o) triangular thresholding method, (p) Yen thresholding method. Source: Sekertekin, 2021



Pixel Value

Obr. 4.10 Ilustrácia optimálnych prahových hodnôt na histograme NDWI získanom z rôznych metód prahovania: a) pôvodný histogram NDWI, b) Huangova a Wangova metóda fuzzy prahovania, c) metóda intermodálneho prahovania, d) metóda prahovania izodát, e) Li a Tamova metóda prahovania, f) metóda prahovania maximálnej entropie, g) metóda prahovania strednej hodnoty, h) metóda prahovania minimálnej chyby, i) metóda minimálneho prahovania, j) metóda prahovania so zachovaním momentu, k) Otsuova metóda prahovania, l) metóda prahovania, o) metóda trojuholníkového prahovania, p) Yenova metóda prahovania.

Fig. 4.10 Illustration of optimal thresholds on the NDWI histogram obtained from different thresholding methods: (a) original NDWI histogram, (b) Huang and Wang's fuzzy thresholding method, (c) intermodal thresholding method, (d) isodate thresholding method, (e) Li and Tam's thresholding method, (f) maximum entropy thresholding method, (g) mean value thresholding method, (h) minimum error thresholding method, (i) Minimum thresholding method, (j) Momentum conservation thresholding method, (k) Otsu's thresholding method, (l) Percentile (P-tile) thresholding method, (m) Renyi entropy thresholding method, (n) Shanbhag's thresholding method, (o) Triangular thresholding method, (p) Yen thresholding method. Source: Sekertekin, 2021

4.3.1.2. Density slicing

Technika hustotných rezov je vylepšená technika prahovania šedi, pri ktorej sú digitálne údaje distribuované pozdĺž osi x histogramu snímky a následne sú rozdelené do série intervalov špecifikovaných analytikom na triedy (rezy), pričom zlepšujú informácie získané z jednotlivých pásem jasu. Všetky digitálne údaje spadajúce do daného intervalu sa na výstupnej snímke zobrazia pod jedným číslom, čím vznikne obraz skladajúci za z takého počtu intervalov v rôznych úrovniach šedi, na koľko intervalov bol obraz rozdelený.

Ak je napríklad definované, že sa histogram rozdelí do 7 pásiem, výsledna snímka bude obsahovať 7 hodnôt pixlov odtieňov šedi (Obr. 4.11). Pre zvýraznenie rozdielov je vhodné priradiť každému pásmu inú farebnú hodnotu. Hustotné rezy sa používajú napr. pre zobrazenie spojitých javov – nadmorských výšok reliéfu, určenia hĺbky morského dna, alebo teplotných pomerov.



Obr. 4.11 Vizualizácia teploty povrchu pomocou hustotných rezov. **Fig. 4.11** Visualization of surface temperature using density slices. Source: quotestrendyngb.blogspot.com/2021/04/density-slicing-in-digital-image.html

Táto technika sa bežne používa na jednopásmový monochromatický obraz na zvýraznenie oblastí, ktoré sa zdajú byť jednotné v tóne, ale nie sú. Hodnoty odtieňov sivej (0 – 255) sa skonvertujú na sériu intervalov alebo rezov a každému rezu sú priradené rôzne farby.

4.3.1.3. Contrast stretching – histogram equalization

Rádiometrická rozlišovacia schopnosť senzorov vyjadruje schopnosť senzora rozlíšiť jednotlivé úrovne jasu (viď kapitola 3.6.3). Zobrazovacie a záznamové zariadenia často pracujú v rozsahu jasu 0 - 255 (maximálny počet reprezentovaný v 8-bitovom kódovaní). Digitálne informácie na snímke len zriedka pokrývajú tento presný rozsah – môžu využiť len malý časť tohto 8-bitového rozsahu (v oblastiach s nízkym kontrastom) alebo môže pokrývať oveľa širší rozsah (v oblastiach s vysokým kontrastom snímaných snímačmi s viac ako 8-bitovým rádiometrickým rozlíšením).

Zámerom zvýraznenia kontrastu (Obr. 4.12) je teda zmeniť rozsah jasu hodnoty prítomnej vo vstupnej snímke tak, aby sa optimálne využil celý 8-bitový rozsah zobrazenia hodnoty pomocou určitej vhodnej funkcie. Výsledkom je výstupná snímka, ktorou je zvýraznený kontrast medzi funkciami, ktoré zaujímajú spracovávateľa obrazu.

4 Digital Image Analysis

V prípade, že vstupné digitálne hodnoty sa zobrazujú bez zmeny, bez akejkoľvek transformácie, nie je využitý celý dynamický rozsah zariadenia, tak nevzniká **žiadne zvýraznenie**.

V prípade, že pôvodné digitálne hodnoty snímky (napr. 35 - 125) sa v ich rozsahu lineárne rozdelia tak, aby vyplnili celý vstupný rozsah výstupného zariadenia (0 - 255), vzniká tzv. lineárne rozdelenie. Intenzita pixlov s blízkymi hodnotami sa tak rozdelí s dostatočne rozdielnymi tónmi šedi.



Obr. 4.12 Efekty zvýraznenia histogramu. **Fig. 4.12** Effects of histogram equalization. Source: ltb.itc.utwente.nl/page/498/concept/81597

Funkciu rozdelenia pre lineárne zvýraznenie možno definovať ako:

$$DN' = \left(\frac{DN - min}{max - min}\right) * 255 \quad , \tag{4.5}$$

kde

DN' je výstupná hodnota digitálneho čísla (digital number DN),

DN je vstupná hodnota digitálneho čísla (0),

min je minimálna hodnota digitálnych čísel vstupnej snímky,

max je maximálna hodnota digitálnych čísel (255).



Obr. 4.13 MS snímka z družice Sentinel 2, pásmo B8a, zobrazujúca plochu spálenú po požiari v Grécku z 30.7.2018. a) žiadne zvýraznenie kontrastu, b) lineárne zvýraznenie histogramu a c) zvýrazenie časti histogramu.

Fig. 4.13 MS image from Sentinel 2 satellite, band B8a, showing the area burned after the fire in Greece on 30.7.2018. a) no contrast enhancement, b) linear enhancement of the histogram and c) enhancement of part of the histogram.

Source: Copernicus Sentinel data [2018]. Retrieved from Copernicus SciHub [07/12/2021], processed by FBERG TUKE

4.3.2. Spatial Filtering

Ďalší postup spracovania údajov v diaľkovom prieskume Zeme spadajúci do kategórie vylepšenia obrazu, ktorý často prezrádza cenné informácie iného charakteru, je priestorové filtrovanie. Aj keď sa táto technika používa menej často, skúma rozloženie pixelov s rôznym jasom na snímke a najmä zisťuje a zostruje hraničné diskontinuity. Tieto zmeny v osvetlení scény, ktoré sú zvyčajne postupné a nie náhle, vytvárajú vzťah, ktorý kvantitatívne vyjadrujeme ako "priestorové frekvencie". Priestorová frekvencia je definovaná ako počet cyklov zmeny hodnôt DN obrazu na jednotku vzdialenosti (napr. 10 cyklov/mm) pozdĺž určitého smeru v obraze. Obraz s iba jednou priestorovou frekvenciou pozostáva z rovnako vzdialených pruhov (rastrových čiar).

Vo všeobecnosti snímky pozostávajú z niekoľkých dominantných priestorových frekvencií. Jemné detaily na obrázku zahŕňajú väčší počet zmien na jednotku vzdialenosti ako hrubé vlastnosti obrázka. Jeden z využívaných matematických aparátov na rozdelenie obrazu na jeho rôzne priestorové frekvenčné zložky sa nazýva Fourierova analýza. Po rozdelení obrazu na jednotlivé komponenty (vykonané ako "Fourierova transformácia") je možné zdôrazniť určité skupiny (alebo "pásma") frekvencií v porovnaní s ostatnými a rekombinovať priestorové frekvencie do vylepšeného obrazu. Algoritmy na tento účel sa nazývajú "filtre", pretože potláčajú (nezdôrazňujú) určité frekvencie a prepúšťajú (zdôrazňujú) iné. Filtre, ktoré prepúšťajú vysoké frekvencie, a teda zdôrazňujú jemné detaily a okraje, sa nazývajú **vysokopriepustné filtre**. **Nízkopriepustné filtre**, ktoré potláčajú vysoké frekvencie a môžu znížiť alebo eliminovať šum "*salt and pepper*".



Obr. 4.14 Snímka zo senzora Thematic Mapper, Band 2 zo zálivu Morro, Kalifornia. Vľavo - pôvodná snímka, vpravo - produkt nízkopriepustného (priemerného) filtra, ktorý má tendenciu zovšeobecňovať snímku.

Fig. 4.14 Thematic Mapper sensor image, Band 2 from Morro Bay, California. Left - original image, right - product of a low-pass (average) filter that tends to generalize the image. Source: http://drr.ikcest.org/remote-sensing-tutorial/chapter01/Sect1_130.html

Konvolučné filtrovanie je bežnou matematickou metódou implementácie priestorových filtrov. V tomto je každá hodnota pixelu nahradená priemerom na štvorcovej ploche so stredom tohto pixelu. Veľkosti štvorcov sú zvyčajne 3 x 3, 5 x 5 alebo 9 x 9 pixelov, ale prijateľné sú aj iné hodnoty. Ako sa používa pri dolnopriepustnom filtrovaní, má to tendenciu znižovať odchýlky od miestnych priemerov a tým vyhladzovať obraz. Rozdiel medzi vstupným obrazom a dolnopriepustným obrazom je výstup filtrovaný hornou priepustou. Vo všeobecnosti musia byť priestorovo filtrované snímky kontrastne roztiahnuté, aby sa využil celý rozsah zobrazenia snímok. Napriek tomu filtrované snímky majú tendenciu vyzerať plocho.

Algoritmus Sobel Edge Enhancement napr. nachádza prebytok diskontinuít, zdôrazňujú sa ostré hranice, ktoré môžu vyplynúť z použitia tohto spôsobu vylepšenia. Obraz hornopriepustného filtra pre záliv Morro tiež odhaľuje hranice, ale tlmenejšie ako vyššie (Obr. 4.15, Obr. 4.16).

4 Digital Image Analysis



Obr. 4.15 Záliv Morro; vľavo - filter na vylepšenie okrajov zvýrazňuje náhle diskontinuity, ako sú skalné spoje a zlomy, hranice polí a vzory ulíc; vpravo - zdôraznené ulice, diaľnice a niektoré potoky a hrebene. Charakteristickým znakom obrazu hornopriepustného filtra je, že lineárne prvky sa bežne javia ako svetlé čiary s tmavým okrajom. Detaily vo vode sa väčšinou stratia. Veľká časť obrazu je plochá.

Fig. 4.15 Morro Bay; left - the edge enhancement filter highlights abrupt discontinuities such as rock joints and faults, field boundaries, and street patterns; rigt - emphasized streets, highways, and some creeks and ridges. A characteristic feature of the top-pass filter image is that linear features commonly appear as bright lines with a dark edge. Details in the water are mostly lost. Much of the image is flat.

Source: http://drr.ikcest.org/remote-sensing-tutorial/chapter01/Sect1_130.html



Obr. 4.16 Obraz subscény Arizony s nízkopásmovým filtrom. Snímka vľavo - konvolučná matica 11x11 pixlov; snímka vpravo - konvolučná matica 51x51 pixlov.

Fig. 4.16 Image of the Arizona subscene with a low-pass filter. Left image - 11x11 pixel convolution matrix; right image - 51x51 pixel convolution matrix.

Source: http://drr.ikcest.org/remote-sensing-tutorial/chapter01/Sect1_130.html

Snímka na Obr.4.16 - vľavo vznikla horným priepustom, v ktorom má konvolučná matica veľkosť 11 x 11 pixelov. Toto sa dosiahne odčítaním obrazu dolnopriepustného filtra od pôvodného (nenatiahnutého) súboru údajov. V tomto prípade je obraz formou vylepšenia okrajov. Keď sa počet pixelov v konvolučnom okne zvyšuje, vysokofrekvenčné zložky sú ostrejšie definované. To je zrejmé na tejto snímke, ktorá používa maticu 51 x 51 pixelov (Obr. 4.16 - vpravo). Nízkopriepustné filtre redukujú odchýlky centrálneho pixlu od jeho okolia. Obraz po filtrácii je oproti pôvodnému obrazu zhladený, nakoľko tieto filtre zmenšujú rozptyl hodnôt pixlov v rámci výberového okna. Stupeň zahladenia je priamo úmerný veľkosti použitého okna (napr. priemerový filter, gaussovský, mediánový a pod.). Vysokofrekvenčné filtre zdôrazňujú zmeny v digitálnych hodnotách pixlov a tým pádom zdôrazňujú hrany a línie medzi rôznymi povrchmi. Vysokofrekvenčné filtre zdôrazňujú objekty, ktoré sú menšie ako polovica vyhľadávacieho okna (laplaceovské filtre, Sobelov filter, Prewittov filter, diferenčné filtre a zostrujúce filtre).

Fourierove transformácie sú aplikované na spojité funkcie, ale v DPZ je digitálny obraz zložený z riadkov a stĺpcov – diskrétna dvojrozmená funkcia. Tu sa aplikuje rýchla Fourierova transformácia (*FFT – Fast Fourie Transformation*), ktorá prevádza obraz z priestorového SS, tvoreného riadkami a stĺpcami, určitým počtom *sin* a *cos* funkcií do frekvenčného SS.



Obr. 4.17 Digitalizovaná oblasť meandru na rieke Colorado, a) homogénna nízka frekvencia vodnej plochy, b) oblasť obsahuje nízku a strednú frekvenciu terénu s horizontálnym a vertikálnym lineárnymi črtami a (c) oblasť obsahuje nízke a stredne frekvenčný terén s diagonálnou líniovou črtou.

Fig. 4.17 Digitized meander area on the Colorado River, (a) homogeneous low frequency water surface, (b) area contains low and intermediate frequency terrain with horizontal and vertical linear features, and (c) area contains low and intermediate frequency terrain with diagonal linear features.

Source: Jensen, 2005

4.3.3. Spectral enhancement - multiband manipulations

4.3.3.1. Colour compositions

Digitálne snímky vytvorené pre potreby diaľkového prieskumu Zeme sú častokrát tvorené viacpásmovými obrazovými záznamami (multispektrálne snímky), ktorých farebný vnem vzniká kombináciou farebných obrazou, čiže farebnou syntézou (RGB). Multispektrálny obraz je možné ale kombinovať aj v iných pásmach tak, aby sa zvýraznili potrebné vizuálne informácie.

Jednotlivé pásma v ktorých senzory snímajú obraz sú tvorené čiernobielym obrazom, ktoré ale neudávajú dostatočne vizuálne vhodné zobrazenie scény (Obr. 3.12, kap. 3.6.1 a 3.6.2). Na takto vytvorenom obaze v jednom pásme každý jeden pixel popisuje len jednu hodnotu šedi. V dôsledku toho je potrebné kombinovať jednotlivé pásma pomocou multipsektrálnych syntéz – aditívne a subtraktívne skladanie farieb. Družica Sentinel 2 je vybavená senzorom Multi Spectral Instrument (Tab. 3.1., Kap. 3.6.2), ktorý snímkuje v pásme B2 vlnové dĺžky 492nm – modrá farba, v pásme B3 560nm – zelená farba, B4 665nm – červená farba. Viditeľný faerbný obraz vznikne systézou týchto 3 zložiek. (Obr. 3.12 a Obr. 4.18). Použitím kombinácií pásiem môžeme zo snímky extrahovať špecifické informácie.



Obr. 4.18 Rôzne farebné kompozície multispektrálnej snímky MSI senzora Sentinel-2: a) RGB kompozícia pásiem B4-B3-B2 zvýrazňujúca prirodzené farby obrazu, b) kompozícia B8-B4-B3 zvýrazňujúca farebné rozdiely vegetácie pomocou NIR pásma, c) zobrazenie jedného pásma B2 d) kompozícia pásem B12-B11-B8A pre zobraznie atmosférickej penetrácie.

Fig. 4.18 Different colour compositions of the multispectral MSI image of the Sentinel-2 sensor: a) RGB composition of the B4-B3-B2 bands highlighting the natural colours of the image, b) B8-B4-B3 composition highlighting the colour differences of the vegetation using the NIR band, c) display of the one - B2 band, d) B12-B11-B8A composition of the B12-B12-B11-B8A bands to show the atmospheric penetration.

Source: Copernicus Sentinel data [2020]. Retrieved from Copernicus SciHub [07/12/2021], processed by FBERG TUKE

Voľba kompozície farebných kanálov závisí v prvom rade od štúdie aká sa spracováva – či od štúdia povrchov, geologických, poľnohospodárske alebo vegetačných analýz. Farebnú syntézu je ale možné zostaviť z takých pásem, aké dávajú najviac odlišné informácie.

4.3.3.2. Spectral rationing

Pri vzniku obrazovej scény helio-synchónnou družicou, kde má veľký význam uhol slnečného žiarenia, nastáva situácia, kedy dopadajúce žiarenie spôsobuje tiene na obraze. Vplyv rôzneho osvetlenia povrchov sa dá potlačiť podielom dvoch pôvodných obrazov (Obr. 4.19, Tab. 4.1).



Obr. 4.19 Vplyv rôzneho osvetlenia scény. **Fig. 4.19** Effect of different scene lighting. Source: after Lillesand, Kiefer and Chipman, 2015

Tab. 4.1 Potlačenie vplyvu rôzneho osvetlenia povrchov prostredníctvom spektrálneho pomeru. **Tab. 4.1** Suppressing the effect of different illumination of surfaces through spectral rationing. Source: after Lillesand, Kiefer and Chipman, 2015

Doursch	Osvetlenie/Tieň	Digitálna hodnota		Dedial A /P
Povrch		Pásmo A	Pásmo B	
listnaté	Osvetlené	48	50	0,96
	Zatienené	18	19	0,95
ihličnaté	Osvetlené	31	45	0,69
	Zatienené	11	16	0,69

Výsledkom obrazových podielov snímky je obraz, ktorý presnejšie zachytáva spektrálne charakteristiky objektov.

4.3.3.3. Normalized Difference Ratios (Indices)

Normalizované pomerové podiely (indexy) a ich modifikácie sú vytvorené z dvoch pásem, pričom čitateľ je tvorený ich rozdielom a menovateľ je tvorený súčtom týchto dvoch pásem. Cieľom tvorby normalizovaných podielových inedxov je maximalizácia viditeľnosti vybraných zložiek snímky kombinovaním spektrálnych pásem a ich podielmi. Týmto spôsobom sú zvýrazňované zložky ako napr. vegetácia (NDVI Normalised Difference Vegetation Index), voda (NDWI Normalised Difference Water Index), sneh (NDSI Normalised Differnce Snow Index), vyhorené oblasti po požiari (NBR Normalised Burned Racio), vlhkosť pôdy (NDMI) a podobne.

Základný vegetačný index **RVI** (**Ratio Vegetation index**) bol navrhnutý v roku 1969 založený na princípe absorbcie relatívne viac červeného svetla ako infračerveného:

$$\mathbf{RVI} = \frac{Red}{NIR} \tag{4.6}$$

RVI sa často používa na odhady a monitorovanie zelenej biomasy, konkrétne pri pokrytí vegetáciou s vysokou hustotou, pretože tento index je veľmi citlivý na vegetáciu a má dobrú koreláciu s rastlinnou biomasou. Keď je však vegetačný kryt riedky (menej ako 50 % pokryv), **RVI** sú citlivé na atmosférické vplyvy a ich zastúpenie biomasy je slabé.

Diferenčný vegetačný index **DVI** bol navrhnutý neskôr ako:

$$\mathbf{DVI} = NIR - Red \tag{4.7}$$

DVI je veľmi citlivý na zmeny pôdneho pozadia; možno ho použiť na monitorovanie vegetačného ekologického prostredia. Preto sa **DVI** nazýva aj index environmentálnej vegetácie (**EVI**).

Index kolmej vegetácie (**PVI** – **Perpendicular Vegetation Index**) je simuláciou indexu zelenej vegetácie (**GVI**) v 2D údajoch Red a NIR pásiem. Pôda predstavuje vysokú spektrálnu odozvu v NIR a R pásmach. Vzdialenosť medzi bodom odrazivosti (R, NIR) a líniou pôdy bola definovaná ako kolmica vegetačného indexu **PVI**, ktorú možno vyjadriť nasledovne:

$$\mathbf{PVI} = \sqrt{(\rho_{p\hat{o}da} - \rho_{veg})_{Red}^2 - (\rho_{p\hat{o}da} - \rho_{veg})_{NIR}^2}$$
(4.8)

Asi naznámejším indexom je normalizovaný diferenčný index je **NDVI – Normalizovaný diferenčný vegetečný index**, určený ako:

$$\mathbf{NDVI} = \frac{NIR - Red}{NIR + Red} \tag{4.9}$$

Výsledná hodnota dobre koreluje s akumuláciou biomasy plodín, ale aj hodnotami chlorofylu v listoch, hodnotami listovej plochy a absobrciou EMŽ vegetácie, vitality rastlín a pod. V závislosti od použitého satelitného senzora je potrebné doplniť odpovedajúce hodnoty konkrétnej misie, ktorá snímku vytvorila. Napr. pre Sentinel 2 tomu odpovedajú hodnoty B8A a B4. Nakoľko chlorofyl v listoch rastlín silne absorbuje viditeľné svetlo (od 0,4 do 0,7 µm) pri fotosyntéze, bunková štruktúra listov zas silne odráža blízke infračervené svetlo (od 0,7 do 1,1 µm). Čím viac listov má rastlina, tým viac sú tieto vlnové dĺžky svetla ovplyvnené.

Jednoduchý pomer (infračervená/červená) je vždy kladný, čo má praktické výhody, ale má aj matematicky nekonečný rozsah (0 až nekonečno), čo môže byť v porovnaní s NDVI praktickou nevýhodou. Hodnoty **NDVI** nadobúdajú rozsah v rámci intervalu <-1, 1>.

Modifíkácie vegetečných ondexov zahrňujú atmosférické efekty ako **ARVI** (**Atmospherically Resistant Vegetation Index**), **SAVI** (**Soil-Adjusted Vegetation Index**), modifikovaný **SAVI** a pod.

Jednoduché vegetačné indexy kombinujúce viditeľné R a NIR pásma výrazne zlepšili citlivosť detekcie zelenej vegetácie. Rôzne prostredia majú svoje vlastné variabilné a zložité charakteristiky, ktoré je potrebné zohľadniť pri používaní rôznych vegetačných indexov. Preto má každý vegetačný index svoje špecifickú reprezentáciu vegetácie, svoju vhodnosť na konkrétne využitie a niektoré limitujúce faktory. Pre praktické aplikácie je preto potrebné pri výbere konkrétneho vegetačného indexu postupovať opatrne, komplexne zvážiť a analyzovať výhody a obmedzenia existujúcich indexov a potom ich

kombinovať, aby sa mohli použiť v špecifickom prostredí. Týmto spôsobom je možné ich využitie prispôsobiť špecifickým aplikáciám a platformám. S rozvojom technológie hyperspektrálneho a multispektrálneho diaľkového snímania je možné vyvinúť nové indexy, ktoré rozšíria oblasti výskumu.

Ďalší pomerne známy používaný je index **NDMI** (**Normalized Difference Moisture Index**), ktorý je normalizovaný rozdielový index vlhkosti pôdy, ktorý používa pre výpočet pásma ako NIR a SWIR. Pásmo SWIR odráža zmeny v obsahu vody vo vegetácii a v štruktúre hubovitého mezofylu vo vegetácii, zatiaľ čo odrazivosť NIR je ovplyvnená vnútornou štruktúrou listov a obsahom sušiny listov, ale nie obsahom vody.

Index	Name	Definition	Landsat 8	Sentinel-2
NDWI	Normalized Difference Water Index	(Green-NIR) / (Green+NIR)	(B5-B6) / (B5+B6)	(B3-B8) / (B3+B8)
NDVI	Normalized Difference Vegetation Index	(NIR-Red) / (NIR+Red)	(B5-B4) / (B5+B4)	(B8-B4) / (B8+B4)
NDSI	Normalized Difference Snow Index	(Green-SWIR) / (Green+SWIR)	(B3-B6) / (B3+B3)	(B3-B11) / (B3+B11)
NDSI	Normalized Difference Soil Index		(B7-B2) / B7+B2)	(B12-B2) / (B12+B2)
NDMI	Normalized Difference Moisture Index	(NIR-SWIR) / (NIR+SWIR)	(B5-B6) / (B5+B6)	(B8A- B11) / (B8A + B11)
dNBR	Delta Normalised Burn Ratio	NBR _{PreFire} - NBR _{PostFire}		
NBR	Normalized Burn Ratio	(NIR-SWIR) / (NIR + SWIR)	(B5-B7) / (B5+B7)	(B8A-B12) / (B8A+B12)

 Tab. 4.2 Potlačenie vplyvu rôzneho osvetlenia povrchov prostredníctvom spektrálneho pomeru.

 Tab. 4.2 Suppressing the effect of different illumination of surfaces through spectral rationing.

Kombinácia NIR s SWIR odstraňuje zmeny spôsobené vnútornou štruktúrou listov a obsahom sušiny listov, čím sa zlepšuje presnosť pri získavaní obsahu vody vo vegetácii. Množstvo vody dostupnej vo vnútornej štruktúre listu do značnej miery riadi spektrálnu odrazivosť v intervale SWIR elektromagnetického spektra. Odrazivosť SWIR teda negatívne súvisí s obsahom vody v listoch. Stručne povedané, **NDMI** sa používa na sledovanie zmien obsahu vody v listoch. **NDWI** sa vypočíta pomocou odrazivosti blízkej infračervenej (NIR) a krátkovlnnej infračervenej (SWIR) (Obr. 4.20).



Obr. 4.20 Zobrazené scény jazera Como a jeho okolia, Taliansko, Sentinel 2, 20.7.2021; a) RGB kompozícia; b) NDVI; c) NDMI; d) NDSI – snow index.
Fig. 4.20 Multiple scenes of Lake Como and its surroundings, Italy, Sentinel 2, 20.7.2021; a) RGB composition; b) NDVI; c) NDMI; d) NDSI - snow index.
Source: ©Modified Copernicus Sentinel data [2021]/Sentinel Hub

Normalizovaný rozdielový index sa zvyčajne používa na zvýraznenie rozdielu medzi najsilnejšími a najslabšími spektrálnymi odozvami cieľovej krajinnej pokrývky. Použitie podielových indexov nie je v každej situáci jednoznačné, preto vznikajú rôzne modifikácie a obmeny, aby bol tento nástroj efektívny.

References

Books

Khan, A. I. (2016). Application of TCT as a Remote Sensing Change Detection Technique: A Temporal Case Study of Lahore District - Pakistan (pp. 1–176) [M.Phil. Geomatics Session 2013 - 2015]

Jensen, J. R. (2015). Introductory digital image processing : a remote sensing perspective (4th ed., pp. 1–659). Pearson Education, Inc. ISBN 978-0-13-405816-0

Tempfli, K., Kerle, N., Huurneman, G. C., & Janssen, L. L. F. (Eds.). (2009). Principles of Remote Sensing: An introductory textbook (4th ed., pp. 1–591). The International Institute for Geo-Information Science and Earth Observation (ITC). ISBN 978–90–6164–270–1

Lillesand, T.M., Kiefer, R.W. and Chipman, J.W. (2015). Remote sensing and image interpretation. Hoboken, N.J.: John Wiley & Sons, Inc. 770p. ISBN 978-1-118-34328-9

Dobrovolný, R. (1998). Dálkový průzkum Země; Digitální zpracování obrazu. Masarykova Univerzita, Přírodovědecká Fakulta. ISBN 80-210-1812-7

Wolf, P. R., Dewitt, B. A., & Wilkinson, B. E. (2014). Elements of photogrammetry with application in GIS (4th ed., pp. 1–807). Mcgraw-Hill Education, Cop. ISBN 978-0-07-176111-6

Papers, manuals, reports

Mikelsons, K., Wang, M., Jiang, L., & Bouali, M. (2014). Destriping algorithm for improved satellite-derived ocean color product imagery. Optics Express, 22(23), 28058. DOI: 10.1364/oe.22.028058

Kolhe, Y. V., & Jain, Y. K. (2013). Removal of Salt and Pepper Noise from Satellite Images. International Journal of Engineering Research & Technology, 2(11), 2051–2058.

Zhang, D., Zhang, C., Li, W., Cromley, R., Hanink, D., Civco, D., & Travis, D. (2014). Restoration of the missing pixel information caused by contrails in multispectral remotely sensed imagery. Journal of Applied Remote Sensing, 8(1), 083698. DOI: 10.1117/1.jrs.8.083698

Sekertekin, A. (2021). A Survey on Global Thresholding Methods for Mapping Open Water Body Using Sentinel-2 Satellite Imagery and Normalized Difference Water Index. Arch Computat Methods Eng 28, 1335–1347 DOI: 10.1007/s11831-020-09416-2

Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. IEEE Transactions on Systems, Man, and Cybernetics, 9(1), 62–66. DOI: 10.1109/tsmc.1979.4310076

Kapur, J. N., Sahoo, P. K., & Wong, A. K. C. (1985). A new method for gray-level picture thresholding using the entropy of the histogram. Computer Vision, Graphics, and Image Processing, 29(1), 140. DOI: 10.1016/s0734-189x(85)90156-2

Pun, T. (1980). A new method for grey-level picture thresholding using the entropy of the histogram. Signal Processing, 2(3), 223–237. DOI: 10.1016/0165-1684(80)90020-1

Sahoo, P. K., Soltani, S., & Wong, A. K. C. (1988). A survey of thresholding techniques. Computer Vision, Graphics, and Image Processing, 41(2), 233–260. DOI: 10.1016/0734-189x(88)90022-9

Shahtahmassebi, A. R., Lin, Y., Lin, L., Atkinson, P. M., Moore, N., Wang, K., He, S., Huang, L., Wu, J., Shen, Z., Gan, M., Zheng, X., Su, Y., Teng, H., Li, X., Deng, J., Sun, Y., & Zhao, M. (2017). Reconstructing Historical Land Cover Type and Complexity by Synergistic Use of Landsat Multispectral Scanner and CORONA. Remote Sensing, 9(7), 682. DOI: 10.3390/rs9070682

Deng, Y., Wu, C., Li, M., & Chen, R. (2015). RNDSI: A ratio normalized difference soil index for remote sensing of urban/suburban environments. International Journal of Applied Earth Observation and Geoinformation, 39, 40–48. DOI: 10.1016/j.jag.2015.02.010

Du, Z., Li, W., Zhou, D., Tian, L., Ling, F., Wang, H., Gui, Y., & Sun, B. (2014). Analysis of Landsat-8 OLI imagery for land surface water mapping. Remote Sensing Letters, 5(7), 672–681. DOI: 10.1080/2150704x.2014.960606

Xue, J., & Su, B. (2017). Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. Journal of Sensors, 2017, 1–17. DOI: 10.1155/2017/1353691

Chen, S., Huang, W., Chen, Y., & Feng, M. (2021). An Adaptive Thresholding Approach toward Rapid Flood Coverage Extraction from Sentinel-1 SAR Imagery. Remote Sensing, 13(23), 4899. DOI: 10.3390/rs13234899

Tsai, F., & Chen, W. W. (2008). Striping Noise Detection and Correction of Remote Sensing Images. IEEE Transactions on Geoscience and Remote Sensing, 46(12), 4122–4131. DOI: 10.1109/tgrs.2008.2000646

Web sources

https://www2.geog.soton.ac.uk/users/trevesr/obs/rseo/geometric_correction.html https://asf.alaska.edu/how-to/data-tools/data-tools/ https://quotestrendyngb.blogspot.com/2021/04/density-slicing-in-digital-image.html https://www.usgs.gov/landsat-missions/normalized-difference-moisture-index https://www.usgs.gov/landsat-missions/landsat-normalized-difference-vegetation-index https://www.usna.edu/Users/oceano/pguth/md_help/html/norm_sat.htm https://www.indexdatabase.de/

5

Image Classification

Image data classification is the basis of many environmental and socioeconomic applications. It is a process where image features are classified into so-called information classes based on a classification scheme - the map legend. The classification of remote sensing data and the creation of a thematic map is challenging because the success of this process can be influenced by many factors such as the complexity of the landscape in the study area, the type of remote sensing data, and the processing and classification approaches and tools used. Classification tools in GIS and remote sensing have evolved over time, from unsupervised classification to supervised, to object-oriented, and current software developments are constantly adding new automated image processing capabilities.

Image data classification is a complex process and requires the consideration of many factors. The main steps of image classification include determining an appropriate classification system, selecting training samples, image pre-processing, feature extraction, selecting appropriate classification approaches, post-classification processing, and accuracy assessment. Important factors influencing the selection of remote sensing data, the design of the classification procedure, and the quality of the classification results are the user's needs, the extent of the area under study, the economic situation, and the analyst's skills. Remote sensing data, including airborne and spaceborne sensor data, vary in spatial, radiometric, spectral and temporal resolution. Understanding the strengths and weaknesses of different types of sensor data is essential for selecting appropriate remote sensing data for image classification. When selecting a classification method, factors that are considered include accuracy, speed, and practicality.

This chapter is devoted to basic information on supervised and unsupervised image data classification algorithms.

·eesa [J] FBERG

5.1. Introduction

Klasifikácia obrazových údajov je základom mnohých environmentálnych a socioekonomických aplikácií. Jedná sa o proces, kde sú prvky obrazu roztriedené do tzv. informačných tried na základe klasifikačnej schémy – legendy mapy. Klasifikácia údajov z diaľkového prieskumu Zeme a vytvorenie tematickej mapy je výzvou, pretože úspech tohto procesu môže ovplyvniť mnoho faktorov, ako je zložitosť krajiny v študovanej oblasti, typ údajov z diaľkového prieskumu Zeme a použité prístupy a nástroje na spracovanie a klasifikáciu. Klasifikačné nástroje v GIS a diaľkovom prieskume Zeme sa vyvíjali časom, od neriadenej klasifikácie, cez riadené, objektovo-orientovaný a súčasný softvérový vývoj pridáva neustále nové možnosti automiatizovaného spracovania obrazu.

Klasifikácia obrazových údajov je zložitý proces a vyžaduje si zváženie mnohých faktorov. Hlavné kroky klasifikácie obrazu môžu zahŕňať určenie vhodného klasifikačnej schémy, výber trénovacích vzoriek, predbežné spracovanie obrazu, extrakciu znakov, výber vhodných klasifikačných prístupov, poklasifikačné spracovanie a posúdenie presnosti. Dôležitými faktormi, ktoré ovplyvňujú výber údajov z diaľkového prieskumu, návrh klasifikačného postupu a kvalitu výsledkov klasifikácie, sú potreby používateľa, rozsah skúmanej oblasti, ekonomická situácia a schopnosti analytika. Údaje z DPZ, vrátane údajov zo vzduchových a vesmírnych senzorov, sa líšia v priestorovom, rádiometrickom, spektrálnom a časovom rozlíšení. Pochopenie silných a slabých stránok rôznych typov údajov snímačov je nevyhnutné pre výber vhodných údajov z diaľkového snímania na klasifikáciu snímok. Medzi faktory, ktoré sa berú do úvahy pri výbere metódy klasifikácie, patrí presnosť, rýchlosť a praktickosť.

Klasifikácia obrazu je vykonávaná na základe pravidiel – klasifikátorov, podľa ktorých sa obrazové infromácie rozdeľujú do jednotlivých tried. Klasifikátory rozdeľujeme podľa:

- Priestorového správania sa objektov textúra, vzájomná vzdialenosť, veľkosť, tvar, opakovateľnosť, kontext,
- Časového správania sa hodnotia sa časové zmeny pre roztriedenie dát (poľnohospodárske plodiny, zmeny v časových cykloch vegetácie a pod.),
- Spektrálneho správania sa na báze multispektrálnych snímok a spektrálneho správania sa objektov na scéne, nakoľko rôzne typy údajov majú rôzne odrazové charakteristiky. Do tejto kategórie spadajú techniky ako "prahovanie" na základe histogramu, "per-pixel" klasifikátory.

V diaľkovom prieskume Zeme sa využívajú nasledovné tri techniky obrazovej klasifikácie:

- 1. Riadená klasifikácia,
- 2. Neriadená klasifikácia,
- 3. Objektovo založená obrazová analýza.

Riadená a neriadená klasifikácia sú najbežnejšie používané klasifikačné techniky.

5.2. Supervised classification

Pri riadenej klasifikácii sa vyberá reprezentatívna vzorka, tzv. tréningová oblasť pre každú triedu krajinnej pokrývky. Výpočtový algoritmus následne použije tieto *"tréningové oblasti"* (signatúry) na hľadanie podobných oblastí na celej snímke, pričom je každý obrazový prvok porovnávaný podľa zvoleného klasifikátora a následne je

zaradený do určitej triedy. Riadená klasifikácia je postup, ktorý sa najčastejšie používa na kvantitatívnu analýzu obrazových údajov diaľkového prieskumu Zeme. Kroky riadenej klasifikácie:

- určenie počtu tried a ich obsahu
- vytváranie tréningových oblastí, vzoriek (minimálne 10 pixlov, ideálne 100 pixlov a viac)
- kontrola kvality tréningových vzoriek dostatočne reprezentatívne a komplexné
- voľba klasifikačného algoritmu (metódy)
- vykonávanie klasifikácie
- spracovanie máp po klasifikácii a úprava
- hodnotenie presnosti klasifikácie a prezentácia výsledkov.

V rámci vytvárania tréningovej vzorky je nutné zabezpečiť z terénu dostatok podporných dát, aby boli tréningové dáta kompletné (charakterizovať všetky hľadané triedy) a reprezentatívne (hľadať typické rysy v každej triede). Trénovacie množiny môžeme vytvoriť zberom jednotlivých pixlov alebo digitalizáciou polygónov (zhluky pixlov), proces je iteratívny, čiže sa pridávajú, vymazávajú a spájanie signatúry, určujú sa štatistické charakteristiky jednotlivých tried (minimálna, maximálna, priemerná hodnota jasu v jednotlivých pásmach, smerodajná odchýlka a pod.). Podmienky riadenej klasifikácie:

ournienky hauenej klasilikacie.

- výber dostatočného počtu pixlov v každej trénovacej ploche,
- vhodná veľkosť trénovacej plochy,
- vhodná poloha trénovej plochy,
- umiestnenie trénovacích plôch bez okrajových pixlov danej plochy,
- rozmiestnenie tréningových plôch pre danú triedu osvetlené, aj neosvetlené scény, rôzny vodný obsah – rovnaké povrchy s rôznymi rádiometrickými charakteristikami,
- miera homogenity trénovacích plôch z hľadiska spektrálneho správania sa normalita rozdelenia v trénovacích plochách.

Riadená klasifikácia používa vo svojej podstate viaceré klasifikačné nástroje. Moderné softvérové balíky na klasifikáciu satelitných snímok poskytujú široký výber algoritmov, čiže matematický algoritmus ktorý na základe trénovacích údajov triedi pixely do rôznych tried. Žiadny algoritmus nie je univerzálne použiteľný vo všetkých možných prípadoch. Namiesto toho má každá metóda klasifikácie svoj vlastný rozsah. Niektoré dávnejšie používané klasifikačné nástroje riadenej klasifikácie sú:

- klasifikácia binárneho kódovania (binary encoding classification),
- klasifikátor minimálnej vzdialenosti (minimum distance),
- klasifikátor rovnobežníkov (parallelepiped classification),
- klasifikácia maximálnej pravdepodobnosti (maximum likelihood classification),
- klasifikátor Mahalanobisovej vzdialenosti,
- Random Forest Klasifikátor,
- Support Vector Machine,
- Spectral Angle Mapper,
- k-nearest neighbour (k-NN) klasifikátor,
- KD Tree KNN klasifikátor,
- Naive Bayes Algorithm,
- Ensemble Modeling a iné.

Potom, ako sú definované tréningové oblasti sa pixely snímky triedia do tried na základe klasifikárov. Rozhodovacie pravidlo je matematický algoritmus, ktorý pomocou údajov obsiahnutých v tréningovej oblasti vykonáva skutočné triedenie pixelov do rôznych tried. Existuje množstvo výkonných kontrolovaných klasifikátorov založených na štatistikách, ktoré sa bežne používajú pre rôzne aplikácie. Rozhodovacie pravidlá možno rozdeliť do dvoch typov:

- 1. Pravidlo parametrického rozhodovania: rozhodovací priestor je spojitý, pretože je založené na modeli údajov (napr. normálne rozdelenie), sem spadá napr. klasifikácia maximálnej pravdepodobnosti,
- 2. Neparametrické pravidlo rozhodovania založené na trénovacích údajoch samotných (určuje, či pixel je alebo nie je lokalizovaný vo vnútri hraníc neparametrickej signatúry). Neparametrické rozhodovacie pravidlo nie je založené na štatistike; preto je nezávislý od vlastností údajov. Ak sa pixel nachádza v hraniciach neparametrickej signatúry, potom toto rozhodovacie pravidlo priradí pixel do triedy podľa tréningovej oblasti. Neparametrické rozhodovacie pravidlo v podstate určuje, či sa pixel nachádza alebo nenachádza vo vnútri hranice neparametrického podpisu. Neparametrické kontrolované klasifikátory, ako napríklad klasifikačný a regresný strom (Classification and Regression Tree CART), Support Vecto machine (SVM) a umelá neurónová sieť (Artificial Neural Network ANN) nevytvárajú žiadne predpoklady týkajúce sa frekvenčného rozdelenia, a preto sa stávajú čoraz obľúbenejšími na klasifikáciu údajov z DPZ, ktoré majú len zriedka normálne rozdelenie.

5.2.1. Binary coding

Najprv musíme zistiť, koľko tried je potrebné klasifikovať. Ak sú potrebné iba dve triedy a všetky pixely snímky budú priradené jednej z nich, najlepšou metódou je klasifikácia binárneho kódovania. Výsledná snímka binárneho kódovania je zobrazená na Obr. 5.1. Na pôvodnej satelitnej snímke zaplaveného územia sa vykonala extrakcia informácií o vodných plochách na základe **MNDWI** (**Modified Normalized Difference Water Index**), ktorý vylepšuje zobrazenie prvkov vody a potláča šum pixlov pôdy a vegetácie. Metódou prahovania sa zobrazila binárna maska oblastí voda/ne-voda.

Napríklad v programovom prostredí ESA SNAP je tento úkon realizovaný matematickým príkazom, kde si na základe histogramového zobrazenia snímky a prahovania šedi analytik volí matematickou podmienkou zobrazenie pixlov vody/ne-vody:

If $(var_1) > 0$ and $(var_2) < 1$ then "Water" else NaN, (5.1)

Čím vznikne binárna maska s hodnotami 0 a 1 (Obr. 5.1).

5 Image Classification



c) Obr. 5.1 a) Pôvodná snímka zatopeného územia, b) MNDWI snímka, c) binárna mapa zobrazenia vody a nie vody.

Fig. 5.1 a) Original image of the flooded area, b) MNDWI image, c) binary map showing water and non water.

Source: Copernicus Sentinel data [2020]. Retrieved from Copernicus SciHub [07/12/2021], processed by FBERG TUKE

Ak potrebujeme priradiť pixely viac ako do dvoch tried, potom pre výber správnej metódy je potrebné analyzovať pozíciu tried v priestore viacrozmerných prvkov na základe rozhodovacieho pravidla – klasifikátora (Obr. 5.2). Tým sú postupne zaraďované prvky obrazu predstavujúce nejakú triedu (zhluk) do viacrozmenrého príznakového súboru. V klasifikácii sa bežne používa viac pásem -3 až 4 spektrálne pásma. Pixely jednolivých tried vytvárajú zhluky so svojimi stredmi (centroidmi). Obrazové prvky jednej triedy nemajú rovnaké hodnoty, ale vytvárajú zhluk pixelov s určitou variabilitou. Napr. vegetečný kryt sa líší druhovým zložením, obsahom vody, či zdravotným stavom.

5 Image Classification



Obr. 5.2 Výber vhodného algoritmu. **Fig. 5.2** Selecting a suitable algorithm. Source: own processing

5.2.2. Minimum distance classifier

Klasifikátor minimálnej vzdialenosti je najjednoduchšia metóda klasifikácie, ktorá počíta vzdialenosť neznámeho pixelu od stredu, resp. od priemeru každej triedy v spektrálnom priestore (Obr. 5.3). Pre kontrolovanú klasifikáciu sú tieto skupiny tvorené hodnotami pixelov v rámci tréningových polí definovaných analytikom. Každý klaster môže byť reprezentovaný svojim ťažiskom, často definovaným ako jeho stredná hodnota. Keďže nepriradené pixely sa zvažujú na priradenie do jednej z niekoľkých tried, vypočíta sa viacrozmerná vzdialenosť ku každému ťažisku klastra a pixel sa potom priradí k najbližšiemu klastru. Klasifikácia teda pokračuje tak, že sa vždy používa "*minimálna vzdialenosť* " od daného pixelu k ťažisku klastra definovanému trénovacími dátami ako spektrálny prejav informačnej triedy. Klasifikátory minimálnej vzdialenosti sú priamou koncepciou a implementáciou, ale nie sú široko používané pri práci v diaľkovom prieskume. Vo svojej najjednoduchšej forme klasifikácia minimálnej vzdialenosti nie je vždy presná; neexistuje žiadne opatrenie na prispôsobenie sa rozdielom vo variabilite tried a niektoré triedy sa môžu na svojich okrajoch prekrývať.



Fig. 5.3 Minimum distance classifier.

Source: www.50northspatial.org/supervised-image-classification-using-minimum-distance-algorithm/

Na obrázku vľavo je znázornená situácia, keď klasifikácia nezahŕňa možnosť neklasifikovaných pixelov. Obr. 5.3 vpravo zobrazuje prípad s neklasifikovanými pixelmi vo výsledkoch klasifikácie. Sivé šipky ukazujú vzdialenosť od zeleného bodu A a červeného bodu B k stredom zelenej a červenej triedy. Oba body sú bližšie k stredu zelenej triedy. Preto body A a B budú klasifikované podľa minimálnej vzdialenosti k zelenej triede. Tu vidíme princíp determinovania príslušnosti k triede a zdroj chýb v klasifikácii.

Euklidovská vzdialenosť je najbežnejšou metrikou vzdialenosti používanou v súboroch údajov s malými vzdialenosťami. Euklidová vzdialenosť je vyjadrená ako:

$$d = \sqrt{\sum_{i} (X_i - Y_i)^2} ,$$
 (5.2)

kde X a Y sú *m*-rozmerné vektory označené ako $x = (x_1, x_2, ..., x_m)$ a $y = (y_1, y_2, ..., y_m)$ predstavujúce hodnoty atribútov *m* dvoch tried.

5.2.3. Mahalanobis distance classifier

Klasifikátor Mahalanobisovej vzdialenosti je podobný ako minimálna vzdialenosť, až na to, že v rovnici je použitá kovariančná matica. Mahalanobisova vzdialenosť je štatistická funkcia vzdialenosti. Mahalanobisova vzdialenosť je miera vzdialenosti medzi dvoma bodmi v priestore definovanom dvoma alebo viacerými korelovanými premennými. To znamená, že vzdialenosť Mahalanobis berie do úvahy korelácie v rámci súboru údajov medzi premennou. Ak existujú dve nekorelované premenné, Mahalanobisova vzdialenosť medzi bodmi premennej v 2D grafe rozptylu je rovnaká ako Euklidovská vzdialenosť. Z matematického hľadiska sa Mahalanobisova vzdialenosť rovná euklidovskej vzdialenosti, keď kovariančná matica je jednotkovou maticou. To je presne ten prípad, ak sú dva stĺpce štandardizovanej matice údajov ortogonálne. Mahalanobisova vzdialenosť závisí od kovariančnej matice atribútu a primerane zohľadňuje korelácie. Tu sa kovariančná matica využíva na korekciu účinkov krížovej kovariancie medzi dvoma zložkami náhodnej premennej. Mahalanobisová vzdialenosť je definovaná ako:

$$\mathbf{D} = (\mathbf{X} - \mathbf{M}_c)^{\mathrm{T}} * (\mathbf{COV}_c)^{-1} * (\mathbf{X} - \mathbf{M}_c), \qquad (5.3)$$

kde *D* je Mahalanobisová vzdialenosť, *c* je konkrétna trieda, **X** je meraný vektor kandidátskeho pixlu, \mathbf{M}_{c} je stredný vektor tréningovej oblasti (signatúry) triedy *c*, **COV**_c je kovariančná matica pixlov v signatúre triedy *c*, (**COV**_c)⁻¹ je inverzná matica, T je transponovaná fukcia.

5.2.4. Parallelepiped classification

Najprv je potrebné zistiť, či sa triedy zhlukov prekrývajú. V prípade, že sa spektrálne charakteristiky v priestore zhlukov neprekrývajú, možno použiť klasifikátor pravouholníkov (*parallelepiped classification*) (Obr. 5.4). To sa často stáva, keď priraďujeme pixely k malému počtu tried, ktoré patria k zásadne odlišným typom povrchov. Napríklad, keď klasifikujeme vodné plochy, vegetáciu, pôdy, povrchy umelých materiálov, skaly. Zvyčajne majú tieto typy objektov veľmi rozdielnu spektrálnu odrazovú kapacitu. Ak vedieme rovnobežné línie pixlov s maximálnou a minimálnou hodnotou v každom pásme, dostaneme v dvoch pásmach štvorec alebo obdĺžnik, ktorý bude vymedzovať oblasť, vo vnútri ktorej budú patriť pixle do jednej kategórie. Pixely ležiace vo vnútri pravouholníkov sú označené tým pádom do jednej triedy.



Obr. 5.4 Klasifikátor pravouholníkov. **Fig. 5.4** Parallelepiped classification. Source: Elsharkawy, 2016

5.2.5. Maximum likelihood classification

V praxi sa častokrát stretávame s tým, že triedy do ktorých klasifikujeme obraz, vykazujú prirodzené variácie vo svojich spektrálnych vzoroch. Ďalšiu variabilitu pridávajú efekty oparu, topografického tieňovania, systémového šumu a efekty zmiešaných pixelov. Výsledkom je, že snímky z DPZ zriedkavo zaznamenávajú spektrálne čisté triedy; typickejšie zobrazujú rozsah jasu v každom pásme. Doteraz zvažované klasifikačné stratégie nezohľadňujú variácie, ktoré môžu byť prítomné v rámci spektrálnych kategórií, a neriešia problémy, ktoré vznikajú, keď sa frekvenčné distribúcie spektrálnych hodnôt

zo samostatných kategórií prekrývajú. Klasifikátor maximálnej pravdepodobnosti (*Maximum likelihood - ML*) je najbežnejšou riadenou klasifikáciou používanou v DPZ. Dá sa opísať ako štatistický prístup k rozpoznávaniu vzorov, kde sa vypočíta pravdepodobnosť pixelu patriaceho do každej z vopred definovaných množín tried; preto je pixel priradený do triedy s najvyššou pravdepodobnosťou. Klasifikátor maximálnej pravdepodobnosti je založený na gaussovom odhade fukcie pravdepodobnosti každej triedy. Preto za tohto predpokladu a s použitím stredného vektora spolu s kovariančnou maticou možno úplne opísať distribúciu vzoru odpovede podľa kategórie. Vzhľadom na tieto parametre je možné vypočítať štatistickú pravdepodobnosť danej hodnoty pixelu, že je členom konkrétnej triedy. Pixel by bol priradený k triede s najvyššou hodnotou pravdepodobnosti, alebo by bol označený ako *"neznámy*", ak sú všetky hodnoty pravdepodobnosti pod hranicou nastavenou používateľom (Obr. 5.5).



Obr. 5.5 Klasifikátor maximálnej pravdepodobnosti. Hodnoty x-vysoká pravdepodobnosť, že patria do triedy A, y-vysoká pravdepodobnosť, že patria do triedy B, z-hodnoty môžu patriť aj do triedy A, alebo B.

Fig. 5.5 Maximum likelihood classifier. Values x-high probability of belonging to class A, y-high probability of belonging to class B, z-values can also belong to class A or B. Source: Shakya et al., 2021



Tab. 5.1 Comparison of advantages and disadvantages of classification methods. Source: UKEssays, 2018

Algoritmus	Výhody	Nevýhody				
Metóda pravouholníkov						
Canal B	Výpočty sú rýchle a jednoduché, čím sa skracuje spracovanie. Nezávisí od normálneho rozdelenia.	Kedže rovnobežnosteny majú rohy, tak pixely, ktoré sú v skutočnosti spektrálne dosť vzdialené od strednej hodnoty signatúry, môžu byť klasifikované.				
Metóda min. vzdialenosti						
	bližšie k jednému alebo druhému priemeru vzorky, neexistujú žiadne neklasifikované pixely.	Pre pixely, ktoré by mali byť neklasifikované, je tento problém zmiernený prahovaním pixelov, ktoré sú najďalej od priemeru svojich tried.				
Carter Ca	Najrýchlejšie rozhodovacie pravidlo na výpočet, s výnimkou metódy pravouholníkov.	Nezohľadňuje variabilitu tried.				
Metóda Mahalanobisovej						
	Na rozdiel od minimálnej vzdialenosti alebo pravouholníka zohľadňuje	Má tendenciu preklasifikovať signatúry s relatívne veľkými hodnotami v kovariančnej matici.				
	variabilitu tried.	Pomalší výpočet ako pri pravouholníkoch alebo minimálnej vzdialenosti.				
Metóda maximálnej pravdepodobnosti						
	Najpresnejší z klasifikátorov.	Rozsiahla rovnica, ktorej výpočet trvá dlho.				
Canal B	Berie do úvahy variabilitu tried pomocou kovariančnej matice, rovnako ako Mahalanobisova vzdialenosť	Maximálna pravdepodobnosť je parametrická, čo znamená, že sa vo veľkej miere spolieha na anormálne rozdelenie údajov v každom vstupnom pásme.				

5.2.6. Random Forest Classifier

Algoritmus Random Forest (RF) je kontrolovaná klasifikácia a regresný algoritmus, ktorý sa používa posledých 20 rokov. Je charakteristický vynikajúcimi výsledkami klasifikácie a rýchlosti spracovania. Spadá do kategórie strojového učenia. RF klasifikátor poskytuje spoľahlivé klasifikácie pomocou predpovedí odvodených zo súboru rozhodovacích stromov. Okrem toho možno tento klasifikátor použiť na výber a zoradenie premenných, ktoré majú najväčšiu schopnosť rozlišovať medzi cieľovými triedami. Je to dôležitá výhoda vzhľadom na to, že vďaka vysokej dimenzii údajov z DPZ je výber najrelevantnejších premenných časovo náročnou a subjektívnou úlohou, náchylnou k chybám.

RF klasifikátor je súborový klasifikátor, ktorý používa sadu **CART** (**Classification and Regression Tree**) na predikciu. Stromy sa vytvárajú nakreslením podmnožiny tréningových vzoriek prostredníctvom výmeny (prístup vrecovania). To znamená, že tú istú vzorku možno vybrať viackrát, zatiaľ čo iné nemožno vybrať vôbec. RF klasifikátor možno úspešne použiť na klasifikáciu viaczdrojových údajov z diaľkového prieskumu Zeme a geografických údajov, najmä kvôli jeho výpočtovej schopnosti a preto, že pomáha obrazovým analytikom pri optimalizovaní klasifikačného modelu použitím iba tých súborov vstupných údajov, ktoré sú identifikované ako dôležité pre cieľ klasifikácie.

RF algoritmus je kombináciou stromových prediktorov tak, že každý strom závisí od hodnôt náhodného vektora vzorkovaného nezávisle a s rovnakým rozdelením pre všetky stromy v lese. RF klasifikácia je súborová klasifikácia, ktorá využíva nielen jeden, ale mnoho klasifikátorov. V skutočnosti sú v klasifikácii RF zabudované stovky klasifikátorov a ich rozhodnutia sa zvyčajne kombinujú viacnásobným hlasovaním. Predpokladom je, že kombinovanie klasifikátorov súboru je často presnejšie ako ktorýkoľvek z klasifikátorov súboru, čím sa predchádza konfliktom medzi podmnožinami prvkov. V dôsledku toho sa klasifikácia RF široko používa pri spracovaní snímok DPZ. Spoločným prvkom všetkých týchto postupov je, že pre k-tý strom sa generuje náhodný vektor θ_k nezávisle od predchádzajúcich náhodných vektorov θ_1 , ..., θ_{k-1} , ale s rovnakým rozdelením; strom sa vyvíja na základe trénovacej množiny θ_k , výsledkom čoho je klasifikátor h (x, θ_k), kde x je vstupný vektor. Klasifikátor pozostáva z viacerých stromov konštruovaných systematicky pseudonáhodným výberom podmnožín komponentov znakového vektora, to znamená, že stromy sú konštruované v náhodne vybraných podpriestoroch, pričom zachovávajú najvyššiu presnosť trénovacích údajov a zlepšujú presnosť zovšeobecňovania, keď rastie komplexnosť. Prostredníctvom procesu vrecovania, keď klasifikácia RF spôsobí, že strom rastie, používa najlepšie rozdelenie náhodnej podmnožiny vstupných funkcií alebo prediktívnych premenných pri delení každého uzla, namiesto použitia najlepších delených premenných. Preto, hoci oslabuje silu každého jedného stromu, znižuje koreláciu medzi stromami a chybu zovšeobecnenia. Vzhľadom na to, že stromy RF klasifikátora rastú bez orezávania, čas na generovanie modelu sa výrazne nepredĺži.

Daný je súbor klasifikátorov $h_1(\mathbf{x})$, $h_2(\mathbf{x})$, ..., $h_k(\mathbf{x})$, s trénovaciou množinou náhodne vybranou z rozdelenia náhodného vektora Y. **X** definuje okrajovú funkciu ako:

$$mg\left(\mathbf{X},Y\right) = av_k I(h_k(\mathbf{X}) = Y) - \max_{j \neq Y} av_k I(h_k(\mathbf{X}) = j) , \qquad (5.4)$$

kde I (·) je funkcia indikátora.

Rozdiel meria mieru, do akej priemerný počet hlasov v X, Y pre správnu triedu prevyšuje priemerný počet hlasov pre ktorúkoľvek inú triedu. Čím väčšie je rozpätie, tým väčšia je dôvera v klasifikáciu. Chyba zovšeobecnenia je daná vzťahom:

$$PE^* = P_{\mathbf{X},Y}(mg(\mathbf{X},Y) < 0).$$
(5.5)

Pre každú novú trénovaciu množinu, ktorá sa vygeneruje, aby strom rástol, sa náhodne vylúči jedna tretina vzoriek, ktoré sa nazývajú "vzorky z vrecka" (**Out-of-Bag – OOB**). Zostávajúce vzorky (vo vrecku) sa použijú na stavbu stromu. Tieto vzorky OOB možno použiť na vyhodnotenie výkonnosti modelu a bolo dokázané, že odhady OOB sú neskreslené.

V klasifikátore *Random Forest* - čím je vyšší počet stromov v lese, tým je väčšia presnosť výsledkov. RF algoritmus funguje ako veľká zbierka dekorelovaných prvkov rozhodovacích stromov:

- vytvorí sa náhodná podmnožina spektrálnych podpisov,
- vytvorí sa rozhodovací strom pre každú podmnožinu,
- zohľadní sa počet hlasov pre výstup každého rozhodovacieho stromu, výsledkom je výstup s maximálnym počtom hlasov (Obr. 5.6 a 5.7).



Obr. 5.6 Jednoduchá ilustrácia regresných modelov rozhodovacích stromov, znázorňujúca stavebné bloky RF algoritmu (A). Random Forest kombinuje viacero náhodných rozhodovacích stromov do jedného výstupu (B). Stromy generované v náhodnom lese sa neinterpretujú jednotlivo, ale používajú sa kolektívne pri predpovedaní premennej odozvy.

Fig. 5.6 A simple illustration of decision tree regression models, showing the building blocks of the RF algorithm (A). Random Forest combines multiple random decision trees into a single output (B). The trees generated in Random Forest are not interpreted individually, but are used collectively in predicting the response variable. Source: Shah et al., 2019

115



Obr. 5.7 Random forest klasifácia na snímkach Landsat - 5 TM. **Fig. 5.7** Random forest classification on Landsat-5 TM images. Source: Lu et al., 2014

5.2.7. Support Vector Machine

Support vector machine (SVM) je ďalším klasifikačným nástrojom riadenej klasifikácie strojového učenia a zároveň neparametrického štatistického rozhodovania regresnými analýzami. Mnohými analytikmi je preferovaný, nakoľko poskytuje značnú presnosť s menším výpočtovým výkonom. SVM možno použiť pre regresné aj klasifikačné úlohy v DPZ.

Cieľom algoritmu SVM je nájsť optimálnu separačnú nadrovinu v N-rozmernom priestore (N – počet prvkov), ktorá zreteľne klasifikuje dátové súbory. SVM zameriava rozhodnutia o klasifikácii na hranici medzi triedami a nie na základe priemeru a odchýlky tried, pričom sa pokúša rozdeliť priestor prvkov pomocou nadroviny tak, že každá trieda bude sídliť úplne na svojej vlastnej strane roviny. Termín optimálna separačná nadrovina sa používa na označenie rozhodovacej hranice, ktorá minimalizuje nesprávne klasifikácie, získané v tréningovom kroku. Učenie sa vzťahuje na iteratívny proces hľadania klasifikátora s optimálnou rozhodovacou hranicou na oddelenie trénovacích vzorov (v potenciálne vysokorozmernom priestore) a potom na oddelenie simulačných údajov v rovnakých konfiguráciách (dimenziách).

Vo svojej najjednoduchšej forme sú SVM lineárne binárne klasifikátory, ktoré priraďujú danej testovacej vzorke triedu z jedného z dvoch možných označení. Inštanciou dátovej vzorky, ktorá sa má označiť v prípade klasifikácie diaľkového snímania, je zvyčajne individuálny pixel odvodený z multispektrálneho alebo hyperspektrálneho obrazu. Takýto pixel je reprezentovaný ako vzorový vektor a pre každé obrazové pásmo pozostáva zo sady numerických meraní. Prvky charakteristického vektora môžu zahŕňať aj iné merania diskriminačných premenných založené na priestorových vzťahoch pixelov, ako je textúra.



Obr. 5.8 Support vector machine klasifikácia. **Fig. 5.8** Support vector machine classification. Source: García-Gonzalo et al., 2016

Obr. 5.8 a 5.9 ilustrujú jednoduchý scenár dvojtriedneho separovateľného klasifikačného problému v dvojrozmernom vstupnom priestore. Dôležitým zovšeobecňujúcim aspektom SVM je, že pri popise a špecifikácii oddeľujúcej nadroviny sa často nepoužívajú všetky dostupné príklady klasifikácie. Podmnožina bodov, ktoré ležia na okraji (nazývané podporné vektory), sú jediné, ktoré definujú nadrovinu maximálneho okraja.

Implementácia lineárneho SVM predpokladá, že dáta multispektrálnych vlastností sú lineárne oddeliteľné vo vstupnom priestore. V praxi sa dátové body rôznych tried (klastrov) prekrývajú. To sťažuje lineárnu separovateľnosť, pretože základné lineárne rozhodovacie hranice často nestačia na klasifikáciu vzorov s vysokou presnosťou. Okrem toho typické problémy diaľkového prieskumu zvyčajne zahŕňajú identifikáciu viacerých tried (viac ako dvoch).



Obr. 5.9 Nadroviny v 2D a v 3D priestore.

Fig. 5.9 Hyperplanes in 2D and 3D feature space.

Source: towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47

Na oddelenie týchto dvoch tried údajových bodov existuje veľa možných nadrovín, ktoré možno vybrať. Naším cieľom je nájsť rovinu, ktorá má maximálnu rezervu, t. j. maximálnu vzdialenosť medzi dátovými bodmi oboch tried. Maximalizácia vzdialenosti okraja poskytuje určité posilnenie, budúce dátové body možno klasifikovať s väčšou istotou.

Nadroviny sú hranice rozhodovania, ktoré pomáhajú klasifikovať dátové body. Dátové body spadajúce na obe strany nadroviny možno priradiť rôznym triedam. Rozmer nadroviny taktiež závisí od počtu prvkov. Ak je počet vstupných prvkov 2, potom je nadrovina len čiara. Ak je počet vstupných prvkov 3, potom sa nadrovina stane 2D rovinou.

Podporné vektory sú determinované dátovými bodmi, ktoré sú bližšie k nadrovine (Obr. 5.8) a ovplyvňujú polohu a orientáciu nadroviny. Pomocou týchto podporných vektorov maximalizujeme okraj klasifikátora. Vymazaním podporných vektorov sa zmení poloha nadroviny.

Myšlienku klasifikátorov SVM možno opísať takto: predpokladajme, že existuje m pozorovaní (tréningová množina) (x_i, y_i), i = 1, 2, ..., m, kde:

$$\mathbf{x}_{\mathbf{i}}^{\mathsf{T}} = (x_{i1}, \dots, x_{id}) \in \mathbb{R}^d \tag{5.6}$$

je *d*-rozmerná vlastnosť vzorky a *i* je jej kódovaná značka triedy. Ak je vzorka x_i priradená pozitívnej triede, potom y_i je +1, ak negatívnej triede, potom y_i je -1. Túto tréningovú množinu možno rozdeliť nadrovinou $\mathbf{w}^T \mathbf{x}_i + b = 0$, kde \mathbf{w} je váhový vektor. Vzťahy pre určenie oboch okrajových rovín H_1 a H_2 sú:

$$H_1: (\mathbf{w}^{\mathrm{T}}\mathbf{x}_{\mathbf{i}} + b) = +1$$

$$H_2: (\mathbf{w}^{\mathrm{T}}\mathbf{x}_{\mathbf{i}} + b) = -1$$
(5.7)

Správne klasifikované body teda spĺňajú nerovnosť:

$$y_i(\mathbf{w}^{\mathrm{T}}\mathbf{x}_i + b) \ge 1 \tag{5.8}$$

pre **x**_i, *i* = 1, 2, ..., *m*.

Vzdialenosť M medzi okrajovými nadrovinami (okrajmi) je určená ako:

$$M = \frac{2}{\|\mathbf{w}\|} \tag{5.9}$$

Akékoľvek tréningové vzorky dopadajúce na nadroviny H_1 a H_2 definujúce okraj sa nazývajú podporné vektory (support vectors) (Obr. 5.8).

SVM klasifikátor je v oblasti DPZ obľúbený vďaka svojej schopnosti úspešne zvládnuť malé súbory trénovacích údajov, ktoré často poskytujú vyššiu presnosť klasifikácie ako tradičné metódy. Podľa tejto schémy SVM algoritmy minimalizujú chybu klasifikácie neviditeľných údajov bez predchádzajúcich predpokladov o pravdepodobnosti rozloženia údajov. Štatistické techniky, ako je odhad maximálnej pravdepodobnosti, zvyčajne predpokladajú, že distribúcia údajov je a priori známa.

5.2.8. Spectral Angle Mapper SAM

Algoritmus Spectral angle mapper (SAM) je založený na ideálnom predpoklade, že jeden pixel v DPZ snímke predstavuje jeden pixel na zemskom povrchu, ktorý je možné jednoznačne priradiť iba k jednej triede (Obr. 5.10). Algoritmus SAM je jednoducho založený na meraní spektrálnej podobnosti medzi dvoma spektrami. Spektrálnu podobnosť možno získať zvážením každého spektra ako vektora v q-rozmernom

priestore, kde q je počet pásiem. Algoritmus SAM určuje spektrálnu podobnosť medzi dvoma spektrami výpočtom uhla medzi nimi, pričom sa považujú za vektory v priestore s rozmermi rovnajúcimi sa počtu pásem snímky.



Obr. 5.10 Na výpočet SAM musí existovať referenčný vektor ako podklad na vyhodnotenie rozdielu spektrálnych uhlov medzi cieľovým bodom a referenčným spektrom. V dvojrozmernom prípade je každé dvojbodové spektrum bodom v priestore pásma i oproti pásmu j. Uhol α popisuje uhlové oddelenie dvoch spektier.

Fig. 5.10 To calculate the SAM, a reference vector must exist as a basis for evaluating the difference in spectral angles between the target point and the reference spectrum. In the two-dimensional case, each two-point spectrum is a point in the space of band i versus band j. The angle α describes the angular separation of the two spectra.

Source: http://vision.gel.ulaval.ca/~jflalonde/cours/4105/h15/tps/results/projet/SASOJ/index.html

Spektroskopia meria intenzitu žiarenia a energiu interakcie medzi svetlom a hmotou, ktoré určujú jeho molekulárnu štruktúru. V absorbčnej spektroskopii, zlúčenina, ktorá interaguje so svetlom sa správa ako pasívny prvok. Absorbuje časť emitovaných fotónov v závislosti od ich vlnovej dĺžky, aby sa vytvorili takzvaný spektrálny podpis. Žiarenie, ktoré nie je absorbované môže prenikať prostredím, alebo byť difúzne odrazené. Spektrum odrazeného žiarenia sa využíva na detekciu povrchu, resp. na klasifikáciu.

SAM algoritmus generalizuje geometrickú interpretáciu do *n*-rozmerného priestoru. SAM determinuje podobnosť aplikovaním nasledovného vzťahu:

$$\alpha(x,y) = \cos^{-1} \frac{\sum_{i=1}^{n} x_i y_u}{\sqrt{\sum_{i=1}^{n} x_i^2} * \sqrt{\sum_{i=1}^{n} y_i^2}} , \qquad (5.10)$$

kde

x je spektrálny podpis vektora pixla na snímke,

y je spektrálny podpis vektora trénigovej oblasti,

n je počet pásem snímky.

Preto pixel patrí do triedy s najnižším uhlom, ak:

$$x \in C_k \Leftrightarrow \alpha(x, y_k) < \alpha(x, y_j) \forall k \neq j,$$
(5.11)

kde

 C_k je trieda krajinnej pokrývky, y_k je spektrálny podpis triedy k, y_j je spektrálny podpis triedy j. Aby sa z klasifikácie vylúčili pixely pod touto hodnotou, je možné definovať prahovú hodnotu *T_i* ako:

$$x \in C_k \iff \alpha(x, y_j) \forall k \neq j$$
(5.12)

a zároveň:

$$\alpha(x, y_k) < T_i. \tag{5.13}$$

Na výpočet SAM musí existovať referenčný vektor ako základ pre vyhodnotenie rozdielu spektrálnych uhlov medzi cieľovým bodom a referenčným spektrom. Bežný prístup k odhadu tohto uhla súvisí s nájdením spektier koncového člena z trénovacej množiny, ktorá je tu modifikovaná nahradením spomínaného referenčného spektra prvou hlavnou zložkou získanou z trénovacej množiny. To znamená, že najprv vypočítame základnú analýzu komponentov pre spektrá trénovacieho súboru, potom pristúpime nájdením zástupcu jednotlivých skupín k odhadu spektrálneho uhla odlišného od uvedených spektier a cieleného pixelového spektra v štádiu testovania.

5.2.9. k-Nearest Neighbours (kNN)

Algoritmus **kNN** (**k-Nearest Neighbors**) je metóda učenia príslušnosti k triede, založená na princípe klasifikácie prvkov na základe najbližších spektrálnych informácií k tréningovej vzorke v priestore zdrojových dát (*k* je kladné celé číslo, zvyčajne malé) a *"väčšinového hlasovania*". Tieto dáta hrajú dôležitú úlohu v priestorových predpovediach parametrami algoritmu **kNN** (Obr. 5.11). **kNN** je bežný klasifikačný nástroj používaný v aplikáciách DPZ a široko využívaný na mapovanie napr. vyhoretých oblastí a povodní. **kNN** je neparametrický algoritmus strojového učenia, ktorý nerobí žiadne predpoklady týkajúce sa hlavného súbora údajov. Je to dôležité pri klasifikácii procesov zmien v území, napr. ako sú povodne a požiare, pre ktoré sú len malé alebo žiadne predchádzajúce znalosti o distribúcii údajov. V algoritme **kNN** je pixel, ktorého trieda je neznáma, zaradený do triedy, ktorá je popísaná spektrálne najbližším susedom, ktorého identitu poznáme.



Fig. 5.11 Principle of the nearest neighbour algorithm. Source: towardsdatascience.com/to-dance-or-not-to-dance-the-machine-learning-approachdecc2a7782b5

Ak k = 3, neznámy pixel je klasifikovaný na základe 3 najbližších susedných pixlov. Ak 3 susedné pixle sú z rôznych tried, neznámemu pixelu bude priradená trieda, z ktorej je viac pixelov. V tomto prípade je to zelená trieda. Ak je parameter k = 7, vyššiu početnosť majú pixely červenej triedy, preto neznámy pixel bude zaradený do červenej triedy.

Pre aplikáciu klasifikácie snímok SAR sú príkladmi tréningových oblastí obrazové údaje pixelov zvolené používateľom, pričom každý má označenie triedy. Tréningová fáza algoritmu pozostáva len z ukladania obrazových dát a tried trénovacích vzoriek. Vo fáze klasifikácie je neoznačený pixel klasifikovaný priradením označenia, ktoré je najčastejšie medzi *k* tréningovými vzorkami, ktoré sú najbližšie k pixelu. Tu je *k* užívateľom definovaná konštanta. Bežne používané metriky vzdialenosti zahŕňajú Euklidovskú vzdialenosť, Mahalanobisovu vzdialenosť a Diagonálnu Mahalanobisovu vzdialenosť. Presnosť klasifikácie **kNN** sa často môže výrazne zlepšiť, ak sa metrika vzdialenosti naučí pomocou špecializovaných algoritmov, ako je napr. analýza komponentov najbližšej oblasti s veľkým rozpätím alebo susedstva.

Nevýhoda základnej klasifikácie "väčšinového hlasovania" nastáva, keď je rozdelenie tried skreslené. To znamená, že príklady častejšej triedy majú tendenciu dominovať v predpovedi nového príkladu, pretože majú tendenciu byť bežné medzi najbližšími susedmi kvôli ich veľkému počtu. Na prekonanie tohto problému sú zavedené rôzne druhy váhových funkcií. Cieľom váhových funkcií je spôsobiť, aby vzdialení susedia mali menší vplyv na väčšinové hlasovanie ako bližší susedia.

Keď sa nájde *k* najbližších susedov testovanej vzorky, možno ich vyhodnotiť pomocou rôznych metód váženia. Pre každý susedný pixel sa hmotnosť pixelu pripočíta k celkovej hmotnosti triedy tohto pixelu. Na konci vyhráva trieda s najväčšou celkovou hmotnosťou. Bežne používané váhové funkcie zahŕňajú zlomok, schody, inverznú vzdialenosť a inverznú štvorcovú vzdialenosť.

5.3. Unsupervised classification

Neriadená klasifikácia je taká, kde sú výsledky (zoskupenia pixelov so spoločnými charakteristikami) založené na softvérovej analýze snímky bez toho, aby používateľ poskytol tréningové vzorky. Softvér používa techniky na určenie, ktoré pixely spolu súvisia a zoskupuje ich do tried. Používateľ môže špecifikovať, ktorý algoritmus bude softvér používať a zároveň aj požadovaný počet výstupných tried, ale inak používateľ neovplyvní proces klasifikácie. Používateľ však musí poznať oblasť, ktorá sa klasifikuje, nakoľko zoskupenia pixelov so spoločnými charakteristikami vytvorené počítačom sa musia týkať skutočných prvkov na zemi (ako sú mokrade, zastavané oblasti, ihličnaté lesy, atď.). Dáta sú rozdeľované do tried na základe samotných dát. Proces je založený na automatickej identifikácii a priradení obrazových pixelov k spektrálnym zoskupeniam. Zohľadňuje iba merania spektrálnej vzdialenosti a zahŕňa minimálnu interakciu používateľa. Tento prístup vyžaduje následnú interpretáciu po klasifikácii. Používateľ často určuje počet tried, ktoré sa majú nájsť, a tieto triedy sú anonymné – t. j. je na používateľovi, aby definoval ich fyzický význam.

Vo všeobecnosti neriadená klasifikácia vyžaduje, aby používateľ špecifikoval nasledujúce parametre:

- počet tried,
- počet pásiem,
- spektrálnu vzdialenosť alebo polomer v spektrálnej vzdialenosti,
- parametre spektrálnej priestorovej vzdialenosti pri zlučovaní zhlukov (cluster).

Neriadená klasifikácia začína spektrálnym grafom celej snímky, na ktorom sa spustí požadovaný počet tried. Klasifikácia prebieha počiatočným oddelením priestoru do oblastí spojených s každou triedou, po ktorom nasleduje iteratívna modifikácia hraníc tried s ohľadom na štatistiku tried ako je priemer, rozptyl, štandardná odchýlka, minimálne a maximálne hodnoty.

Základným predpokladom neriadenej klasifikácie je, že pixely patriace do jednej triedy sú vo viacrozmernom priestore blízko seba a naopak pixely odlišných skupín s iným spektrálnym správaním sa sú naopak dobre separované. K vymedzeniu odlišných skupín – zhlukov sa využívajú zhlukové analýzy na princípe iteračných výpočtov. Výsledkom prvej fázy sú informačné triedy, ktorým sa následne prisúdi informačný obsah. Čiže najpv sa určia spektrálne separované kategórie a následne sa určí ich informačná hodnota. Poloha každého zhluku (klastera) je definovaná jeho ťažiskom – centroidom. Cieľom je následne minimalizovať vzdialenosť jednotlivých pixelov daného zhluku od jeho ceintroidu a maximalizovať vzdialenosť medzi inými centroidmi. Okrem polohy centroidu je zadaná aj miera homogenity – násobky smerodajnej odchýlky.

Zhluková analýza (alebo klastrovanie) je klasifikácia objektov do rôznych skupín, alebo presnejšie, rozdelenie súboru údajov do podmnožín (klastrov alebo tried), takže údaje v každej podmnožine (v ideálnom prípade) zdieľajú nejakú spoločnú črtu – často blízkosť podľa nejakej definovanej vzdialenosti. Klastrovanie údajov je bežnou technikou štatistickej analýzy údajov, ktorá sa používa v mnohých oblastiach vrátane strojového učenia, dolovania údajov, rozpoznávania vzorov, analýzy obrazu a bioinformatiky. Výpočtová úloha klasifikácie súboru údajov do k zhlukov sa často označuje ako *k*-zhlukovanie.

Postupnosť neriadenej klasifikácie:

1. definovanie počtu zhlukov (klastrov) – minimálny a maximálny počet tried,

- 2. definovanie počiatočnej hodnoty centroidu pre každý zhluk,
- 3. priradenie pixelov k zhlukom ku ktorým majú v príznakovom priestore najbližšie,
- 4. výpočet centroidu pre každý zhluk na základe prirodzených pixelov,
- 5. opakovanie kroku 3 a 4 pokiaľ sa poloha zluku alebo počet pixelov v zhluku výrazne nezmení,
- 6. priradenie významu tzv. stabilnému zhluku,
- 7. tvorba informačných tried.

Metódami neriadenej klasifikácie sú Analýza hlavných komponentov (PCA) a analýza nezávislých komponentov (ICA). Vo svojich najjednoduchších formách predpokladajú, že pozorované údaje môžu byť reprezentované lineárnou kombináciou niektorých neznámych skrytých faktorov, nazývaných zdroje a príčiny.

5.3.1. K-means classifier

K-means klasifikátor je najjednoduchším nástrojom neriadenej klasifikácie. Ako rozhodovacie pravidlo je určená pozmenená metóda najbližšieho suseda, kde vzdialenosť medzi stredmi jednotlivých zhlukov je hodnotená rôznymi mierami vzdialenosti. Každý pozorovaný pixel je priradený do takého zhluku, ku ktorému priemerovaného pixlu má v analyzovanom priestore najbližšie. Nástroj na zhlukovanie k-means implementovaný napr. v SNAP je schopný pracovať s ľubovoľne veľkými scénami. Vzhľadom na počet klastrov k je základný algoritmus (Obr.5.12):

- 1. náhodne vybratie pixelov, ktorých vzorky definujú počiatočné stredy klastrov,
- 2. priradí sa každý pixel najbližšiemu stredu zhluku, ako je definovaný euklidovskou vzdialenosťou,
- 3. prepočíta stredy klastrov ako aritmetický priemer všetkých vzoriek zo všetkých pixelov v klastri,
- 4. opakuje kroky 2 a 3, kým nie je splnené konvergenčné kritérium.

Kritérium konvergencie je splnené, keď je prekročený maximálny počet opakovaní zadaný používateľom, alebo keď sa stredy klastrov medzi dvoma iteráciami nezmenili. Tento algoritmus by mal byť primárnou voľbou na vykonávanie klastrovej analýzy. Tento algoritmus sa dôrazne odporúča na analýzu veľkých scén.



Fig. 5.12 The result of the K-means algorithm - from the 0th to the 14th iteration. Source: towardsdatascience.com/clustering-in-geospatial-applications-which-model-should-you-use-59a039332c45

5 Image Classification

Výsledok klastrovej analýzy sa zapíše do pásma s názvom *class_indices* (Obr. 5.13). Hodnoty v tomto pásme označujú indexy tried, kde hodnota "O" sa týka prvého zoskupenia, hodnota "1" sa týka druhého zoskupenia atď. Indexy tried sú zoradené podľa počtu členov v príslušnom zoskupení. klaster, tj index triedy "O" sa vzťahuje na klaster s najväčším počtom členov.

Indexové kódovanie je pripojené k pásmu *class_indices*, ktoré je možné upravovať v okne manipulácie s farbami. Je možné zmeniť označenie a farbu spojenú s indexom triedy. V posledných stĺpcoch okna manipulácie s farbami je uvedené umiestnenie stredov klastrov. Stredy klastrov sú tiež uvedené v skupine klastrových analýz metadát produktu.



Label	Colour	Value	Frequency	Descriptio
class_1		0	36.850	Cluster 0,
class_2		1	26.099% Cluster 1,	
class_3		2	11.781% Cluster 2,	
class_4		3	10.6669	6 Cluster 3,
class_5		4	9.9419	6 Cluster 4,
class_6		5	3.278	6 Cluster 5,
class_7		6	1.3869	Cluster 6,

Obr. 5.13 Výsledok K-means klasifikácie MS snímky v programovom prostredí SNAP. **Fig. 5.13** K-means classification result of MS image in SNAP programming environment. Source: GEARS - Geospatial Ecology and Remote Sensing, 2018 (youtube.com/watch?v=gh6tZC48yJ0)

5.3.2. H- α classification

Klasifikácia Cloude-Pottier je nekontrolovaná klasifikačná schéma, ktorá je založená na použití roviny *Entropia* (*H*) / *Alfa* (α). Entropia je podľa definície prirodzeným meradlom prirodzenej reverzibility rozptylových údajov (neusporiadanosti sústavy či objektu), zatiaľ čo alfa možno použiť na identifikáciu základných mechanizmov priemerného rozptylu. Rovina *H*/*Alfa* je rozdelená do deviatich zón zodpovedajúcich deviatim triedam rôznych mechanizmov rozptylu. Pre každý pixel v zdrojovom produkte sa vypočíta jeho entropia a uhol alfa. Na základe polohy vypočítanej entropie a alfa v rovine *H*/*Alfa* je pixel zaradený do jednej z deviatich zón, pixelu je priradený index zóny. Obr. 5.14 ukazuje umiestnenie a hranice deviatich zón v rovine *H*/*Alfa*.





Hranice zobrazené na Obr. 5.14 ukazujú, že keď je entropia vysoká, schopnosť klasifikovať rôzne mechanizmy rozptylu je veľmi obmedzená. Počiatočné rozdelenie do deviatich tried (osem použiteľných) navrhli Cloude a Pottier (1997) a je znázornené na Obr. 5.14. Triedy sa vyberajú na základe všeobecných vlastností mechanizmu rozptylu a nezávisia od konkrétneho súboru údajov. To umožňuje neriadenú klasifikáciu na základe fyzikálnych vlastností signálu. Interpretácie tried, ktoré navrhli Cloude a Pottier, sú nasledovné (ďalšie podrobnosti pozri Cloude & Pottier 1997):

Trieda ZI: Dvojitý odrazový rozptyl v prostredí s vysokou entropiou

Trieda Z2: Viacnásobný rozptyl v prostredí s vysokou entropiou (napr. lesná klenba)

Trieda Z3: Povrchový rozptyl v prostredí s vysokou entropiou v H/Alfa

Trieda Z4: Viacnásobný rozptyl strednej entropie

Trieda Z5: Stredne entropický vegetačný (dipólový) rozptyl

Trieda Z6: Stredný rozptyl na povrchu entropie

Trieda Z7: Viacnásobný rozptyl s nízkou entropiou (dvojitý alebo dokonca odrazový rozptyl)

Trieda Z8: Dipólový rozptyl s nízkou entropiou (silne korelované mechanizmy s veľkou nerovnováhou amplitúdy medzi HH a VV)

Trieda Z9: Povrchový rozptyl s nízkou entropiou (napr. Braggov rozptyl a drsné povrchy).

Je však dôležité poznamenať, že hranice sú do istej miery ľubovoľné a závisia od kalibrácie, spodnej hranice šumu merania a rozptylu odhadov parametrov. Napriek tomu je táto klasifikačná metóda spojená s vlastnosťami fyzikálneho rozptylu, vďaka čomu je nezávislá od trénovacích dátových súborov. Počet potrebných tried, ako aj použiteľnosť metódy závisí od aplikácie (Obr. 5.15).





Fig. 5.15 Unsupervised classification for ALOS PALSAR satellite image based on H/α segmentation of Honshu, Japan after the earthquake. A) On May 19, 2006, b) on November 24, 2008, c) on June 4, 2009, d) H/α -based segmentation, e) H/α display for each area.

Source: Yonezawa et al., 2012

References

Books

Jensen, J. R. (2015). Introductory digital image processing : a remote sensing perspective (4th ed., pp. 1–659). Pearson Education, Inc. ISBN 978-0-13-405816-0

Tempfli, K., Kerle, N., Huurneman, G. C., & Janssen, L. L. F. (Eds.). (2009). Principles of Remote Sensing: An introductory textbook (4th ed., pp. 1–591). The International Institute for Geo-Information Science and Earth Observation (ITC). ISBN 978–90–6164–270–1

Lillesand, T.M., Kiefer, R.W. and Chipman, J.W. (2015). Remote sensing and image interpretation. Hoboken, N.J.: John Wiley & Sons, Inc. 770p. ISBN 978-1-118-34328-9

Dobrovolný, R. (1998). Dálkový průzkum Země; Digitální zpracování obrazu. Masarykova Univerzita, Přírodovědecká Fakulta. ISBN 80-210-1812-7

Wolf, P. R., Dewitt, B. A., & Wilkinson, B. E. (2014). Elements of photogrammetry with application in GIS (4th ed., pp. 1–807). Mcgraw-Hill Education, Cop. ISBN 978-0-07-176111-6

Huang, T.-M., Kecman, V., & Kopriva, I. (2006). Kernel based algorithms for mining huge data sets : supervised, semi-supervised, and unsupervised learning (pp. 1–266). Springer-Verlag. ISBN 978-3-540-31681-7

M Emre Celebi, & Kemal Aydin. (2016). Unsupervised Learning Algorithms (1st ed., pp. 1–564). Springer International Publishing Switzerland. ISBN 978-3-319-24209-5

Papers, manuals, reports

Elsharkawy, A. (2016). A modification to hyper-rectangle supervised classification method for high resolution satellite imagery. The International Conference on Civil and Architecture Engineering, 11(11), 1–7. DOI: 10.21608/iccae.2016.43463

Shakya, A. K., Ramola, A., & Vidyarthi, A. (2021). Modeling of texture quantification and image classification for change prediction due to COVID lockdown using Skysat and Planetscope imagery. Modeling Earth Systems and Environment. DOI: 10.1007/s40808-021-01258-6

UKEssays. (November 2018). Supervised Image Classification Techniques. Retrieved from https://www.ukessays.com/essays/engineering/supervised-image-classification-9746.php?vref=1

Breiman, L. (2001). Random Forests. Machine Learning, 45(1), 5–32. DOI: 10.1023/a:1010933404324

Lu, L, Di, L, & Ye, Y. (2014). A Decision-Tree Classifier for Extracting Transparent Plastic-Mulched Landcover from Landsat-5 TM Images. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7(11), 4548–4558. DOI: 10.1109/JSTARS.2014.2327226

García-Gonzalo, E., Fernández-Muñiz, Z., García Nieto, P. J., Bernardo Sánchez, A., & Menéndez Fernández, M. (2016). Hard-Rock Stability Analysis for Span Design in Entry-Type Excavations with Learning Classifiers. Materials, 9(7), 531. DOI: 10.3390/ma9070531

Feng, X., Zhou, H., Liu, C., Zhang, Y., Liang, W., Nilot, E., Zhang, M., & Dong, Z. (2019). Particle Center Supported Plane for Subsurface Target Classification based on Full Polarimetric Ground Penetrating Radar. Remote Sensing, 11(4), 405. DOI: 10.3390/rs11040405

Shah, S. H., Angel, Y., Houborg, R., Ali, S., & McCabe, M. F. (2019). A Random Forest Machine Learning Approach for the Retrieval of Leaf Chlorophyll Content in Wheat. Remote Sensing, 11(8), 920. DOI: 10.3390/rs11080920

Cloude, S. R., & Pottier, E. (1997). An entropy based classification scheme for land applications of polarimetric SAR. IEEE Transactions on Geoscience and Remote Sensing, 35(1), 68–78. DOI: 10.1109/36.551935

Yonezawa, C., Watanabe, M., & Saito, G. (2012). Polarimetric Decomposition Analysis of ALOS PALSAR Observation Data before and after a Landslide Event. Remote Sensing, 4(8), 2314–2328. DOI: 10.3390/rs4082314

Web sources

gisgeography.com/image-classification-techniques-remote-sensing

http://www.50northspatial.org/pick-best-supervised-classification-method/

https://www.ukessays.com/essays/engineering/supervised-image-classification-9746.php

https://www.ukessays.com/essays/engineering/supervised-image-classification-9746.php

GEARS - Geospatial Ecology and Remote Sensing. (2018, March 29). Classification Part 2 - Unsupervised clustering. Www.youtube.com. https://www.youtube.com/watch?v=gh6tZC48yJ0

6

Basics of Radar Remote Sensing

Microwave radiation is represented in the electromagnetic spectrum by wavelengths ranging from 1 millimetre to several metres, which are followed by radio waves in the electromagnetic spectrum. Typical representatives of systems using microwave radiation include a device referred to as RADAR. This abbreviation, originally from the English phrase Radio Detection and Ranging, defines a group of systems used to locate and detect a variety of objects in the contemporary world.

The basic form of radar consists of a transmitting antenna, emitting electromagnetic radiation, and a receiving antenna or another receiving device. The idea is that part of the transmitted signal is reflected from an object, and thus the receiving antenna collects the returned energy. This is then delivered to the receiver, where it is processed. From this, the location of the target and other attributes can then be determined.

It is clear that objects on the Earth's surface emit not only infrared radiation but also microwave radiation with relatively low energy levels. If the sensor detects microwave radiation that is naturally emitted by the ground, this type of radiation is defined as passive microwave radiation. On the other hand, in addition to passively sensing emissions originating from objects on Earth's surface, satellite sensors can also emit active microwaves towards Earth's surface. These microwaves reflect off the Earth's surface and return back to the sensors. This type of remote sensing of the Earth is commonly referred to as active microwave radiation. Thus, two basic types of microwave sensors can be encountered in practice, namely passive and active microwave systems. Their further specification and classification is the subject of this chapter.



6.1. Introduction to radar RS

Mikrovlnné žiarenie je v elektromagnetickom spektre zastúpené vlnovými dĺžkami v rozsahu od 1 milimetra až do niekoľko metrových hodnôt, na ktoré majú v elektromagnetickom spektre nadväznosť rádiové vlny. Medzi typických zástupcov systémov využívajúcich mikrovlnné žiarenie, patrí zariadenie označované ako RADAR. Táto skratka pôvodom z anglického slovného spojenia Radio Detection and Ranging definuje skupinu systémov slúžiacich na lokalizáciu a detekciu rôznorodých objektov súčasného sveta, konkrétne:

- R ako Radio vyjadruje skutočnosť, že systém využíva mikrovlnné elektromagnetické žiarenie s dĺžkou v rozsahu od vlny 3 cm do 50 cm,
- D ako Detection charakterizuje schopnosť technológie rozpoznať prítomnosť alebo neprítomnosť určitého objektu,
- R ako Ranging predstavuje schopnosť určiť presnú vzdialenosť, v akej sa pozorovaný objekt nachádza.

Základná forma radaru je tvorená vysielacou anténou, emitujúcou elektromagnetické žiarenie a prijímacou anténou alebo iným prijímacím zariadením. Podstatou fungovania je to, že časť vysielaného signálu sa odrazí od určitého objektu a teda prijímacia anténa zhromažďuje vrátenú energiu. Tá je v ďalšej fáze dodaná do prijímača, kde je spracovaná. Z nej je potom možné určovať polohu cieľa a ďalších atribútov. Vzdialenosť alebo rozsah od cieľa sa určuje odmeraním času *T_R*, za ktorý impulz dorazí do cieľa a vráti sa späť. A keďže sa elektromagnetická energia šíri rýchlosťou svetla c, vzdialenosť R sa vyjadrí pomocou nasledujúceho vzťahu:

$$R = \frac{c T_R}{2} \tag{6.1}$$

Ako je už známe, v diaľkovom prieskume Zeme sa je možné stretnúť s dvomi pôvodmi žiarenia a to prírodným a umelým. Pokiaľ ide o mikrovlnné žiarenie, to je v nemalom rozsahu tvorené práve umelým spôsobom. Dôsledkom toho je vznik žiarenia s niekoľkonásobne vyššou intenzitou, než žiarenie produkované prírodným zdrojom s rovnakou vlnovou dĺžkou. Intenzita radarového žiarenia závisí najmä od dvoch parametrov, ktorými sú výkon vysielača *W* a zosilnenie antény *G*. Čiže pre určenie intenzity v určitej vzdialenosti *r* platí tento výraz.

$$E = \frac{WG}{4\pi r^2} \tag{6.2}$$

Dôležitý je tiež fakt, že vyžarovanie energie pri radaroch nie je vždy stále. Niekedy tento jav prebieha v tzv. pulznom režime, pri ktorom je pulzný výkon W_p nepriamoúmerný pulznej frekvencii f_p a dobe trvania pulzu r. Platí teda:

$$W_p = \frac{W}{\tau f_p} \tag{6.3}$$

Je pravdou, že medzi najdôležitejší atribút radarových systémov patrí ich schopnosť určiť vzdialenosť od celej škály objektov. Aj preto majú tieto systémy od ostatných senzorov diaľkového prieskumu Zeme navrch a to vďaka dvom nasledujúcim vlastnostiam:

• schopnosť žiarenia prenikať oblačnosťou, jemným dažďom, hmlou a smogom

 odlišnosť pohľadu na tzv. hladké a drsné povrchy rôznych objektov Zeme. Pre lepšie pochopenie to znamená, že ak sa niektoré objekty správali v oblasti infračerveného a viditeľného žiarenia ako drsné povrchy, tak sa v tomto prípade budú správať ako hladké povrchy.

Ako je už zrejmé, frekvenčný rozsah mikrovlnného žiarenia je pomerne široký. Z toho vyplýva, že pre radarové systémy je nevyhnutné, aby boli ďalej rozdelené a špecifikované do niekoľkých pásiem. Tieto pásma sú označované písmenami a zoradené z hľadiska použitej frekvencie a vlnovej dĺžky čo uvádza nasledujúca tabuľka (Tab. 6.1).

Označenie pásma	Vlnový rozsah (cm)	Frekvenčný rozsah (GHz)
Ка	0,8 - 1,1	40,0 - 26,5
К	1,1 - 1,7	26,5 - 18,0
Ku	1,7 - 2,4	18,0 - 12,5
х	2,4 - 3,8	12,5 - 8,0
С	3,8 - 7,5	8,0 - 4,0
S	7,5 - 15,0	4,0 - 2,0
L	15,0 - 30,0	2,0 - 1,0
Р	30,0 - 100,0	1,0 - 0,3

Tab. 6.1 Frekvenčné pásma mikrovlnného žiarenia v elektromagnetickom spektre. **Tab. 6.1** Frequency bands of microwave radiation in the electromagnetic spectrum.

6.1.1.A brief history of radar systems development

Za počiatok objavovania radarových systémov možno považovať počin nemeckého vedca Heinricha Hertza, ktorý okolo roku 1887 začal experimentovať s rádiovými vlnami. Všimol si, že sa tieto vlny prenášajú rôznymi typmi materiálov a tiež ich odrazivosť od kovových predmetov. O niekoľko rokov neskôr si rádiový priekopník Guglielmo Marconi taktiež všimol odrazivosť rádiových vĺn v súvislosti s experimentom s rádiomajákmi. Použil však krátke vlny, ktoré sa neskôr ukázali ako dôležité pre praktický vývoj radaru.

V roku 1904 Christian Hülsmeyer v Nemecku a Holandsku použil rádiové vlny na detekciu lodí, hlavne z dôvodu predikcie ich neželaných kolízií. Samozrejme netrvalo dlho a o pár rokov sa princípom odrazivosti mikrovlnného žiarenia začali zaoberať aj vedci ako Robert Watson Watt, Harry Egerton Wimperis a ďalší. Táto technológia si práve začiatkom dvadsiateho storočia, v čase svetových vojen, našla uplatnenie aj v oblasti obrany, konkrétne leteckej ochrany a bezpečnosti štátov. Vývoj systémov schopných vytvárať krátke impulzy rádiovej energie bol kľúčovým krokom, ktorý umožnil vznik moderných radarových systémov. Načasovaním impulzov na osciloskope bolo možné určiť rozsah a smer antény odhalil uhlové umiestnenie cieľov.

Po skončení vojen sa použitie radaru rozšírilo do mnohých oblastí. Našiel si tak uplatnenie nielen v oblasti civilného letectva, námorníctva, meteorológie a medicíny, ale čo je najdôležitejšie, aj v oblasti mapovania. To podnietilo neustály progres vo vývoji tejto technológie, čo malo za následok vznik ďalších typov radarov. V nasledujúcej kapitole bude princíp ich fungovania a rozdelenie z hľadiska rôznych aspektov podrobnejšie opísané a špecifikované.

6.2. Classification of radar systems

Je zrejmé, že predmety na zemskom povrchu emitujú nielen infračervené žiarenie, ale aj tiež mikrovlnné žiarenie s relatívne nízkou úrovňou energie. Pokiaľ snímač deteguje mikrovlnné žiarenie, ktoré je prirodzene vyžarované zemou, tak tento typ žiarenia je definovaný ako pasívne mikrovlnné žiarenie. Na druhej strane okrem pasívnych snímaní emisií, pochádzajúcich z objektov nachádzajúcich sa na zemskom povrchu, môžu satelitné senzory vysielať tiež aktívne mikrovlny smerom k zemskému povrchu. Tieto mikrovlny sa odrážajú od povrchu Zeme a vracajú sa späť k senzorom. Takýto typ diaľkového pozorovania Zeme sa zvykne označovať ako aktívne mikrovlnné žiarenie. Teda v praxi je možné stretnúť sa s dvoma základnými typmi mikrovlnných senzorov a to pasívnymi a aktívnymi mikrovlnnými systémami. Ich bližšej špecifikácii a rozdeleniu sa venujú nasledujúce strany tejto publikácie.

6.2.1. Passive radar systems

Tieto systémy sú založené na pasívnom pozorovaní atmosféry za pomoci mikrovlnných rádiometrov (Obr. 6.1). To znamená, že merajú termálne emisie z rôznych širokých vrstiev medzi zemským povrchom a atmosférou. Takýto typ žiarenia je založený na princípe Planckovho zákona a je priamoúmerný vyžarovacej schopnosti, teda emisivite (v rozmedzí 0 až 1) a fyzikálnej teplote. Prostredníctvom teploty jasu *TB*, ktorá je nižšia ako fyzikálna teplota, platí pre mikrovlnný rádiometer v kozmickom priestore táto rovnica:

$$TB = \tau_{ATM} (TB_{SK} + TB_C) + TB_{ATM}$$
(6.4)

Ak všeobecne platí, že parameter τ_{ATM} definuje priepustnosť atmosféry, T_{BC} je zmes zemského povrchu, TB_{ATM} predstavuje zmes atmosféry a TB_{SK} charakterizuje zmes odrazenej nebeskej a kozmickej radiácie. Zaujímavosťou je tiež, že takýto typ senzorov detegujúci pasívne mikrovlnné žiarenie, dokáže pomerne jednoducho rozlíšiť napríklad morský ľad od oceánu, dôsledkom selektívneho pohlcovania žiarenia v mikrovlnnej časti spektra (existencia atmosférických okien). Je to teda dôležitý typ technológie diaľkového prieskumu pre oblasti výskumu ako meteorológia, hydrológia a oceánografia (teda najmä pri mapovaní mora, ľadu a snehu a pri hodnotení pôdnej vlhkosti). Na druhej strane je potrebné uviesť, že pre tieto systémy je charakteristická aj určitá skupina nevýhod. Azda najvýznamnejšou je nízka úroveň energie, ktorej výsledkom je to, že žiarenie sa musí zhromažďovať vo väčšej oblasti. Taktiež sa väčšina pasívnych mikrovlnných senzorov vyznačuje nízkym priestorovým rozlíšením výsledných produktov. Možno teda povedať, že mikrovlnné rádiometre, aspoň v blízkej budúcnosti, nie sú schopné nahradiť systémy s vysokým rozlíšením (optický rádiometer, SAR) napr. pre lesné aplikácie diaľkového prieskumu Zeme.



Obr. 6.1 Zjednodušená schéma fungovania pasívneho radarového systému. **Fig. 6.1** Simplified diagram of a passive radar system. Source: Richards, 2009

6.2.2. Active radar systems

Druhú kategóriu radarových systémov tvoria aktívne radarové systémy. Patria medzi podstatne rozšírenejší a využívanejší typ mikrovlnných systémov. Sú založené na meraní spiatočného signálu na konkrétne vzdialenosti. Čiže ide o určenie vzdialenosti medzi radarom a cieľom. Zároveň sú tieto systémy schopné získať informácie o fyzikálnych vlastnostiach cieľa a jeho tvare. Medzi veľké pozitíva týchto systémov patrí schopnosť fungovať aj za nepriaznivých poveternostných podmienok a schopnosť fungovať aj mimo denného svetla v noci. Veľmi dôležitou charakteristikou aktívnych radarových systémov je to, že nie vždy musia byť ich finálnym produktom obrazové dáta. Ich umiestnenie môže byť ako na lietadlovom alebo družicovom nosiči, tak aj na zemskom povrchu. Na základe toho je známe hlavné delenie aktívnych radarových systémov na zobrazujúce. Následne sa ďalej delia z hľadiska technologických kapacít, fyzikálneho princípu a systémových parametrov na ďalšie podskupiny, čo znázorňuje nasledujúca snímka (Obr. 6.2). Pre účely DPZ však budú charakterizované iba najrozšírenejšie druhy zobrazujúcich aktívnych radarových systémov.



Obr. 6.2 Klasifikácia aktívnych radarových systémov podľa ich špecifických funkcií. **Fig. 6.2** Classification of active radar systems according to their specific functions. Source: Richards, 2009

6.2.2.1. Side Looking Airborne Radar (SLAR)

Dlhoročne známym typom aktívnych zobrazujúcich radarových systémov je **radar s bočným pohľadom**, označovaný skratkou *SLAR* (angl. *Side Looking Airborne Radar*). Je to aktívny mikrovlnný systém, ktorý je kolmý na smer letu. Ide o radarovú technológiu s reálnou apertúrou, ktorá zvyčajne býva umiestnená na leteckom, prípadne družicovom nosiči. Začiatky týchto radarových systémov siahajú až do päťdesiatych rokov dvadsiateho storočia. Vo vtedajšom období šlo teda o skenovanie za pomoci pevného lúča, nasmerovaného na stranu, ktorého pohyb po Zemi bol realizovaný lietadlom. Svoje uplatnenie mal primárne vo vojenskom sektore a tiež pre výskumné účely. Tento systém taktiež vyžaduje, aby anténa bola primeranej veľkosti pre adekvátne uhlové rozlíšenie. Azimutálne rozlíšenie je v SLAR systémoch definované nasledovne:

$$R_a = \frac{H \cdot \lambda}{L \cdot \cos \theta} , \qquad (6.5)$$

ak H je výška antény (resp. lietadla), L označuje geometrickú dĺžku antény, λ je vlnová dĺžka prenášaných impulzov a heta symbolizuje uhol dopadu. Geometrické zobrazenie SLAR radarom je zásadne odlišné ako zobrazenie leteckej snímky. Tento rozdiel je markantný vďaka tomu, lebo SLAR patrí do skupiny meracích systémov DPZ a nie uhlových meracích systémov. To sa v mnohých prípadoch prejavuje zmenou geometrie výsledného obrazu. Tieto zmeny je možné zhrnúť do niekoľkých chýb. Prvou z nich je distorzia mierky v šikmom smere, ktorá vzniká vtedy, ak je rozlišovacia schopnosť bunky väčšia smerom k okraju obrazu ako v jeho strede. Ide o skreslenie, ktoré je potrebné zohľadniť. Druhou chybou je **paralaxa**, ktorá je zapríčinená pozičnou chybou kvôli nerovnosti terénu, pri snímaní rovnakého miesta z dvoch rôznych pohľadov, a to buď snímaním z jedného smeru no v rozdielnych výškach, alebo snímaním z dvoch navzájom opačných strán. Posledná **pozičná chyba spôsobená terénom** vzniká vďaka terénnym nerovnostiam, kde dochádza k neskoršiemu zaznamenaniu odrazu od bližšieho bodu, než od vzdialenejšieho. Teda dochádza k vzniku zhustenia signálu, prekrytu a tieňa. V súvislosti s geometrickou korekciou radarového obrazu budú tieto tri skreslenia bližšie špecifikované v kapitole charakteristík SAR obrazu. Medzi ďalšiu nevýhodu SLAR systémov patrí slabé rozlíšenie finálneho obrazu. To znamená, že ak je šírka azimutu menšia, tak tým je rozlíšenie jemnejšie. Tento vplyv je možné eliminovať veľmi dlhou anténou alebo použitím veľmi krátkych vlnových dĺžok. To sa ale môže prejaviť útlmom v atmosfére.

6.2.2.2. Synthetic Aperture Radar (SAR)

Medzi najvýznamnejši typ aktívnych zobrazujúcich radarových systémov v oblasti družicového diaľkového prieskumu Zeme, patrí **radar so syntetickou apertúrou**, označovaný ako **SAR** (angl. *Synthetic Aperture Radar*). Ide o technológiu, ktorá v súčasnej dobe patrí medzi populárnu a rozvíjajúcu sa. V porovnaní so SLAR umožňuje táto technológia použitie dlhších vlnových dĺžok pre dosiahnutie čo najlepšieho výsledku. Taktiež v porovnaní so SLAR systémom SAR družice poskytujú lepšie azimutálne rozlíšenie aj napriek tomu, že sú vybavené fyzicky kratšou anténou na nosiči. Na spracovanie signálu využívajú modifikovaný záznam dát pomocou tzv. dlhých antén. Týmto spôsobom je možné napr. pomocou antény s dĺžkou 2-3 metre nahradiť anténu, ktorá by pre rovnaké rozlíšenie obrazu musela dosahovať veľké rozmery (cca 500- 600 metrov). Pre lepšiu predstavivosť geometriu snímania SAR umiestneného na družici znázorňuje nasledujúca situácia (Obr. 6.3). Dôležitú úlohu pri SAR systémoch zohráva šikmý smer (angl. *Slant range direction*), prostredníctvom ktorého je definovaný smer

šírenia radarového signálu. Zároveň určuje aj vzdialenosť antény od zemského povrchu, resp. iného cieľa. Medzi ďalšiu geometrickú charakteristiku SAR systému patrí pozemná trasa (z angl. *Groung track*), ktorú možno charakterizovať ako ortogonálny priemet obežnej dráhy družice. Významný je pri SAR systémoch aj priečny smer (angl. *Ground range direction*), ktorý reprezentuje ortogonálny priemet snímaného územia na zemský povrch.



Obr. 6.3 Zjednodušené znázornenie geometrie SAR systému. **Fig. 6.3** Simplified illustration of the SAR system geometry. Source: Ferretti, 2007

SAR patrí do skupiny aktívnych mikrovlnných systémov vďaka už spomínanej nepretržitej operačnej schopnosti, a to aj za akýchkoľvek poveternostných podmienok. Je samozrejmosťou, že na svete existuje množstvo radarových satelitných misií, ktoré sa neustále vyvíjajú. Ich fungovanie však nie je vždy založené na rovnakých fyzikálnych princípoch. To znamená, že mnohé z nich sú schopné pracovať vo viacerých frekvenciách (pásmach) mikrovlnného žiarenia, a tiež rôznych režimoch akvizície. Medzi využívané frekvenčné pásma mikrovlnného žiarenia v SAR systémoch patria tieto tri:

- L pásmo (angl. L band) pásmo s frekvenciou 1,2 GHz (do tejto skupiny partia ALOS misie a tiež japonská JERS misia)
- **C pásmo** (angl. *C band*) pásmo s frekvenciou 5,3 GHz (zahŕňa staršie misie ako ERS-1, ERS-2, ale aj novšie ako Envisat, Radarsat-1, Radarsat-2, Sentinel-1 a ďalšie)
- **X pásmo** (angl. *X band*) pásmo s frekvenciou 10 GHz (zahŕňa misie ako TerraSAR-X, COSMO SkyMed a ďalšie misie).

Pokiaľ ide o režimy akvizície, ich neustály vývoj podnecuje progres pri skúmaní nových algoritmov a techník spracovania, schopných využívať vlastnosti družicových senzorov. V posledných desaťročiach však boli senzory SAR navrhnuté tak, aby uspokojili rastúcu potrebu vedeckého monitorovania krajiny. V súčasnosti tieto systému fungujú na princípe niekoľkých režimov snímania, ktorých rozdelenie a špecifikácia boli popísané v prvej kapitole tejto publikácie. Vďaka rozptylovým a zobrazovacím mechanizmom a tiež škvrnám v SAR obraze sa však interpretácia a porozumenie SAR obrazu výrazne líši od vizuálnej analýzy prostredníctvom fotografií.

6.3. SAR signal characteristics

Správanie radarového signálu, ktorý je spätne rozptýlený od objektov na zemskom povrchu, býva ovplyvnené niekoľkými faktormi, ktoré možno rozdeliť do dvoch hlavných kategórií. Prvou z nich sú vnútorné parametre, označované v literatúre tiež ako systematické. Do tejto kategórie možno zaradiť vlnovú dĺžku, polarizáciu, rozlíšenie a uhol dopadu. Okrem systematických parametrov je spätne rozptýlený radarový signál ovplyvnený aj skupinou ďalších parametrov. Ide o tzv. vonkajšie parametre, označované aj ako cieľové parametre. Patria medzi ne dielektrické vlastnosti materiálov, drsnosť povrchu, spätný rozptyl a lokálny sklon povrchu.

6.3.1. Internal parameters

6.3.1.1. Wavelength

Prvým parametrom je vlnová dĺžka, ktorá určuje, do akej miery sa radarový signál zoslabuje alebo rozptyľuje. V závislosti od rozdielnej vlnovej dĺžky je rozdielna aj penetrácia, čiže prienik žiarenia rôznym prostredím, objektmi a zložkami Zeme a jej povrchu. Prienik mikrovlnného žiarenia pod povrch pôdy alebo vegetáciu je závislý nielen od vlnovej dĺžky, ale aj od uhla dopadu žiarenia. Príkladom je dole uvedený obrázok (Obr. 6.4), znázorňujúci prienik troch využívaných SAR pásem. Zároveň možno povedať, že intenzita drsnosti povrchu závisí od uhla pohľadu a vlnovej dĺžky použitého žiarenia. V praxi to znamená, že niektoré povrchy sa môžu pri dlhších vlnových dĺžkach javiť ako hladké. Naopak, povrchy snímané pomocou kratších vlnových dĺžok môžu byť výrazne rozptýlené. Teda drsné povrchy pôsobia ako difúzne reflektory v tom, že rozptyľujú dopadajúcu energiu do všetkých smerov vrátane smerom späť k senzoru.



Obr. 6.4 Znázornenie penetrácie pre jednotlivé frekvenčné pásma SAR. **Fig. 6.4** Penetration for individual SAR frequency bands. Source: Salepci et al., 2018

Zároveň možno povedať, že intenzita drsnosti povrchu závisí od uhla pohľadu a vlnovej dĺžky použitého žiarenia. V praxi to znamená, že niektoré povrchy sa môžu pri dlhších vlnových dĺžkach javiť ako hladké. Naopak povrchy snímané pomocou kratších vlnových dĺžok môžu byť výrazne rozptýlené. Teda drsné povrchy pôsobia ako difúzne reflektory v tom, že rozptyľujú dopadajúcu energiu do všetkých smerov vrátane späť smerom k platforme diaľkového snímania).

Ak sa na problematiku vlnovej dĺžky elektromagnetického žiarenia pozrieme z fyzikálneho hľadiska, platí, že vzhľadom ku konštantnej polohe r_0 sa mení fáza vlny o hodnotu 2π , pričom dochádza k zmene v čase o $2\pi/\omega$. Časový interval tak predstavuje periódu vlny v tvare:

$$T = \frac{2\pi}{\omega} = \frac{1}{f} \tag{6.6}$$

Pri zmene radiálnej vzdialenosti o hodnotu $2\pi/t$ dochádza v konštantnom čase t_o k zmene fázy o 2π radiány. Tento prírastok je vyjadrený prostredníctvom vlnovej dĺžky λ v nasledujúcom tvare:

$$\lambda = \Delta r = \frac{2\pi}{k} \tag{6.7}$$

Pre vlnu v priestore v konštantnom čase a v prostredí s konštantami vákua platí tento rozšírený vzťah:

$$\lambda = \Delta r = \frac{2\pi}{2\pi f \sqrt{\mu_0 \varepsilon_0}} = \frac{c}{f} , \qquad (6.8)$$

ak c predstavuje rýchlosť svetla vo vákuu.

6.3.1.2. Polarisation

Medzi ďalšie vnútorné parametre patrí polarizácia EM vĺn SAR systémov. Je definovaná orientáciou vektorov magnetického a elektrického poľa. Podstata spočíva v smere emitovaného a prijatého signálu pochádzajúceho z mikrovlnných senzorov na družici resp. inom nosiči (Obr. 6.5). Teda radarový signál môže byť filtrovaný, a to na princípe kmitajúcej vlny iba v jednej rovine, kolmej na smer šírenia signálu.



Obr. 6.5 Princíp polarizácie. **Fig. 6.5** Polarisation principle. Source: Pottier, 2021

Ak sa na polarizáciu elektromagnetickej vlny pozrieme z fyzikálneho hľadiska, môžeme skonštatovať, že je definovaná smerom elektrického poľa \vec{E} . Teda platí, že polarizácia je vertikálna, ak je \vec{E} kolmé na rovinu dopadu. V prípade horizintálnej polarizácie platí, že \vec{E} patrí do roviny dopadu.

Na základe výpočtu koeficientov odrazu r a prenosu t na princípe Descartových zákonov, platia pre elektrické polia $\vec{E_r}$ a $\vec{E_t}$ tieto rovnice:

$$\begin{pmatrix} E_{r,\perp} \\ E_{t,\parallel} \end{pmatrix} = \begin{pmatrix} e^{i\vec{k}\cdot\vec{d}} \\ |\vec{d}| \end{pmatrix} \begin{pmatrix} r_{\perp} & 0 \\ 0 & r_{\parallel} \end{pmatrix} \begin{pmatrix} E_{i,\perp} \\ E_{i,\parallel} \end{pmatrix} ,$$
 (6.9)

ak $\vec{E_i}$ predstavuje elektrické pole dopadu, vektor \vec{k} charakterizuje rovinu dopadu elektromagnetickej vlny a \vec{d} je vektorom definujúcim pozíciu pozorovateľa nasledovne:

$$r_{\parallel} = -\frac{\tan(\theta - \theta')}{\tan(\theta + \theta')} \qquad r_{\perp} = -\frac{\sin(\theta - \theta')}{\sin(\theta + \theta')} , \qquad (6.10)$$
$$t_{\parallel} = \frac{2\cos(\theta)\sin(\theta')}{\sin(\theta + \theta')\cos(\theta + \theta')} \qquad t_{\perp} = \frac{2\cos(\theta)\sin(\theta')}{\sin(\theta + \theta')} ,$$

pričom θ je známy ako Brewsterov uhol. Všeobecne platí, že polarizovaná vlna sa viac neodráža vtedy, ak je splnené:

$$\theta + \theta' = \frac{\pi}{2} \tag{6.11}$$

Ak uvažujeme štandardný pravostranný systém, potom pre vektor elektrického poľa platí nasledovné:

$$\vec{E}(u,t) = \vec{E}e^{i(\omega t - vu)} , \qquad (6.12)$$

ak: ω predstavuje uhlovú frekvenciu, v je číslom vlny, pričom \vec{E} predstavuje kompletný 2D vektor v tvare $\vec{E} = E_H \hat{u}_H + E_V \hat{u}_V$, pričom zložky \hat{u}_v a \hat{u}_H sú jednotkové vektory. Pokiaľ ide o určenie polarizácie elektromagnetickej vlny, vychádza z uvedených amplitúd E_V a E_H , doplnených o relatívnu fázu, nachádzajúcu sa medzi nimi.

Empirická kovariančná matica je v tvare:

$$\bar{\Gamma} = \frac{1}{2} \begin{pmatrix} |E_H|^2 & E_H E_V \\ E_V E_H & |E_V|^2 \end{pmatrix},$$

$$\bar{\Gamma} = \frac{1}{2} (g_0 \sigma_0 + g_1 \sigma_1 + g_2 \sigma_2 + g_3 \sigma_3),$$

$$\bar{\Gamma} = \frac{1}{2} \begin{pmatrix} g_0 + g_1 & g_2 - ig_3 \\ g_2 + ig_3 & g_0 - g_1 \end{pmatrix},$$
(6.13)

za predpokladu, že uvažujeme Pauliho skupinu matíc v tejto podobe:

$$\sigma_0 = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \qquad \sigma_1 = \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix}$$

$$\sigma_2 = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix} \qquad \sigma_0 = \begin{pmatrix} 0 & -i \\ i & 0 \end{pmatrix}$$
(6.14)

a g_0 , g_1 , g_2 a g_3 sú takzvané Stokesove parametre, ktorých vektorový zápis je v nasledovnej podobe, označovanej ako Stokesov vektor:

$$g = \begin{pmatrix} g_0 \\ g_1 \\ g_2 \\ g_3 \end{pmatrix}$$
(6.15)

Teda možno zhrnúť, že všetky tieto rovnice popisujú rozdielne správanie **horizontálnej** a **vertikálnej** vlny, ktorá môže byť horizontálny (H) a vertikálny (V) charakter (Obr. 6.6). Na základe toho rozoznávame niekoľko typov polarizácie elektromagnetickej vlny pri SAR snímkach a to:

- **úroveň jednoduchej polarizácie** pozostáva z kopolarizovaných signálov HH alebo VV (prípadne krížovo polarizovaných signálov HV alebo VH),
- úroveň duálnej polarizácie je tvorená dvojicami kopolarizovaných aj krížových zložiek v tvare HH a HV, HH a VV alebo VV a VH,
- úroveň štvoritej polarizácie tvoria ju všetky 4 zložky, teda HH, VV, HV a VH,
- úroveň hybridnej polarizácie RH, RV, LH, LV.



Obr. 6.6 Horizontálna (vľavo) a vertikálna (vpravo) polarizácia podľa Fresnelových zákonov. **Fig. 6.6** Horizontal (left) and vertical (right) polarization according to Fresnel's laws. Source: own processing

SAR polarizácia tiež používa rozptylovú maticu S na identifikáciu rozptylového správania sa objektov po interakcii s elektromagnetickou vlnou. Matica je zostavená kombináciou horizontálnych a vertikálnych polarizačných stavov, vyslaných a prijímaných signálov a má nasledovný tvar:

$$S = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix}$$
(6.16)

Usporiadaním všetkých prvkov rozptylovej matice S do stĺpca, dostávame cieľový vektor (prípadne aj jeho transponovanú podobu), ktorý je vhodný pre ďalšie odvodzovanie:

$$\mathbf{k} = \begin{bmatrix} S_{HH} \\ S_{HV} \\ S_{VH} \\ S_{VV} \end{bmatrix} = \begin{bmatrix} S_{HH} & S_{HV} & S_{VH} & S_{VV} \end{bmatrix}^{\mathrm{T}}$$
(6.17)

Ak vezmeme do úvahy rovnosť $S_{HV} = S_{VH}$, vzťahujúcu sa k spätnému rozptylu, potom platí, že jeden z prvkov je možné z rovnice vynechať. Na základe toho dostávame redukovaný vektor k v tvare:

$$\mathbf{k} = \begin{bmatrix} S_{HH} & \sqrt{2}S_{HV} & S_{VV} \end{bmatrix}^{\mathrm{T}}$$
(6.18)

Prostredníctvom kombinácie prvkov rozptylovej matice a na princípe Pauliho spinových matíc z kvantovej mechaniky je možné odvodiť ďalšie cieľové vektory:

$$k_p = \frac{1}{\sqrt{2}} [S_{HH} + S_{VV} \quad S_{HH} - S_{VV} \quad S_{HV} + S_{VH} \quad S_{HV} - S_{VH}]^{T} , \qquad (6.19)$$

pričom pre redukovaný spätný rozptyl bude platiť nasledovné:

$$k_p = \frac{1}{\sqrt{2}} [S_{HH} + S_{VV} \quad S_{HH} - S_{VV} \quad 2S_{HV}]^{T}$$
(6.20)

6.3.1.3. Resolution

Rozlišovacia schopnosť výsledného obrazu (Obr. 6.7) je tvorená množstvom SAR pixelov. Ten je možné definovať ako súčet všetkých príspevkov v rozlíšení bunky s rozlíšením azimutu alebo rozlíšením šikmej vzdialenosti. **Azimutálne rozlíšenie** (angl. *Azimuth Resolution*), alebo rozlíšenie pozdĺž stopy možno dosiahnuť kombináciou niekoľkých radarových návratov. Je možné ho definovať ako funkciu veľkosti antény v azimutálnom smere prostredníctvom vzťahu:

$$\delta_{az} = \frac{\lambda r_0}{2A_{az}} , \qquad (6.21)$$

kde λ symbolizuje vlnovú dĺžku, r_o je parameter vzdialenosti a A_{az} je azimut clony. Druhý typ rozlíšenia, teda **rozlíšenie šikmej vzdialenosti** (angl. *Slant Range Resolution*), ktoré sa dosahuje meraniami časového oneskorenia pomocou časovo rozptýlených impulzov, modulovaných lineárnou frekvenciou, ktoré je možné komprimovať do extrémne krátkych impulzov. Býva označované aj ako rozlíšenie naprieč stopou, pričom zase závisí od šírky pásma, a teda platí preňho tento vzťah:

$$\delta_{sr} = \frac{c}{2W} , \qquad (6.22)$$

kde parameter *c* symbolizuje rýchlosť svetla a *W* je pulzová šírka pásma. Teda tento typ rozlíšenia je nezávislý od vzdialenosti od Zeme.



Obr. 6.7 Princíp rozlíšenia radarového obrazu pomocou pixelov. **Fig. 6.7** Principle of radar image resolution using pixels. Source: Salepci et al., 2018

6.3.1.4. Angle of incidence of the radar signal

Za uhol dopadu (angl. Incidence Angle) môžeme považovať uhol, ktorý zviera rovina snímaného povrchu s normálou vedenou v mieste dopadajúceho lúča (Obr. 6.8). Vo všeobecnosti platí, že spätný rozptyl klesá so zvyšujúcim sa uhlom dopadu (samozrejme za predpokladu, že všetky ostatné podmienky zostanú nezmenené).



Obr. 6.8 Princíp zmeny veľkosti uhla dopadu. **Fig. 6.8** The principle of changing the size of the angle of incidence. Source: Salepci et al., 2018

Radarový lúč, ktorý dopadá pod strmým uhlom na snímaný povrch spôsobuje intenzívny odraz od relatívne hladkých povrchov. Tento uhol tak ovplyvňuje nielen výslednú geometriu radarovej snímky, ale aj rozsah radarových tieňov. Na druhej strane ak má uhol dopadu veľkú hodnotu, tak je intenzita spätného rozptylu nízka, dokonca lokálne nepostačujúca. Presnú hodnotu uhla dopadu pre každý pixel určitej scény, možno jednoducho vyjadriť pomocou údajov o nadmorskej výške platformy a pomocou parametrov priestorového rozlíšenia.

6.3.2. External parameters

6.3.2.1. Dielectric properties of materials

Je všeobecne známe, že elektrické vlastnosti majú vplyv na šírenie akéhokoľvek signálu, teda aj mikrovlnného. Elektrické charakteristiky vlastností terénu úzko kooperujú s ich geometrickými vlastnosťami pri určovaní intenzity odrazeného signálu. Na základe toho je elektrický charakter objektov charakterizovaných dielektrickou konštantou ε_r , ktorá určuje odrazivosť a vodivosť rôznorodých materiálov. Silne závisí od množstva prítomnej vody v prírodných materiáloch (napr. v pôde) (Obr. 6.9). V mikrovlnnom spektre má väčšina prirodzených materiálov v suchom stave hodnotu tejto konštanty od 3 do 8, no pokiaľ ide o vodu, tam sa hodnota konštanty pohybuje okolo hodnoty 80. Z toho vyplýva, že významné zvýšenie odrazivosti je spôsobené prítomnosťou vlhkosti v pôde alebo vo vegetácii. Teda dielektrická konštanta riadi odrazové vlastnosti prírodných materiálov a tým aj silu radarového spätného rozptylu. V praxi to znamená, že čím je konštanta ε_r vyššia, tým je vyšší aj spätný rozptyl. Ak vezmeme do úvahy rastliny, tak tie disponujú vysokým odrazom radarovej energie vďaka vysokému obsahu vlhkosti. Vegetačný pokryv so svojimi premenlivými komplexnými dielektrickými konštantami a ich mikroreliéfom často dominuje v radarovom obraze. Samozrejme vplyvom rôznych atmosférických podmienok (predovšetkým oblačnosť) sa mení aj dielektrická konštanta. Obzvlášť oblačnosť znižuje alebo zastavuje transpiráciu vegetácie, čo zase mení vodný potenciál, dielektrickú konštantu a radarový spätný rozptyl vegetácie. Vysokú návratnosť radarového signálu poskytujú aj kovové objekty (napr. železné mosty, stĺpy, hustá železničná sieť a podobne).



Obr. 6.9 Vplyv pôdnej vlhkosti na správanie spätného rozptylu. **Fig. 6.9** Effect of soil moisture on backscattering behaviour. Source: Salepci et al., 2018
6.3.2.2. Surface roughness

Ide o relatívnu vlastnosť predovšetkým závislú od vlnovej dĺžky a uhla dopadu. Povrch možno považovať za drsný, ak jeho povrchová štruktúra má rozmery porovnateľné s dopadajúcou vlnovou dĺžkou. Podľa Rayleighovho kritéria sa povrch považuje za drsný, ak platí:

$$h > \frac{\lambda}{8 \cdot \cos\theta} , \qquad (6.23)$$

kde *h* symbolizuje strednú výšku povrchových odchýlok, λ je vlnová dĺžka a θ je uhol dopadu. Príklady vplyvu drsnosti povrchu je možné pozorovať v zónach kontaktu medzi pôdou a vodnými plochami (Obr. 6.10). Vnútrozemské vodné útvary majú tendenciu byť relatívne hladké, pričom väčšina energie sa odráža iba miernym spätným rozptylom k radaru. Naopak, pôdne povrchy majú tendenčne vyššiu drsnosť. V oblasti mikrovlnného žiarenia môže byť tento rozdiel medzi príslušnými vlastnosťami pôdy a vody veľmi užitočný pre aplikácie, akými sú napríklad meranie rozsahu povodní alebo erózia pobrežných zón a podobne.



Obr. 6.10 Príklad vplyvu drsnosti povrchu na dvoch rôznych povrchoch. **Fig. 6.10** Example of the effect of surface roughness on two different surfaces. Source: after Richards, 2009

6.3.2.3. Backscatter

Výsledný signál spätne rozptýleného radarového žiarenia je výsledkom skupiny mechanizmov, pomocou ktorých môže dôjsť k rozptýleniu energie k senzorom. Pre dokonalejšiu interpretáciu SAR snímok je preto potrebné týmto rozptylovým mechanizmom porozumieť. Práve sila rozptylu závisí od dvoch predošlých vonkajších parametrov, teda dielektrickej konštanty materiálu a od drsnosti povrchu.

Prvým z rozptylov je **povrchový rozptyl** (angl. *Surface Scattering*), ktorý je definovaný ako rozptyl, ktorý sa vyskytuje iba na hraničnej ploche medzi dvoma rôznymi no homogénnymi prostrediami. Vo všeobecnosti platí, že koeficient rozptylu, ktorý je rozptyl plochy na jednotku plochy, je funkciou uhla dopadu a uhla rozptylu. V prípade DPZ je uhol rozptylu identický s uhlom dopadu, pretože prijímacia anténa radaru je umiestnená na rovnakom mieste ako vysielacia anténa. Z tohto dôvodu sa pri DPZ uvažuje iba spätný rozptyl, a teda plocha radarového prierezu je definovaná nasledovne:

$$\sum \sigma_i = \frac{P_r \cdot (4\pi)^3 \cdot R^4}{P_t \cdot G^2 \cdot \lambda^2} , \qquad (6.24)$$

ak zložka P_t symbolizuje vyslanú energiu, λ je vlnová dĺžka, P_r označuje prijatú energiu, G je zisk antény a písmenom R je vyjadrená vzdialenosť medzi radarom a objektom. Oblasť rozptylu na jednotku plochy sa označuje ako koeficient spätného rozptylu σ a určí sa zo vzťahu:

$$\sigma = \frac{\sigma_i}{A_i} , \qquad (6.25)$$

keď pod premennou A_i je označená diferenciálna plocha povrchového rozptylu. Hodnota tohto koeficientu je priamo závislá od drsnosti povrchu a tiež uhla dopadu.

Do druhej kategórie rozptylov patrí **objemový rozptyl** (angl. *Volume Scattering*). Ide o typ rozptylu vyskytujúci sa v médiu počas vysielania elektromagnetického žiarenia z jedného média na druhé médium. Typickým príkladom objemového rozptylu je rozptyl medzi stromami alebo vetvami, snehovými vrstvami, podpovrchovými alebo pôdnymi vrstvami a pod. Uhol rozptylu závisí od drsnosti povrchu, priemernej relatívnej permitivity a vlnovej dĺžky. Teda výslednú hodnotu objemového rozptylu σ^o určíme zo vzťahu:

$$\sigma^0 = \sigma^0_{p\hat{o}da} + \sigma^0_{veget\hat{a}cia} + \sigma^0_{p\hat{o}da-veg.}$$
(6.26)

Posledným typom rozptylu je **viacnásobný objemový rozptyl** (angl. *Multiple Volume Scattering*). V tomto prípade ide o takzvaný dvojitý odraz žiarenia od určitého prostredia, kde dochádza k jeho depolarizácii. Pre lepšie pochopenie uvádza nasledujúci obrázok (Obr. 6.11) znázornenie jednotlivých rozptylových situácii vo vzájomnej interakcii s pôdou a vegetáciou.



Obr. 6.11 Rôzne typy správania rozptylu: a) priamy rozptyl od pôdy, b) priamy rozptyl od vegetácie, c) viacnásobný rozptyl medzi pôdou a vegetáciou a d) viacnásobný medzivegetačný rozptyl. **Fig. 6.11** Different types of scatter behaviour: a) direct scatter from soil, b) direct scatter from vegetation, c) multiple scatter between soil and vegetation, and d) multiple inter-vegetation scatter.

Source: after Richards, 2009

6.3.2.4. Local slope and orientation

Spätne rozptýlený radarový signál a teda aj výsledné snímky môžu byť ovplyvnené zmenou lokálneho sklonu povrchu (Obr. 6.12). Uhol dopadu možno opísať ako uhol medzi smerom dopadu radarovej vlny a vertikálou, smerom k elipsoidu (napr. WGS84). Na druhej strane, lokálny uhol dopadu je ten, ktorý leží medzi smerom dopadu radarovej vlny a povrchovou normálou smerom k rozptyľovacej ploche. Ak vezmeme do úvahy pixely charakterizované iba nízkym lokálnym sklonom, predpokladá sa, že lokálny uhol dopadu sa dá aproximovať samotným uhlom dopadu.



Obr. 6.12 Vplyv lokálneho uhla dopadu. **Fig. 6.12** Effect of local angle of incidence. Source: after Salepci et al., 2018

6.4. SAR image characteristics

Zjednodušene možno povedať, že digitálny SAR obraz pripomína mozaiku malých obrazových prvkov, nazývaných pixely. Tie poskytujú komplexné informácie o **amplitúde** a **fáze** mikrovĺn (Obr. 6.13), ktoré sú spätne rozptýlené od množiny odrážačov na zemskom povrchu. Ide napríklad o horniny, líniové stavby, budovy, vegetáciu a podobne. Každý takýto pixel sa vzťahuje k určitej oblasti na povrchu, ktoré sa mierne prekrývajú v azimute aj v šikmej vzdialenosti, čo sa označuje ako **rozlíšenie bunky** (angl. *Resolution Cell*). Vizualizácia SAR snímky prebieha prostredníctvom stupnice odtieňov šedej farby. Konkrétne, oblasti so silnou amplitúdou a teda aj silným spätným rozptylom signálu (mestské oblasti, horniny a pod.) sú reprezentované svetlými pixelmi na výslednej SAR snímke. Pre oblasti s nízkou amplitúdou a tiež nízkym spätným rozptylom žiarenia (napr. stabilné a pokojné vodné plochy) sú charakteristické tmavé pixely.



Obr. 6.13 Vizualizácia SAR obrazu v odtieňoch šedej. **Fig. 6.13** Visualisation of SAR image in grayscale. Source: after Papčo, 2018

6.4.1. Thermal noise

Pri SAR snímkach je známe, že ich výsledný obraz je okrem požadovaného signálu doplnený aj o určitý šum. Pre účely ďalšej práce s obrazom je šum nežiaducim elementom, ktorý je zvyčajne superponovaný v tom istom pixeli. Jedným z nich je práve **tepelný šum** (angl. *Thermal noise*), ktorý je spôsobený miešaním častíc v komponentoch SAR systému. Možno povedať, že je jeho výskyt na snímke náhodný. Je vo vzájomnej interakcii, jednak so šírkou pásma snímajúceho systému, ako aj s teplotou prostredia, počas ktorej je systém v prevádzke. V praxi to znamená, že so zvyšujúcou sa teplotou a zároveň šírkou pásma je generovaný šum čoraz vyšší. Možno povedať, že tepelný šum má výrazný vplyv nielen na rádiometriu SAR snímok, ale aj na vzdialenosť signálu. Práve pri SAR systémoch možno túto zložku označovať za pomerne kritický parameter, najmä z dôvodu výrazného vplyvu na **pomer signálu k šumu** (angl. *Signal to Ratio*). Ak vezmeme do úvahy výkon signálu P_s a šumu P_N , pre výsledný výkon v SAR GRD produkte teda platí:

$$P_{SN} = G(P_S + P_N)$$
, (6.27)

ak *G* predstavuje celkový výkon potrebný na vytvorenie SAR snímky. Odstránenie tepelného šumu v procese predspracovania SAR družicových dát minimalizuje úroveň šumu, hlavne pri krížovo polarizovaných pásmach. Práve pri takomto type polarizácie je tepelný šum výraznou prekážkou pri ďalšom spracovávaní SAR snímok s nízkym spätným rozptylom. Typickým príkladom sú oblasti s pokojnou vodnou hladinou (napr. jazerá, priehrady a podobne). Možno tiež konštatovať, že zmeny tepelného šumu na SAR obraze nastávajú pozdĺžne v smere osi azimutu aj rozsahu.

6.4.2. Calibration

Kalibráciu možno zjednodušene definovať ako postup prevodu digitálnych pixelov obrazu na spätne rozptýlený kalibrovaný SAR signál. Podstatou kalibrácie SAR snímok je poskytnutie takých produktov, v ktorých je radarový spätný rozptyl v priamej interakcii s hodnotami jednotlivých pixelov. Kalibrácia zahŕňa komplexné procesy, ktoré si vyžadujú testovacie ciele a oblasti, aby sa čo najefektívnejšie odhadol vzor antény, ak je to možné. V SAR systémoch je možné sa stretnúť z troma druhmi kalibrácie a to rádiometrická, polarimetrická a interferometrická. Rádiometrická a polarimetrická kalibrácia SAR systému a následné dlhodobé sledovanie jeho rádiometrickej stability sú základnými úlohami na zabezpečenie kvality SAR dát. Ak sa na rádiometrickú kalibráciu pozrieme z fyzikálneho hľadiska, tak funkcia rádiometrickej odozvy daného snímacieho systému súvisí s ožarovaním obrazu *I* (resp. žiarenie zachytenej scény na snímke). Jeho intenzita *M* je merateľná a je možné ju vyjadriť ako:

$$M = f(I) \tag{6.28}$$

Rádiometrické kalibračné metódy pre účely dominancie intenzity ožiarenia využívajú funkciu inverznej odozvy v tvare:

$$g = f - 1 \tag{6.29}$$

Na základe toho je možné definovať vzťah na jej výpočet, ktorý má túto podobu:

$$g(m_A) = kg(m_B) , \qquad (6.30)$$

ak m_A a m_B charakterizujú namerané intenzity obrazu v bodoch A a B, a parametre k a g predstavujú expozičné pomery. Princíp fungovania kalibrácie znázorňuje Obr. 6.14.



Obr. 6.14 Fyzikálny princíp rádiometrickej kalibrácie. **Fig. 6.14** Physical principle of radiometric calibration. Source: after Skolnik, 1980

Rádiometrickú kalibráciu možno rozdeliť na dve základné skupiny. Prvou z nich je absolútna kalibrácia, ktorá sa používa medzi snímkami a určitou fyzikálnou veličinou. Pre určenie koeficientu spätného rozptylu je tento typ kalibrácie založený na vzájomnom porovnaní rôznosystémových výsledkov na podklade teoretických modelov. Pri odvodzovaní absolútnej kalibrácie sa využívajú ciele so stabilnou a známou radarovou vlnou, označované aj ako referenčné ciele. Druhým typom rádiometrickej kalibrácie je relatívna kalibrácia, využívaná výlučne iba medzi snímkami. Tento typ kalibrácie je využívaný práve v SAR systémoch charakteristické svojou relatívne stabilnou konfiguráciou. Základným prvkom relatívnej kalibrácie pre správnu interpretáciu SAR obrazu je charakterizácia vzoru a smerovania antény. Ten je možné vyjadriť prostredníctvom SAR bistatickej rovnice v tvare:

$$P_{R} = \frac{P_{T} g_{T} G_{T}(\theta_{T}, \varphi_{T}) g_{R} G_{R}(\theta_{R}, \varphi_{R}) \lambda^{2}}{(4\pi)^{3} R_{T}^{2} R_{R}^{2}} , \qquad (6.31)$$

ak dolné indexy *T* definujú parametre vysielania energie, konkrétne P_T je výkon vysielaného signálu, g_T vyjadruje zisky vysielača, $G_T(\theta_T, \varphi_T)g_R$ definuje vzor vysielacej antény a R_T predstavuje šikmú vzdialenosť od vysielacej antény až po cieľ. V prípade dolného indexu *R* sa parametre $P_R, g_R, G_R(\theta_R, \varphi_R)$ a R_R vzťahujú k prijatej energii. Posledný parameter rovnice λ definuje vlnovú dĺžku SAR systému. Súčasná doba ponúka niekoľko metód bistatickej kalibrácie, založených na princípe bodových cieľov, ktoré sú zhrnuté do dvoch základných ideí. Jedným z nápadov je použiť aktívny kalibračný cieľ s veľkým **radarovým prierezom RCS** (angl. *Radar Cross Section*) vo veľkom frekvenčnom rozsahu, ktorý je možné ľahko nakonfigurovať pre rôzne bistatické uhly. Na druhej strane je výroba aktívnych kalibračných cieľov pomerne nákladnou a zložitou záležitosťou. Druhým pohľadom je použitie pasívnych kalibračných cieľov.

6.4.3. Speckle effect

Škvrnitý efekt (angl. *Speckle effect*) v SAR je spôsobený kvôli zobrazovacím koherentným mechanizmom, ktorých vlny sú odrážané od veľkého množstva odrážačov na zemskom povrchu. Práve v homogénnom prostredí tvoreného nezávislými odrážačmi, reaguje SAR systém značnými zmenami amplitúdy. K tomuto javu dochádza pri návrate odrazeného mikrovlnného žiarenia, ktoré môže byť prijaté v rôznej (náhodnej) fáze, kvôli viacnásobným odrazom medzi odrážačmi. To sa prejavuje zvýšeným množstvom jasnejších a tmavších pixelov a takto navrstvený obraz pripomína kúsky soli a čierneho korenia (angl. Salt and Pepper). Teda tento jav spôsobuje, že výsledný SAR obraz má značne škvrnitý vzhľad, ktorý znižuje schopnosť pozorovať detaily v obraze. Tento neželaný jav je samozrejme možné eliminovať viacerými spôsobmi. Jedným z nich je použitie nástrojov na vykonanie priemeru hodnôt susedných pixelov pre danú SAR snímku. Metódy filtrácie škvrnitého efektu v SAR obrazoch možno rozdeliť na dve skupiny, konkrétne **priestorové** a **transformačné**. Medzi najpoužívanejšie priestorové filtračné nástroje patria:

• **Kuanova filtrácia** – princíp tohto filtra je založený na minimálnej strednej štvorcovej chybe, pričom optimálny stav nastáva pri Gaussovom rozdelení scény aj intenzity. Odhad hodnoty pixela možno vyjadriť nasledovne:

$$\hat{x} = \bar{y} + \frac{\sigma_x^2 (y - \bar{y})}{\sigma_x^2 + (\bar{y}^2 + \sigma_x^2)/L} , \qquad (6.32)$$

ak pre platí:

$$\sigma_x^2 = \frac{L\sigma_y^2 - \bar{y}^2}{L+1} , \qquad (6.33)$$

ak uvažujeme a predpokladáme.

- Leeová filtrácia ide o Kuanov filter avšak s drobnou zmenou, a to odstránením výrazu z rovnice, kvôli lineárnej aproximácii.
- Frostová filtrácia združuje hodnoty pixelov obrazu, ktoré majú fixovanú veľkosť okna s impulznou odozvou m, pre ktorú platí:

$$m = exp\left[-KC_{y}(t_{0})|t|\right] \qquad C_{y} = \frac{\sigma_{y}}{\bar{y}}, \qquad (6.34)$$

ak *K* reprezentuje parameter filtra, t_0 určuje polohu spracovávaného pixela a premenná |t| vyjadruje vzdialenosť od t_0 .

 Gamma MAP (Maximum a Posteriori) filtrácia – ide o aposteriórny filter, predpokladajúci gamma distribúciu nielen pre škvrnitý šum, ale aj pre odrazivosť radaru. Je daná odhadom pomocou vzťahu:

$$\hat{x} = \frac{(\alpha - L - 1)\bar{y} + \sqrt{\bar{y}^2(\alpha - L - 1)^2 + 4\alpha L y \bar{y}}}{2\alpha} , \qquad (6.35)$$

ak pre α platí nasledovné:

$$\alpha = \frac{L+1}{L(\sigma_y \overline{/y})^2 - 1} , \qquad (6.36)$$

ak platí $\hat{x} = \bar{y}$.

- Lee Sigma filtrácia princíp spočíva vo vykonaní priemeru vybraných pixelov v rozmedzí dvoch štandardných odchýlok σ vzťahujúcich sa k stredovému pixelu v danom skenovacom okne. Teda za odľahlé hodnoty sú považované všetky pixely mimo rozsahu oboch parametrov σ. V praxi to znamená ponechanie vysokokontrastných pixelov a na druhej strane nepostačujúcu filtráciu šumu pri tmavších pixeloch. Je to spôsobené malým rozsahom sigma spojeným s tmavými pixelmi modelu multiplikatívneho šumu, a preto pre tieto pixely nie je vykonaná žiadna filtračná akcia (Yu et al., 2018).
- Mediánová filtrácia ide o ďalší jednoduchý filtračný nástroj, založený na výpočte mediánov, štandardných odchýlok a ďalších jednoduchých štatistík, podobne ako predchádzajúci Lee Sigma filter. Základný rozdiel oproti Lee Sigma filtrácii spočíva v nahradení iba stredového pixela, pokiaľ predstavuje škvrnitý šum. Pokiaľ stredový pixel nepredstavuje šum, ponecháva si svoju pôvodnú hodnotu. To znamená, že nedochádza k jeho nahradeniu. Tým pádom sú pre výpočet využívané hodnoty lokálneho priemeru ± násobok lokálneho σ.
- Priemerová (MEAN) filtrácia podstata tohto nástroja je v nahradení stredového pixela strednou hodnotou pixelov skenovacieho okna. Nevýhodou je častá strata rozlíšenia, ktorú je však možné eliminovať použitím malých okien (3x3 resp. 5x5).
- A **d'alšie** odvodené filtre (Obr. 6.15).

Pre všetky uvedené filtre platí, že parameter *x* symbolizuje ten pixel obrazu, ktorý je zasiahnutý **zrnitým šumom** (angl. *Speckle noise*) *n*, kde platí *y* = *nx*. Pri väčšine štandardných filtrov je podmienka poznať štandardné odchýlky σ_y a σ_n , a tiež hodnotu . V praxi sa však σ_y a σ_y lokálne odhadne, pričom odchýlka σ_n je vstupom pre daný filter.



Obr. 6.15 SAR snímka pred filtráciou (vľavo) a po filtrácii (vpravo) zrnitého šumu. **Fig. 6.15** SAR image before (left) and after (right) speckle noise filtering. Source: own processing

Do priestorových metód možno zaradiť aj filtračné metódy ako NLM metóda (metóda odšumovania nelokálneho priemeru) a maticové odšumovacie metódy. Pri posledných dvoch však bola zistená tendencia stmavnutia výsledného SAR obrazu. Práve použitie priestorových filtrov patrí k často používaným spôsobom upravenia obrazu. Ich nevýhodou je však citlivosť vzhľadom na veľkosť jadra filtra. V takomto prípade môže byť problémom zachovanie detailov SAR snímky z dôvodu nevyváženej sily v procese "odšumenia." Jednoducho povedané pri väčšej veľkosti filtra už nemusí výsledný obraz obsahovať požadované podrobnosti a detaily. A v prípade malej veľkosti filtra nemusí dôjsť k úplnému potlačeniu Speckle efektu. Pokiaľ ide o **transformačné** metódy najznámejšou je **lineárna minimálna stredná chyba štvorca LMMSE** (angl. *Linear minimum mean-square error*), vykonávajúce viacrozmernú dekompozíciu obrazu s následnou filtráciou jednotlivých častí obrazu a ich následným "spojením." Ich výhodou je pomerne presné zachovanie textúr a hrán obrazu oproti priestorovým filtračným metódam. Nevýhodou je však ich použitie v homogénnych oblastiach.

6.4.4. Geometric correction

Napriek tomu, že SAR systémy počas svojej prevádzky prekonávajú rôzne poveternostné vplyvy a iné náchylnosti, stále však majú obrazové SAR produkty určitú geometrickú deformáciu obrazu v porovnaní so skutočným povrchom Zeme. Takéto neželané javy obrazu sú spôsobené najmä naklonením SAR snímača a topografickými variáciami. Pre plnohodnotné spracovanie a vyhodnocovanie SAR údajov je potrebné takto vyvolané terénne účinky eliminovať resp. opraviť, aby sa znázornenie obrazu po korekcii priblížilo reálnemu svetu čo najefektívnejšie. Teda geometrická korekcia je výpočtový proces odstraňovania deformácií, aby sa získal geograficky zhodný obraz. Ortokorekcia odstraňuje účinky terénu a uhla tým, že vykonáva úpravu obrazu na známy súradnicový systém, pričom je nevyhnutné použitie **digitálneho výškového modelu DEM** (angl. *Digital Elevation Model*). Ďalšou možnosťou je vykonanie georektifikácie, teda lokalizácie obrazu bez súradnicového systému do známeho súradnicového systému. Avšak tieto opravené údaje by sa vo všeobecnosti nemali považovať za terénne opravené, pretože neexistuje ich prispôsobenie s miestnou nadmorskou výškou a sklonom.



Obr. 6.16 Princíp geometrickej korekcie pri SAR systémoch. **Fig. 6.16** Principle of geometric correction for SAR systems . Source: own processing

Ak vezmeme do úvahy geometriu družicového SAR systému (Obr. 6.16), SAR senzor v polohe S sníma cieľ T na zemskom povrchu. V závislosti od použitia jednoduchého elipsoidu θ_E alebo iného alternatívneho modelu terénu θ_{LIM} dochádza k odlišnostiam pri odhade uhla dopadu. V dôsledku výškových rozdielov naprieč smerom stopy snímania však spôsobuje bočná geometria SAR systému tieto signifikantné skreslenia. Tie boli okrajovo spomínané v podkapitole popisujúcej SLAR geometriu snímania. Ide teda o:

- **zhustenie signálu** (angl. *Foreshortening*), ktoré je funkciou lokálneho uhla dopadu θ_{loc} s lokálnym sklonom α , prostredníctvom vzťahu $\theta_{loc} = \theta \alpha$. V situácii ak $\theta = \alpha$ je fazeta (skosená hrana terénu) premietnutá do bodu, nachádzajúceho sa na radiálnej osi.
- prekryt (angl. Layover), ktorý nastáva, ak je radiálna vzdialenosť α menšia ako vzdialenosť základne, čiže platí α>θ. Splnením tejto podmienky tak dochádza k transformácii skracovania na prekryt, niekedy prekladaný aj ako medzipriestor. V podstate ide teda o nedostatočnú schopnosť rozlíšenia horizontálnej a vertikálnej zložky merania.
- **tieň** (angl. *Shadow*) ku ktorému dochádza, ak fazeta nie je ožiarená radarovým signálom a teda platí $\alpha < -\theta$. Pokiaľ ide o odrazivosť, tá v tomto prípade dosahuje minimálnu hodnotu, ktorú možno porovnať s hodnotou radarového šumu pri podmienke $\theta_{loc} > 80^{\circ}$. Pre lepšiu predstavivosť je rozdelenie spomínaných skreslení znázornené na nasledujúcom obrázku (Obr. 6.17).



Obr. 6.17 Geometria snímania a jej skreslenia. **Fig. 6.17** Geometry of imaging and its distortions. Source: Ferro-Famil et al., 2016

V súčasnosti existuje niekoľko typov topografických korekcií, medzi ktoré patria range-Dopplerova korekcia (angl. *Range-Doppler*), korekcia racionálnych

polynomiálnych koeficientov (angl. *Rational Polynomial Coefficients*), prepracovaná polynomiálna korekcia (angl. *Revised Polynomial*) a ďalšie. Najviac rozšírenou korekciou pri spracovaní SAR obrazu je práve Dopplerova korekcia. Nakoľko SAR patrí medzi aktívne zobrazovacie systémy, dokáže poskytovať dostatočne presné dopplerovské informácie a informácie o sklone. Vďaka ním je možné definovať geo-lokalizačný model prostredníctvom sústavy nasledujúcich rovníc:

$$\frac{X_T^2 + Y_T^2}{(R_e + H_T)^2} + \frac{Z_T^2}{R_p^2} = 1 ,$$

$$R = R (i, j) ,$$

$$f_d = -\frac{2}{\lambda} \frac{dR}{dT} ,$$
(6.37)

ak zložky X_T^2, Y_T^2 a Z_T^2 predstavujú súradnice cieľa *T* na zemskom povrchu, (*i,j*) symbolizuje číslo riadku a stĺpca pixela v SAR obraze, R_p je polárny polomer elipsoidu Zeme, R_e rovníková (ekvatoriálny) polomer elipsoidu Zeme, λ definuje vlnovú dĺžku SAR systému, parameter f_d symbolizuje dopplerovskú frekvenciu, H_T je výška cieľa na zemskom povrchu a R (*i,j*) vyjadruje šikmý rozsah pixelov. Podstatou geometrickej korekcie je teda transformačná zmena dopplerovských súradníc na geografické súradnice, pričom sa zohľadňuje posun medzi referenčným elipsoidom pre projekciu DEM a tiež referenčným elipsoidom opisujúcim geometriu obežnej dráhy snímača.

References

Books

Andía, G. Duroc, Y. Tedjini, S.: Non-linearities in Passive RFID Systems – Third Harmonic Concept and applications, London: ISTE Ltd., 2018. 29 s. ISBN 978-1-78630-226-7

Dobrovolný, Petr: Dálkový prôskum Země: Digitální zpracování obrazu, Brno: Masarykova univerzita, 1998. IV, 208 s. ISBN 80-210-1812-7 (brož.)

Ferretti, A. Monti-Guarnieri, A. Prati, C.: InSAR Principles: Guidelines for SAR Interferometry Processing and Interpretation. Noordwijk: ESA Publications, 2007. 234 s. ISBN: 92-9092-233-8

Ferro-Famil, L. Pottier, E.: 1 - Synthetic Aperture Radar Imaging. Microwave Remote Sensing of Land Surface: Elsevier. 2016. pp. 1-65. ISBN 9781785481598.

Hansen, R. F.: Radar Interferometry Data Interpretation and Error Analysis. Dordrecht: Springer, 2001. 308 s. ISBN 978-0-7923-6945-5

Henri, M.: Processing of Synthetic Aperture Radar Images. ISTE Ltd. 2008. 384 s. ISBN 978-1-84821-024-0.

Kolář, Ján Halounová, Lena Pavelka, Karel: Dálkový průskum Země, Praha: ČVUT, 1997. 164 s. ISBN 80-01-01567-X (brož.).

Leško, M.: Využitie radarovej interferometrie na tvorbu digitálneho modelu terénu: Bakalárska práca. Bratislava, 2014. 54p.

Maitre, H.: Processing of Synthetic Aperture Radar Images, London: ISTE Ltd, 2008. 411 s. ISBN 978-1-84821-024-0

Mott, H.: Remote Sensing with Polarimetric Radar. John Wiley & Sons, Inc. 2007. 284 s. ISBN 9780470079812.

Raymond, C. Watson, Jr. (2009). Radar Origins Worldwide: History of Its Evolution in 13 Nations Through World War II. Trafford Publishing, 45 s. ISBN 978-1-4269-9156-1

Richards, J. A.: Remote Sensing Digital Image Analysis: An Introduction. Fifth Edition. Springer, 2013. 503 s. ISBN 978-3-642-30061-5.

Richards, J. A.: Remote Sensing with Imaging Radar, Berlin: Springer, 2009. 373 s. ISBN 978-3-642-02019-3

Skolnik, M. I.: Introduction to Radar Systems (Third Edition), Singapore: McGraw-Hill Book Company, 1980. 590 s. ISBN 0-07-057909-1

Svatoňová: Dálkový průskum Země, Brno: Masarykova univerzita, 2010, 94 s. ISBN 978-80-210-5162-1

Szekielda, K. H.: Satellite Monitoring of the Earth, New York: Wiley, 1988, 326 s. ISBN 0-471-61330-4

Woodhouse, H. I.: Introduction to microwave remote sensing, CRC Press, 2005. 400 s. ISBN 978-0415271233.

Papers, manuals, reports

Bovenga, F.: Synthetic Aperture Radar (SAR) Techniques and Applications. Sensors, Vol. 20, 1851. 2020.

Carreno Conde, F. De Mata Munoz M.: Flood Monitoring Based on the Study of Sentinel-1 SAR Images: The Ebro River Case Study. Water, Vol. 11 (12), 2454. 2019. 25 s. ISSN 2073-4441.

Chan, Y. K. Koo, V. C.: An Introduction to Synthetic Aperture Radar (SAR). Malaysia: Progress In Electromagnetics Research B, Vol. 2, 27–60. 2008. 34 s.

Chen, S. Wang, H. Xu, F. Jin, Y. Q.: Target Classification Using the Deep Convolutional Networks for SAR Images. IEEE Transactions on Geoscience and Remote Sensing, Vol. 54, no. 8. 2016. pp. 4806-4817. ISSN 1558-0644.

Chen, Q. L. Zhang, Y. Z. Ekroos, A. Hallikainen, M.: The role of remote sensing technology in the EU water framework directive (WFD): Environmental Science & Policy, Vol. 7 (4), 2004. pp. 267–276. ISSN 1462-9011.

Dingle Robertson, L. et al.: Synthetic Aperture Radar (SAR) image processing for operational space-based agriculture mapping. International Journal of Remote Sensing, Vol. 41 (18). 2020. pp. 7112-7144.

Dubois-Fernandez, P. et al.: ONERA-DLR bistatic SAR campaign: Planning, data acquisition, and first analysis of bistatic scattering behaviour of natural and urban targets. IEE Proceedings Radar Sonar and Navigation, Vol. 153 (3). 2004. pp. 214-223. ISSN 1350-2395.

Fang, Q. et al.: Speckle Noise Reduction in SAR Imagery Using a Local Adaptive Median Filter. GIScience & Remote Sensing, Vol. 41 (3). 2004. pp. 244-266.

Ferazzoli, P. Guerriero, L.: Passive Microwave Remote Sensing of Forests: A Model Investigation. United States: IEEE Transactions on Geoscience and Remote Sensing, 1996. Vol. 34, no. 2, pp. 433-443.

Gagnon, L. Jouan, A.: Speckle filtering of SAR images: a comparative study between complex-wavelet-based and standard filters. Wavelet Applications in Signal and Image Processing, Vol. 3169. 1997. pp. 80-91.

Guccione, P. et al.: Low-Frequency SAR Radiometric Calibration and Antenna Pattern Estimation by Using Stable Point Targets. IEEE Transactions on Geoscience and Remote Sensing, Vol. 56, no. 2. 2018. pp. 635-646. ISSN 1558-0644.

Haj, M.E. Baghdadi, N. Zribi, M. Angelliaume, S.: Analysis of Sentinel-1 Radiometric Stability and Quality for Land Surface Applications. Remote Sensing, Vol. 8 (5), 406. 2016. ISSN 2072-4292.

Hogland, J. Billor, N. Anderson, N.: Comparison of standard maximum likelihood classification and polytomous logistic regression used in remote sensing. European Journal of Remote Sensing, Vol. 46, No. 1. 2013. pp. 623– 640.

Huang, C. Chen, Y. Wu, J. P.: Mapping spatio-temporal flood inundation dynamics at large river basin scale using time-series flow data and MODIS imagery. International Journal of Applied Earth Observation and Geoinformation, Vol. 26. 2014. pp. 350–362. ISSN 0303-2434.

Jackson, T. J.: III. Measuring surface soil moisture using passive microwave remote sensing. John Wiley & Sons, Ltd, Vol. 7, No. 2. 1993. pp. 139-152.

Lee, J. S. Grunes, M.R. De Grandi, G.: Polarimetric SAR Speckle Filtering and Its Implication for Classification. IEEE Transactions on Geoscience and Remote Sensing, Vol. 37 (5). 1999. 11 s. ISSN 1558-0644.

Lee, J. S. et al.: Speckle filtering of synthetic aperture radar images: A Review. Remote Sensing Reviews, Vol. 8, no. 4. 1994. pp. 313-340.

Lin, S. Gu, J. Yamazaki, S. Shum, H-Y.: Radiometric calibration from a single image. Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Vol. 2. 2004. pp. II-II. ISSN 1063-6919.

Lining, G. Xiaosong, X. Xiao, M.: Research on software cache applied to the Geometric Correction of SAR images. IET International Radar Conference 2013. 2013. 7 s. ISBN 978-1-84919-603-1.

Liu, S. et al.: SAR Speckle Removal Using Hybrid Frequency Modulations. IEEE Transactions on Geoscience and Remote Sensing, Vol. 59 (5). 2021. pp. 3956-3966. ISSN 0196-2892.

Loew, A. Mauser, W.: Generation of geometrically and radiometrically terrain corrected SAR image products. Remote Sensing of Environment, Vol. 106 (3). 2007. pp. 337-349 ISSN 0034-4257.

Papčo, J.: Teoretické aspekty družicovej radarovej interferometrie: Prezentácia. Košice, Slovensko. 85p.

Park, J. W. et al.: Efficient Thermal Noise Removal for Sentinel-1 TOPSAR Cross-Polarization Channel. IEEE Transactions on Geoscience and Remote Sensing, Vol. 56 (3). 2018. pp. 1555-1565. ISSN 1558-0644.

Pienaar, M. et al.: Active calibration target for bistatic radar cross-section measurements. Radio Science, Vol. 51 (5). 2016. pp. 515–523.

Prati, C. Rocca, F.: Improving slant-range resolution with multiple SAR surveys: IEEE Transactions on Aerospace and Electronic Systems, Vol. 29, no. 1. 1993. pp. 135-143.

Salepci, N. Thiel, Ch.: SAR techniques & Applications for Forestry: Prezentácia. ESA PECS Training Course Bratislava, Slovensko 2018. 74 s.

Satalino, G. Balenzano, A. Mattia, F. Davison, M. W. J.: C-Band SAR Data for Mapping Crops Dominated by Surface or Volume Scattering: IEEE Geoscience and Remote Sensing Letters, Vol. 11 (2). 2014. pp. 384-388.

Shirvany, R. Chabert, M. Tourneret, J. Y.: Estimation of the Degree of Polarization for Hybrid/Compact and Linear Dual-Pol SAR Intensity Images: Principles and Applications. IEEE Transactions on Geoscience and Remote Sensing, Vol. 51, no. 1. 2013. pp. 539-551. ISSN 1558-0644.

Small, D.: Flattening Gamma: Radiometric Terrain Correction for SAR Imagery. IEEE Transactions on Geoscience and Remote Sensing, Vol. 49 (8). 2011. pp. 3081-3093. ISSN 1558-0644.

Suneela Mishra, J. V. D. Misra T.: Thermal Noise Removal in Hybrid Polarimetry SAR Data. Earth Observing Missions and Sensors: Development, Implementation, and Characterization, Vol. 9881. 2016, pp. 347-353.

Tilley, D. G. Bonwit, K. S.: Reduction of layover distortion in SAR imagery. Remote Sensing of Environment, Vol. 27 (3). 1989. pp. 211-220. ISSN 0034-4257

Touzi, R.: A review of speckle filtering in the context of estimation theory. IEEE Transactions on Geoscience and Remote Sensing, Vol. 40, no. 11, 2002. pp. 2392–2404. ISSN 1558-0644.

Wang, W. Q.: Inflight Antenna Pattern Measurement for Bistatic Synthetic Aperture Radar Systems. IEEE Antennas and Wireless Propagation Letters, Vol. 6. 2007. pp. 432-435.

Wang, G. Zi, W. Xie, CH. Zhang, F.: Dual-aspect geometric and radiometric terrain correction method for highresolution SAR data. 2011 IEEE International Geoscience and Remote Sensing Symposium, 2011, pp. 1894-1897. ISSN 2153-7003. Wegmuller, U.: Automated terrain corrected SAR geocoding. IEEE 1999 International Geoscience and Remote Sensing Symposium. IGARSS'99 (Cat. No.99CH36293), Vol. 3. 1999. pp. 1712-1714. ISBN 0-7803-5207-6.

Yu, Z. et al.: Speckle Noise Suppression in SAR Images Using a Three-Step Algorithm. Sensors, Vol. 18 (11), 3634. 2018. ISSN 1424-8220.

Zheng, Q. Wang, Y. Hong, J. Wang, A.: Feasibility, Design, and Deployment Requirements of TCR for Bistatic SAR Radiometric Calibration. Remote Sensing, Vol. 10(10), 1610. 2018. ISSN 2072-4292.

Web sources

earth.esa.int/web/guest/missions/esa-operational-eo-missions/ers/instruments/sar/applications/radarcourses

sar.kangwon.ac.kr/etc/rs_note/rsnote/contents.htm

www.radartutorial.eu/druck/index.en.html

https://nsidc.org/cryosphere/seaice/study/passive_remote_sensing.html

7

SAR Applications – Interferometry, Polarimetry

SAR data from radar remote sensing is characterised by the phase angle of the backscattered signal for a particular pixel in the image. Due to the relatively simple measurement of the phase signal, it is possible to compare the phase differences (interference) of the same region in two different images (or even more). Based on this type of comparison, it is then possible to find the relative positions of the pixels and their parameters, which are longitude, latitude, altitude, or their equivalents.

SAR polarimetry is applicable in sectors of landscape characterisation such as forestry, agriculture, and others. The essence of this method is the ability to transmit information from an object to a sensor via electromagnetic waves. These waves propagate at the speed of light, either from the object directly through free space or indirectly by reflection, scattering or radiation to the sensor. The interaction of EM waves with the atmosphere and natural surfaces is strongly dependent on the frequency of the waves.

SAR interferometry, also referred to as Interferometric Synthetic Aperture Radar, is a method that can be used to measure displacements and elevation changes of landforms using the phase difference between two radar acquisitions. It uses radar waves, transmitted from space antennas and backscattered onto the Earth's surface, to measure changes between different radar acquisitions at different times.

The term SAR polarimetry, also referred to as PolSAR, can be defined as the field of RS, concerned with the acquisition, processing and analysis of the polarisation state of the electromagnetic field. In SAR polarimetry, information is transmitted from the object to the sensor using electromagnetic waves. This information can be encoded in the frequency content, intensity or polarisation of the electromagnetic wave.

This chapter describes both methods of application of SAR systems in the satellite RS segment in more detail.

· e esa

7.1. Introduction

V posledných dvoch desaťročiach sme svedkami vzostupnej popularity aplikácie SAR snímok pre účely topografického mapovania. Pomerne často sa takého mapovanie realizuje na podklade satelitných dát a za pomoci interferometrie. Pre SAR dáta je charakteristický fázový uhol spätne rozptýleného signálu pre konkrétny pixel na snímke. Vďaka pomerne jednoduchému meraniu fázového signálu je možné porovnať fázové rozdiely (interferenciu) tej istej oblasti na dvoch rôznych snímkach (prípadne aj na viacerých). Na základe takéhoto typu porovnania je potom možné nájsť relatívne polohy pixelov a ich parametre, ktorými sú zemepisná dĺžka, zemepisná šírka, nadmorská výška, prípadne ich ekvivalenty.

Ďalším spôsobom spracovania a vyhodnocovania výsledkov družicového DPZ predstavuje SAR polarimetria, uplatniteľná v odvetviach charakteristiky krajiny ako lesníctvo poľnohospodárstvo a podobne. Pokiaľ ide o SAR polarimetriu, podstatou tejto metódy je schopnosť prenosu informácií z určitého objektu do senzore prostredníctvom elektromagnetických vĺn. Je známe, že tieto vlny sa šíria rýchlosťou svetla a to buď z objektu priamo cez voľný priestor, alebo nepriamo odrazom, rozptylom, prípadne žiarením k senzoru. Teda interakcia elektromagnetických vĺn s atmosférou a prírodnými povrchmi je silne závislá od frekvencie vĺn.

Nasledujúca kapitola bližšie popisuje obe metódy aplikácie SAR systémov v segmente družicového DPZ.

7.2. SAR Interferometry

SAR interferometria, označovaná tiež ako **InSAR** (angl. *Interferometric Synthetic Aperture Radar*) je metóda, ktorú možno použiť na meranie posunov a výškových zmien reliéfov pomocou fázového rozdielu medzi dvoma akvizíciami radaru. Využíva radarové vlny, vysielané z kozmických antén a spätne rozptýlené na zemský povrch, na meranie zmien medzi rôznymi akvizíciami radaru v rôznych obdobiach. Avšak nie vždy je možné použiť InSAR na meranie pôdnych deformácií v dôsledku obmedzení technológie, akými sú napr. interferometrický šum spôsobený priestorovými a geometrickými dekoreláciami, tepelný šum, dekorelácia Dopplerovho centroidu a nerovnomerné rýchlosti deformácie s vysokými priestorovými gradientmi počas dvoch SAR akvizícií. Preto je dôležité vedieť, kedy je možné túto technológiu efektívne použiť na meranie deformácií a naopak, kedy to nie je veľmi výhodné. Geometria SAR interferometrie je podľa načrtnutej situácie (Obr. 7.1) definovaná nasledovnými parametrami:

- **interferometrická základnica B** (angl. *Interferometric Baseline*), ktorá definuje vzdialenosť medzi dvoma družicami v rovine kolmej na obežnú dráhu,
- **kolmá základnica Bp** (angl. *Perpendicular Baseline*), čo je projekcia interferometrickej základnice kolmá na šikmý smer,
- **uhol pohľadu** SAR signálu θ_l
- rozsah vzdialeností pre príslušné akvizície, označený ako r₁ a r₂
- rozdiel vzdialeností r₁ a r₂, definovaný symbolom Δr



Obr. 7.1 Zjednodušené zobrazenie geometrie SAR interferometrie. **Fig. 7.1** Simplified representation of the SAR interferometry geometry. Source: Salepci et al., 2018

Pre SAR interferometriu je charakteristické, že pri jej aplikácii môžu byť dáta získané z rôznych konfigurácií snímania. To znamená, že daná lokalita nemusí byť snímaná iba jedným radarovým systémom z dvoch susedných dráh, ale aj dvoma radarmi na dvoch rôznych družiciach (tandemový typ snímania napr. družice ERS), prípadne iným typom kompozície (dve antény). Medzi najdôležitejší krok pri akomkoľvek interferometrickom spracovaní radarových dát patrí bezpochyby stanovenie kritérií pri výbere vhodných snímok. Ide o kľúčový parameter, pretože od spomenutých vhodných kritérií závisí, v akej podobe a s akou kvalitou a presnosťou bude disponovať výsledok. Ide o tieto kritériá:

- uhol pohľadu (vzostupné a zostupné prechody),
- čas akvizície,
- koherencia,
- geometrická základnica,
- časová základnica,
- meteorologické podmienky.

Presnosť tejto metódy závisí najmä od počtu družicových snímok, ich kvality, časovej hustoty dát, ich presnosti a v neposlednom rade od dostatočného počtu odrážačov, resp. odrážačov za zemskom povrchu. Vo všeobecnosti je však metóda InSAR schopná určovať rozdiely s presnosťou až 1 milimeter Pre účely interferometrického spracovania je možné použiť SAR snímky v ľubovoľnom pásme mikrovInného spektra (C, L alebo X pásmo). Pri získavaní SAR produktov je však potrebné zvoliť správny typ produktu. Napríklad dáta z družice Sentinel-1 produktového typu GRD nie sú na tento účel vhodné, nakoľko táto produktová úroveň neobsahuje informácie o fáze. Takýto výsledný produkt má približné štvorcové priestorové rozlíšenie pixelov. Pre interferometické spracovanie sa tak využíva dátová produktová úroveň SLC (angl. *Single-Look Complex*), charakteristická koherentným režimom snímania. Dôležitým pre interferometrické spracovanie je tiež výber režimu snímania IW (angl. *Interferometric Wide Swath*) v prípade použitia snímok Sentinel-1.

7.2.1. DInSAR

Metóda **DINSAR** (angl. *Differential Interferometric Synthetic Aperture Radar*) spočíva v spracovaní dvojice SAR snímok do podoby interferogramov, ktorých výsledkom je znázornenie fázového rozdielu radarových vĺn, označovaný ako $\Delta \varphi$ (Obr. 7.2). Ide o určovanie deformácií zemského povrchu pomocou interferometrie s opakovaným prechodom. Je dobre známe, že pixel v obraze SAR mení svoju fázu kvôli niekoľkým faktorom a to relatívnej polohe satelitného rozptylu, možným časovým zmenám cieľa a atmosférickým zmenám.



Obr. 7.2 Zjednodušený princíp interferometrickéj metódy DInSAR. **Fig. 7.2** Simplified principle of the DInSAR interferometric method. Source: www.un-spider.org/links-and-resources/data-sources/daotm-land-deformation

Spracovanie SAR snímok pomocou DINSAR metódy využíva podobne ako INSAR jednu **hlavnú** (tzv. *Master*) a druhú **vedľajšiu** (tzv. *Slave*) snímku. To znamená, že za hlavnú sa považuje snímka pred monitorovanou zmenou a vedľajšiu po zmene (resp. aj počas ak zmena neustále pretrváva). Spomínaný fázový rozdiel radarových vĺn $\Delta \varphi$ je možné určiť z nasledujúceho vzťahu:

$$\Delta \varphi = \Delta \varphi_f + \Delta \varphi_{el} + \Delta \varphi_d + \Delta \varphi_a + \Delta \varphi_n , \qquad (7.1)$$

ak $\Delta \varphi_f$ je zložka zakrivenia zeme, $\Delta \varphi_{el}$ je topografická zložka, $\Delta \varphi_d$ symbolizuje pohyby pixelov v smere LOS resp. priamej viditeľnosti (angl. *Line of Sight*), $\Delta \varphi_a$ je zložka oneskorenia atmosférickej fázy medzi prechodmi a $\Delta \varphi_n$ je fázový šum spôsobený variabilitou rozptylu. V procese generovania interferogramu je potrebné redukovať prvé 2 zložky horeuvedenej rovnice t.j. $\Delta \varphi_f$, $\Delta \varphi_{el}$. Konkrétne na základe obežných dráh satelitov a matematického modelu Zeme sa z interferogramov odstráni hodnota $\Delta \varphi_f$. Pokiaľ ide o topografickú zložku $\Delta \varphi_{el}$, na jej odhad sa poväčšine používa družicový digitálny model SRTM, prípadne iný typ DEM. Odstránenie zložky atmosférickej fázy $\Delta \varphi_a$ prebieha pomocou výberu stabilnej referenčnej oblasti. Možnosti monitorovania posunov a deformácií zemského povrchu DInSAR metódou sú založené na týchto princípoch:

- použitie jedného interferogramu (angl. Single Interferogram) odvodenie výsledkov za pomoci jedného interferometrického páru je reprezentované konfiguráciou s nulovou redundanciou. Pri takejto konfigurácii nie je možné skontrolovať prítomnosť atmosférických chýb, a teda odhad deformácie nie je spoľahlivý. To sa samozrejme týka aj DEM, ktoré sú odvodené z jednotlivých InSAR párov.
- použitie viacerých interferogramov (angl. Multiple Interferogram) Redundanciu pozorovaní je možné využiť na kontrolu a zníženie atmosférických účinkov a vplyvu iných zdrojov chýb. Samozrejme jej využitie je možné aj pri posúdení presnosti výsledkov.



Obr. 7.3 Znázornenie interferogramu ako výstupu pri spracovaní SAR snímok metódou DINSAR. **Fig. 7.3** Representation of the interferogram as an output of DINSAR image processing. Source: step.esa.int/images/amatrice_eq_s1tbx_outputs/S1A_Amatrice_asc_phase_25p.png

7.2.2. PSInSAR

Interferometrická **metóda perzistentných odrazov PSInSAR** (angl. *Persistent Scatterers Interferometric SAR*) je pokročilá metóda multitemporálnej satelitnej radarovej interferometrie (MTInSAR), ktorá bola vyvinutá za účelom sledovania povrchových deformácii na rozsiahlych územiach s vysokou presnosťou a odstránením nedostatkov vyplývajúcich z použitia metódy DInSAR. Jej rozdiel spočíva najmä v tom, že sa zameriava na zmiernenie problému dekorelácie, pri generovaní časového rádu fázových zmien bez atmosférických efektov a reziduálnych efektov DEM. Teda metóda PSInSAR je definovaná využitím jednej hlavnej snímky a množiny vedľajších snímok. Tento typ spracovania bol vyvinutý na konci deväťdesiatych rokov A. Ferrettim a kol. v Taliansku, konkrétne na Technickej univerzite v Miláne, kde sa tejto technológii venujú

rôzni odborníci dodnes. Technika perzistentných (trvalých) odrazov PS zabezpečuje detekciu tých buniek, v ktorých pri odraze signálu dominuje jediný odraz (Obr. 7.4). Príkladmi takýchto objektov sú napr. budovy, mosty priehrady, priemyselné areály, nadzemné vodovody (prípadne iné IS), antény, prípadne stabilné prírodné odrážače tzv. "reflektory". Priestorová hustota PS je mimoriadne závislá od krajinnej pokrývky, jej tvaru, veľkosti a orientácii rôznorodých štruktúr. Výber odrazových PS bodov je založený na analýze amplitúdy fázovej stability PS bodov.



Obr. 7.4 Intenzita signálu odrazových bodov pri DInSAR a PSInSAR metóde. **Fig. 7.4** Signal intensity of scatterers in DInSAR and PSInSAR methods. Source: Hooper, 2016

Proces interferometrického spracovania SAR dát pomocou techniky PS možno definovať do týchto základných krokov:

- tvorba interferogramu,
- voľba PS bodov,
- rozbalenie fázy (angl. Phase Unwrapping),
- extrakcia parametrov deformácie a reziduálnych výšok,
- odstránenie atmosférických vplyvov (možno odhadnúť a eliminovať).

Odhady deformácie prostredníctvom časových radov dosahujú zvyčajne presnosť niekoľkých milimetrov za rok. Práve vďaka takto vysokej presnosti je možné detegovať aj minimálne pohyby zemského povrchu, a takisto je možné predpovedať budúci vývoj zmeny, prípadne jej veľkosť, na základe pretrvávajúceho trendu. Taktiež PS InSAR ponúka rozsiahle pokrytie oblasti, spojené s relatívne vysokým priestorovým rozlíšením, čo umožňuje skúmať deformačné javy v celých metropolitných oblastiach.

PS interferometria sa od metódy DInSAR líši v dvoch zásadných rozdieloch. Prvým z nich je početnosť SAR snímok potrebných na samotný proces interferometrického spracovania. Druhý dôležitejší rozdiel je ten, že práve PS technika umožňuje vhodné postupy modelovania údajov na štatistický odhad parametrov (Obr. 7.5). Prvým parametrom je časová séria deformácie, poskytujúca časové informácie o sledovanom jave. Druhým parametrom je tzv. zvyšková topografická chyba. Jednoducho povedané ide o výškový rozdiel medzi skutočnou výškou rozptylu fázy v danom bode a výškou DEM

použitého na spracovanie. Ďalším veľkým faktorom PS metódy je dôraz kladený na koherenciu. Pod týmto pojmom môžeme chápať mieru fázovej stability medzi dvoma SAR snímkami (veľkosť v rozpätí od 0 do 1), pričom interferogram v dobrej kvalite je reprezentovaný viditeľnými prstencami (hodnoty koherencie sa blížia k hodnote 1). Nižšia kvalita interferogramu môže byť zapríčinená fázovými chybami.



Obr. 7.5 Zjednodušená diagramová situácia metód DInSAR a PS InSAR a ich rozdielu. **Fig. 7.5** Simplified diagram comparison of DInSAR and PS InSAR methods and their difference. Source: Tarikhi, 2011

V súčasnej dobe je však vyvinutých niekoľko osvedčených algoritmov interferometrického spracovania PSInSAR za účelom získania väčšieho počtu dominantných odrazov a teda aj dosiahnutia presnejších výsledkov. Jedným z nich je tzv. SqueeSAR, predstavujúci vylepšenie interferometrického procesu spracovania. Tento algoritmus zohľadňuje okrem PS aj distribuované odrazy (angl. Distributed Scatterers), ktoré pozostávajú zo širokej oblasti, kde je spätne rozptýlená energia určitým spôsobom nižšia, ale štatisticky homogénna v rámci danej oblasti. Vďaka algoritmu SqueeSAR je možné určiť pohyby s rovnakou presnosťou ako PS v tých oblastiach, v ktorých dominujú DS. Teda možno povedať, že výsledkom tohto spracovania sú informácie o posunoch a deformácii na zemskom povrchu pomocou výstupných informácii, tvorených PS aj DS. Ďalším využívaným nástrojom na PSInSAR postprocessing v podobe softvérového balíka je nástroj StaMPS (angl. Stanford Method for Persistent Scatterers). Tento spôsob spracovania implementuje metódu PSInSAR tak, aby fungovala aj v terénoch bez umelých štruktúr, prípadne v miestach podliehajúcim nestálej deformácii. Jedným z ďalších spôsobov spracovania je aj metóda SBAS-InSAR (angl. Small Baseline Subset InSAR), ktorá využíva interferometrické páry malých časopriestorových základníc na generovanie povrchovej deformácie. Táto technika prekonáva nízku koherenciu niektorých interferogramov vyvolanú jednotlivými "Super-Master" snímkami a znižuje požiadavku na množstvo snímok SAR.

7.2.3. Factors affecting the interferometry process

Nielen v priebehu akvizície družice na obežnej dráhe, ale aj v procese spracovania dochádza ku vzniku a hromadeniu skupiny chýb, ovplyvňujúcich výsledky SAR interferometrie. Niektoré z nich možno vhodným výberom dát a spracovaním redukovať, no zasa nie je ich možné odstrániť všetky. Na základe toho bývajú výsledky spracovania ovplyvnené dvojicou faktorov, konkrétne faktory spôsobené pri akvizícii obrazu a faktory spôsobené pri spracovaní obrazu. Ich charakteristika je popísaná v nasledujúcich podkapitolách.

7.2.3.1. Acquisition errors

Medzi dôležité akvizičné chyby patrí **atmosférické oneskorenie** (angl. *Atmospheric Delay*), ktoré vzniká pri spracovaní SAR snímok hlavne v týchto dvoch vrstvách zemskej atmosféry:

- lonosféra v dôsledku odlišnej hustoty elektrónov je častokrát označovaná ako najhoršia vrstva atmosféry. Oneskorenie závisí hlavne od frekvencie signálu a geomagnetických podmienok v ionosfére. Kompenzáciu tohto oneskorenia je možné vykonať postupným porovnaním fázy, vzťahujúc sa k určitému pixelu.
- Troposféra ide o vrstvu atmosféry, vystavenú rôznym meteorologickým a fyzikálnym podmienkam ako vlhkosť, teplota a tlak. Práve od týchto faktorov závisí hodnota indexu lomu. Vďaka premenlivosti prostredia, spôsobenej aj tvorbou oblačnosti, sa očakáva korelácia troposférického oneskorenia s topografickou výškou. Tento vplyv je možné odhadnúť a čiastočne eliminovať v rámci opravy chyby DEM v procese spracovania.

Ďalšou z chýb spôsobených akvizíciou je **nestabilita satelitných hodín** (angl. *Satellite Clock Instability*). Keďže nie je možné korigovať nestabilitu satelitných hodín, navrhujú sa satelity tak, aby nestabilita bola čo najmenšia. Táto chyba môže spôsobovať:

- Chybu opakovania pulzu tzv. PRF chyba (angl. *Pulse Repetition Frequency*), ktorá je obmedzená dĺžkou antény a rýchlosťou družice,
- chybu rozsahu dekompresie, ktorá vedie k oneskoreniu signálu,
- chyby obežných dráh.

Medzi dôležité akvizičné chyby patrí aj **dekorelácia** (angl. *Decorrelation*) čo je v podstate signifikantná zmena meraných údajov. Dekoreláciu možno označiť ako fázovú chybu, od ktorej závisí výsledná koherencia (Obr. 7.6). V interferometrickom spracovaní sa je možné stretnúť s viacerými typmi dekorelácií, konkrétne:

- geometrická γ_{geometry} dochádza k nej v dôsledku pozorovania určitého bodu na zemskom povrchu pod mierne odlišnými uhlami. Ovplyvňuje to celkovú hodnotu pixela.
- **tepelná** $\gamma_{thermal}$ v podstate ide o dôsledok pozorovania objektov s rôznou teplotou. Eliminácia tohto vplyvu je možná zosilnením signálu.
- časová γ_{temporal} je závislá najmä od pozorovaného terénu. V prípade rýchlych a extrémnych zmien alebo v oblastiach s vysokou koncentráciou vegetácie spôsobuje vysoká dekorelácia nízke hodnoty koherencie. Naopak v oblastí pohorí a zastavaných plôch je dekorelácia nízka a teda koherencia vykazuje vysoké hodnoty.
- dekorelácia spôsobená spracovaním $\gamma_{process}$ je spôsobená najmä procesom koregistrácie, prevzorkovania a tiež rozbalením fázy.
- dekorelácia spôsobená Dopplerovým centroidom γ_{DC} je spôsobená rozdielom medzi frekvenciami Doplerovského centroidu (stredmi týchto frekvencií) a medzi dvoma akvizíciami. Dopplerov princíp sa využíva pre zväčšenie rozsahu snímaného územia.
- dekorelácia spôsobená preniknutím vlny do vegetácie γ_{vol} závisí od použitého mikrovlnného pásma a schopnosti žiarenia prenikať rôznymi prostrediami napr. vegetáciou a pod.

Teda celkovú dekoreláciu γ možno určiť prostredníctvom vzťahu:

$\gamma = \gamma_{geometry} * \gamma_{DC} * \gamma_{thermal} * \gamma_{temporal} * \gamma_{process} * \gamma_{vol}$

(7.2)

Interferometrický proces býva poväčšine ovplyvnený aj ďalším akvizičným faktorom, ktorým je tepelný šum. Problematika tepelného šumu a jeho vplyv na SAR obraz bola bližšie komentovaná v kapitole, popisujúcej charakteristiky SAR obrazu.



Obr. 7.6 Interferogram ovplyvnený atmosférickými faktormi (vľavo) a vysokou dekoreláciou (vpravo).

Fig. 7.6 Interferogram affected by atmospheric factors (left) and high decoration (right). Source: Hooper, 2016

7.2.3.2. Processing errors

Jednými z najrozšírenejších a kľúčových chýb pri interferometrickom spracovaní sú **chyby rozbalenia fázy** (angl. *Phase Unwrapping Errors*). Pri nelineárnych deformáciách môže byť fázová zložka deformačného signálu zmiešaná s atmosférickou zložkou. Rozbalenie fázy vyrieši túto nejednoznačnosť integráciou fázového rozdielu medzi susednými pixelmi (Obr. 7.7). Teda fázová zmena medzi dvoma bodmi na sploštenom interferograme umožňuje meranie skutočnej zmeny nadmorskej výšky. Proces rozbalenia fázy možno však v osobitných prípadoch vynechať, no platí to hlavne pre oblasti s deformáciami nepatrného rozsahu.



Obr. 7.7 Grafické znázornenie rozbalenej a nerozbalenej fázy. **Fig. 7.7** Graphic representation of the wrapped and unwrapped phase. Source: Leško, 2014

Medzi ďalšie chyby paria **chyby pozície satelitov** (angl. *Satellite Position Errors*). Tieto chyby sú taktiež dôležitým ukazovateľom presnosti SAR interferometrie, pretože aj malé centimetrové chyby môžu spôsobiť fázové chyby interferogramu. Informácie o polohe družice sú zahrnuté v prijatých dátach, keďže počas jej letu je automaticky určená aj jej poloha. Avšak táto poloha môže byť chybná o niekoľko metrov v každom smere. Preto je poloha satelitu určovaná výpočtom za pomoci neskôr získaných údajov, čo zabezpečuje presnejšie určenie výslednej pozície družice. Samozrejme, tieto údaje sú k dispozícii až po určitej dobe od dátumu akvizície. Tieto chyby majú náhodný charakter a ovplyvňujú interferogram ako celok v týchto dvoch krokoch spracovania:

v procese odčítania fázy plochého zemského povrchu, kde pre reziduálnu fázu platí:

$$d(\Delta \varphi_E) = \frac{4\pi}{\lambda} * (dB_h \sin \theta - dB_v \cos \theta)$$
(7.3)

• a v procese odčítania topografie povrchu, kde pre reziduálnu fázu platí:

$$d(\Delta\varphi_{tpg}) = \frac{4\pi}{\lambda} \cdot \frac{1}{\sin(\theta + \epsilon) \cdot R_M} * (dB_h \cos\theta h - dB_v \sin\theta h) , \qquad (7.4)$$

ak dB_h a dB_v sú chyby vzťahujúce sa k obežnej dráhe v horizontálnom aj vertikálnom smere. Parameter *h* pri topografickom odčítaní reprezentuje nadmorskú výšku a θ je uhol dopadu.

V kategórii chýb spôsobených interferometrickým spracovaním satelitných dát majú svoje zastúpenie aj **chyby digitálneho výškového modelu** (angl. *DEM Errors*). Účinok týchto chýb je možné odvodiť z nasledujúceho vzťahu:

$$d(\Delta \varphi_{DEM}) = \frac{4\pi}{\lambda} \cdot \frac{1}{\sin(\theta + \epsilon) \cdot R_M} \cdot B_{\perp} dh \quad , \tag{7.5}$$

ak *dh* je chyba DEM, vzťahujúca sa ku konkrétnemu pixelu interferogramu. Táto chyba sa samozrejme líši pre každý pixel. Ďalší parameter, označený ako B_{\perp} , symbolizuje dĺžku kolmej základnice medzi pozíciami družíc a uhol θ je ako pri pozícii satelitov uhlom pohľadu.

7.3. SAR Polarimetry

Pojem **SAR polarimetria** (angl. *SAR Polarimetry*), označovaný tiež ako PolSAR, možno definovať ako oblasť diaľkového prieskumu Zeme, zoberajúcu sa získavaním, spracovaním a analýzou stavu polarizácie elektromagnetického poľa. Pri SAR polarimetrii sa informácie prenášajú z objektu do senzora pomocou elektromagnetických vĺn. Tieto informácie môžu byť zakódované vo frekvenčnom obsahu, intenzite alebo polarizácii elektromagnetickej vlny. Elektromagnetický rozptyl je vo svojej podstate vektorový jav z hľadiska povahy. Na zachytenie všetkých informácií v rozptýlenej vlne je preto potrebné zmerať celý vektor rozptylu. Vďaka SAR polarizácii radary využívajú polarizačnú diverzitu na meranie kompletnej rozptylovej matice. Nasledujúce riadky preto bližšie popisujú polarizačné správanie vlny a jej reprezentácie.

7.3.1. Polarization descriptors

Vo všeobecnosti je známe, že časopriestorové správanie elektromagnetických vĺn je založené na princípe Maxwellových rovníc. Pre elektromagnetickú vlnu, ktorá sa šíri v smere \hat{z} , možno skutočnú elektrickú vlnu rozložiť na dve ortogonálne zložky \hat{x} a \hat{y} , reprezentujúc nasledujúcu vektorovú formuláciu:

$$\vec{E}(z,t_0) = \begin{bmatrix} E_x \\ E_y \\ E_z \end{bmatrix} = \begin{bmatrix} E_{0x} \cos(\omega t - kz + \delta_x) \\ E_{0y} \cos(\omega t - kz + \delta_y) \\ 0 \end{bmatrix},$$
(7.6)

ktorú možno definovať aj v komplexnej forme v nasledujúcej podobe:

$$\underline{\vec{E}}(z,t_0) = \begin{bmatrix} \underline{E}_x \\ \underline{E}_y \\ \underline{E}_z \end{bmatrix} = \begin{bmatrix} E_{0x}e^{j\delta_x}e^{-jkz}e^{j\omega t} \\ E_{0y}e^{j\delta_y}e^{-jkz}e^{j\omega t} \\ 0 \end{bmatrix}, \qquad (7.7)$$

ak E_{0x} a E_{0y} predstavujú amplitúdy vĺn pre obe súradnice x a y, parameter $e^{i\omega t}$ charakterizuje harmonickú časovú závislosť elektrickej vlny a δ_x a δ_y predstavujú vlnové fázy pre zložky x a y. Amplitúda šírenia vektora vlny k sa určí ako:

$$k = \frac{2\pi}{\lambda} , \qquad (7.8)$$

kde λ predstavuje vlnovú dĺžku. Na základe týchto skutočností je možné špecifikovať 3 typy polarizačného správania. Patria medzi ne:

 Lineárna polarizácia – elektrické pole možno chápať ako sínusovú vlnu (Obr. 7.8) vpísanú do roviny orientovanej uhlom φ vzhľadom k osi x̂, teda:

$$\vec{E}(z,t_0) = \sqrt{E_{0x}^2 + E_{0y}^2} \begin{bmatrix} \cos\varphi\\ \sin\varphi\\ 0 \end{bmatrix} \cos(\omega t_0 - kz + \delta_x)$$
(7.9)



Obr. 7.8 Priestorový vývoj lineárne (horizontálne) polarizovanej rovinnej vlny. **Fig. 7.8** Spatial evolution of a linearly (horizontal) polarized plane wave. Source: Lee and Pottier, 2009

• **Kruhová polarizácia** $\delta = \delta_y - \delta_x = \frac{\pi}{2} + k\pi$ – toto správanie je založene na princípe vlny otáčajúcej sa kruhovým pohybom okolo osi , pričom je orientované s uhlom $\varphi(z)$ vzhľadom k osi \hat{x} . Teda platí:

$$\left|\vec{E}(z,t_{0})\right|^{2} = E_{0x}^{2} + E_{0y}^{2}$$

$$\varphi(z) = \pm(\omega t_{0} - kz + \delta_{x})$$
(7.10)

Zároveň možno povedať, že kruhové správanie polarizácie

• Eliptická polarizácia – tento princíp je charakterizovaný vlnou opisujúcou špirálovitú trajektóriu okolo osi *ż*. Teda platí, že ak neexistujú žiadne obmedzenia pre hodnoty uhla elipticity a orientácie, potom elektrická vlna predstavuje stav eliptickej polarizácie.

Toto rozdelenie polarizačného správania charakterizuje priestorový vývoj rovinnej monochromatickej vlny. Zároveň znázorňuje, že monochromatická vlna sleduje špirálovitú trajektóriu pozdĺž osi \hat{z} . Na druhej strane je však pomerne zložité znázorniť a analyzovať 3D špirálové krivky. Z tohto dôvodu sa vo všeobecnosti uprednostňuje charakterizácia vlny v časovej oblasti v pevnej polohe $z = z_0$. Časové správanie sa tak študuje v priečnej rovine, kolmej na smer šírenia a na pevnom mieste pozdĺž osi \hat{z} . Teda s vývojom času má vlna charakteristický eliptický geometrický tvar (Obr. 7.9).



Obr. 7.9 Časová trajektória monochromatickej rovinnej vlny na pevnej osi $z = z_0$. **Fig. 7.9** Temporal trajectory of a monochromatic plane wave at a fixed abscissa $z = z_0$. Source: Pottier, 2021

Charakter trajektórie časovej vlny možno určiť z nasledujúceho parametrického vzťahu medzi zložkami $\vec{E}(z_0, t)$ a pre vlnové zložky E_x a E_y platí:

$$\left[\frac{E_{\chi}(z_0,t)}{E_{0\chi}}\right]^2 - 2\frac{E_{\chi}(z_0,t) E_{\chi}(z_0,t)}{E_{0\chi} E_{0\chi}} \cos(\delta_{\chi} - \delta_{\chi}) + \left[\frac{E_{\chi}(z_0,t)}{E_{0\chi}}\right]^2 = \sin(\delta_{\chi} - \delta_{\chi})$$
(7.11)

Táto rovnica je tiež charakterizovaná ako polarizačná elipsa, pretože popisuje polarizáciu vĺn. Tvar polarizačnej elipsy možno charakterizovať pomocou troch parametrov. Prvým z nich je **amplitúda elipsy A**, ktorá je určená osou elipsy v tvare:

$$A = \sqrt{E_{0x}^{2} + E_{0y}^{2}}$$
(7.12)

Ďalším parametrom je **orientácia elipsy** φ , ktorí je definovaná ako uhol medzi hlavnou osou elipsy a osou \hat{x} v tvare:

$$\tan 2\varphi = 2 \frac{E_{0x} E_{0y}}{E_{0x}^2 - E_{0y}^2} \cos \delta , \qquad (7.13)$$

ak platí $\delta = \delta_y - \delta_x$, pričom je známe:

$$\varphi \in \left[-\frac{\pi}{2}, \frac{\pi}{2}\right] \tag{7.14}$$

Posledným parametrom je **elipticita** τ , alebo tiež označované ako elipsová apertúra, ktorá je definovaná nasledovne:

$$|\sin 2\tau| = 2 \frac{E_{0x} E_{0y}}{E_{0x}^2 + E_{0y}^2} |\sin \delta| , \qquad (7.15)$$

pričom platí:

$$|\tau| \in \left[0, \frac{\pi}{4}\right] \tag{7.16}$$

Jednotlivé parametre znázorňuje nasledujúca prehľadná situácia (Obr. 7.10).

7 SAR Applications – Interferometry, Polarimetry



Obr. 7.10 Priestorový vývoj kruhovo polarizovanej rovinnej vlny. **Fig. 7.10** Spatial evolution of a circularly polarized plane wave. Source: López-Martínez and Pottier, 2021

7.3.1.1. The Jones vector

Úlohou tejto reprezentácie rovinného monochromatického elektrického poľa je charakteristika polarizácie vĺn za pomoci minimálneho množstva údajov. Práve **Jonesov vektor** jednoznačne špecifikuje stav polarizácie vlny. Obsahuje kompletné informácie o amplitúdach a fázach zložiek *x* a *y* vektora elektrického poľa. Keďže Jonesov vektor je určený dvoma komplexnými veličinami (čiže amplitúda a fáza), je ho možné získať iba použitím koherentného radarového systému. Dostupnosť takýchto koherentných systémov je v súčasnosti rozšírená.

Časopriestorový vektor možno zapísať ako:

$$\vec{E}(z,t) = \begin{bmatrix} E_{0x}\cos(\omega t - kz + \delta_x) \\ E_{0y}\cos(\omega t - kz + \delta_y) \end{bmatrix} = Re\left\{ \begin{bmatrix} E_{0x}e^{j\delta_x} \\ E_{0y}e^{j\delta_y} \end{bmatrix} e^{-jkz}e^{j\omega t} \right\} = Re\{\vec{E}(z)e^{j\omega t}\}$$
(7.17)

Jonesov vektor <u>E</u> je potom definovaný z komplexného vektora elektrického poľa $\vec{E}(z)$ ako:

$$\underline{E} = \vec{E}(z)|_{z=0} = \vec{E}(0) = \begin{bmatrix} E_{0x}e^{j\delta_x} \\ E_{0y}e^{j\delta_y} \end{bmatrix}$$
(7.18)

Definície stavu polarizácie z deskriptorov Jonesovho vektora alebo polarizačnej elipsy sú potom ekvivalené:

$$\underline{E} = Ae^{+j\alpha} \begin{bmatrix} \cos\varphi\cos\tau - j \sin\varphi\sin\tau\\ \sin\varphi\cos\tau + j \cos\varphi\sin\tau \end{bmatrix}$$
(7.19)

Ak α predstavuje absolútny fázový člen. Jonesov vektor možno zapísať efektívnejšie, pomocou tejto maticovej podoby:

$$\underline{E} = Ae^{+j\alpha} \begin{bmatrix} \cos\varphi & -\sin\varphi\\ \sin\varphi & \cos\varphi \end{bmatrix} \begin{bmatrix} \cos\tau\\ j\sin\tau \end{bmatrix}$$
(7.20)

Jonesove vektory a hodnoty súvisiacich parametrov polarizačnej elipsy detailnejšie popisuje nasledujúca tabuľka (Tab. 7.1):

Tab. 7.1 Jonesove vektory a súvisiace parametre polarizačnej elipsy.
Tab. 7.1 The Jones vectors and the associated polarization ellipse parameters
Source: Lee and Pottier, 2009

Stav polarizácie	Jonesov vektor $\widehat{u}_{(x,y)}$	Uhol orientácie φ	Uhol elipticity $ au$
Horizontálna	$\widehat{u}_{H} = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$	0	0
Vertikálna	$\hat{u}_{V} = \begin{bmatrix} 0\\1 \end{bmatrix}$	$\frac{\pi}{2}$	0
Lineárna +45°	$\hat{u}_{+45} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1\\1 \end{bmatrix}$	$\frac{\pi}{4}$	0
Lineárna –45°	$\hat{u}_{-45} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1\\ -1 \end{bmatrix}$	$-\frac{\pi}{4}$	0
Ľavotočivá	$\hat{u}_L = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 \\ j \end{bmatrix}$	$\left[-\frac{\pi}{2}\cdots\frac{\pi}{2}\right]$	$\frac{\pi}{4}$
Pravotočivá	$\hat{u}_R = \frac{1}{\sqrt{2}} \begin{bmatrix} 1\\ -j \end{bmatrix}$	$\left[-\frac{\pi}{2}\cdots\frac{\pi}{2}\right]$	$-\frac{\pi}{4}$

7.3.1.2. The Stokes vector

Ako je známe, nekoherentné systémy sú schopné merať iba pozorovateľné časti prichádzajúcej vlny. Teda v dôsledku toho bolo potrebné charakterizovať polarizáciu vlny iba meraním výkonu, čiže prostredníctvom reálnych veličín. Pre tento účel bol definovaný takzvaný **Stokesov vektor**, spomínaný už v kapitole venovanej všeobecne SAR systémom. Hermitovskú maticu na popísanie parametrov Stokesovho vektora možno definovať za pomoci vonkajšieho produktu Jonesovho vektora <u>*E*</u> v tomto tvare:

$$\underline{\underline{E}} \cdot \underline{\underline{E}}^{*T} = \begin{bmatrix} E_x E_x^* & E_x E_y^* \\ E_y E_x^* & E_y E_y^* \end{bmatrix}$$
(7.21)

Ak vezmeme do úvahy Pauliho skupinu matíc, je možné rovnicu (7.21) zapísať v tvare:

$$\begin{bmatrix} E_x E_x^* & E_x E_y^* \\ E_y E_x^* & E_y E_y^* \end{bmatrix} = \frac{1}{2} \{ g_0 \sigma_0 + g_1 \sigma_1 + g_2 \sigma_2 + g_3 \sigma_3 \} = \frac{1}{2} \begin{bmatrix} g_0 + g_1 & g_2 - jg_3 \\ g_2 + jg_3 & g_0 - g_1 \end{bmatrix}, \quad (7.22)$$

kde parametre $\{g_0, g_1, g_2, g_3\}$ sú známe ako Stokesove parametre. Na základe toho je možné odvodiť Stokesov vektor v nasledujúcom tvare:

$$\underline{g}_{\underline{E}} = \begin{bmatrix} g_0 \\ g_1 \\ g_2 \\ g_3 \end{bmatrix} = \begin{bmatrix} E_x E_x^* + E_y E_y^* \\ E_x E_x^* - E_y E_y^* \\ E_x E_y^* + E_y E_x^* \\ j(E_x E_y^* - E_y E_x^*) \end{bmatrix} = \begin{bmatrix} |E_x|^2 + |E_y|^2 \\ |E_x|^2 - |E_y|^2 \\ 2Re(E_x E_y^*) \\ -2Im(E_x E_y^*) \end{bmatrix} = \begin{bmatrix} A \\ A\cos 2\varphi \cos 2\tau \\ A\sin 2\varphi \cos 2\tau \\ A\sin 2\tau \end{bmatrix} , \quad (7.23)$$

pričom je možné stanoviť nasledovné:

$$g_0^2 = g_1^2 + g_2^2 + g_3^2 \tag{7.24}$$

Stokesove vektory a súvisiace Jonesove vektory pre niektoré kanonické stavy polarizácie uvádza nasledujúca tabuľka (Tab. 7.2):

Tab. 7.2 Stokesove vektory a súvisiace Jonesove vektory.	
Tab. 7.2 The Stokes vectors and the associated Jones vectors.	
Source: Lee and Pottier, 2009	

Stav polarizácie	Jonesov vektor	Stokesov vektor
Horizontálna	$\hat{u}_H = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$	$\underline{g}_{\widehat{u}_{H}} = \begin{bmatrix} 1\\1\\0\\0 \end{bmatrix}$
Vertikálna	$\hat{u}_V = \begin{bmatrix} 0\\1 \end{bmatrix}$	$\underline{g}_{\widehat{u}_{V}} = \begin{bmatrix} 1\\ -1\\ 0\\ 0 \end{bmatrix}$
Lineárna +45°	$\hat{u}_{+45} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1\\1 \end{bmatrix}$	$\underline{g}_{\hat{u}_{+45}} = \begin{bmatrix} 1\\0\\1\\0\end{bmatrix}$
Lineárna –45°	$\hat{u}_{-45} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1\\ -1 \end{bmatrix}$	$\underline{g}_{\widehat{u}_{-45}} = \begin{bmatrix} 1\\0\\-1\\0 \end{bmatrix}$
Ľavotočivá	$\hat{u}_L = \frac{1}{\sqrt{2}} \begin{bmatrix} 1\\ j \end{bmatrix}$	$\underline{g}_{\widehat{u}_L} = \begin{bmatrix} 1\\0\\0\\1 \end{bmatrix}$
Pravotočivá	$\hat{u}_R = \frac{1}{\sqrt{2}} \begin{bmatrix} 1\\ -j \end{bmatrix}$	$\underline{g}_{\widehat{u}_R} = \begin{bmatrix} 1\\0\\0\\-1 \end{bmatrix}$

7.3.2. SAR polarimetry and Interferometry

Z predchádzajúcich kapitol je známe, že metóda SAR interferometrie umožňuje umiestnenie efektívneho centra rozptylu vo vnútri rozlišovacej bunky. Pri SAR polarimetrii zase platí, že umožňuje identifikáciu resp. rozklad rôznych rozptylových procesov, ktoré sa vyskytujú vo vnútri rozlišovacej bunky. Kombináciou týchto dvoch prístupov možno docieliť zlepšenie interferometrickej koherencie a fázovej kvality, čo má dobrý aplikačný potenciál. Metóda **polarimetrickej SAR interferometrie PolInSAR** (angl. *Polarimetric SAR Interferometry*) predstavuje techniku DPZ, založenú na kombinácii polarimetrických a interferometrických informácií v SAR snímkach. Teda hlavnou charakteristikou tejto metódy je jej potenciál oddeliť v určitej výške rôzne rozptylové procesy, ktoré sa vyskytujú sa vo vnútri SAR rozlišovacej bunky (Obr. 7.11).



Obr. 7.11 Znázornenie metód a vyjadrenie rozptylových procesov rozptylovými maticami. **Fig. 7.11** Representation of methods and expression of scattering processes by scattering matrices.

Source: Hajnsek, 2021

Teda pri tejto metóde sme schopní získať dve skupiny plne polarizovaných obrazov. Potom každý pixel v plne polarizovanom obraze má zodpovedajúcu rozptylovú maticu S (komplexná matica s rozmerom 2x2). V porovnaní s metódou InSAR môže PolInSAR zlepšiť koherenciu aj obrazu. Takisto je metóda PolInSAR charakteristická silnou penetrabilitou v nízkofrekvenčnom pásme ako je L-pásmo a P-pásmo.

7.3.3. SAR Polarimetry and Tomography

SAR tomografia predstavuje experimentálny interferometrický režim viacnásobnej základnice dosahujúci úplné priestorové zobrazenie v podobe rozsah-azimut-výška. Vďaka tomu je možné získať rozlíšenie viacerých odrážačov na výšku pre rovnakú bunku rozsah-azimut. Dôležitý význam však majú aj informácie o povahe zobrazovaných odrážačov. Na základe toho bola SAR tomografia rozšírená aj o polarimetrické informácie označovaná ako **Pol-TomoSAR** (angl. *Polarimetric Tomography SAR*). Výhodou je použitie dát viacnásobnej základne, získaných rôznymi polarizačnými kanálmi, za účelom zlepšenia presnosti odhadu vertikálnej polohy odrážačov.

7.4. Applications of SAR systems and their data

Spoločnou vlastnosťou všetkých SAR systémov je ich schopnosť detailne a relatívne v krátkom čase získať veľké množstvo informácií o prostredí na Zemi. Takto získané dáta predstavujú zásadný zdroj informácií o neustále meniacom sa zemskom povrchu. Nasledujúce strany preto ponúkajú krátky náhľad do jednotlivých sfér bežného života a ich fungovania, v ktorých má uplatnenie SAR dát pre účely mapovania veľký význam.

7.4.1. Applications of SAR Interferometry

7.4.1.1. Geology

Geologické využitie aplikácie metódy InSAR je pomerne široké najmä pri monitorovaní zosuvov pôdy. Je zrejmé, že zosuvy pôdy sa vyskytujú v širokej škále foriem a prostredí. Sú teda priamym vyjadrením geológie, reológie a destabilizačných síl svahu. Deštruktívna sila zosuvu pôdy úzko súvisí s variáciou dostupnej trecej sily, ktorá zase určuje rýchlosť posunu v kombinácií s časom. Predikcia a včasné varovanie sú preto jedinými životaschopnými možnosťami. V tejto súvislosti má veľký význam aj sledovanie poddolovaných oblastí, ako dôsledok podpovrchovej banskej činnosti. Tá môže mať taktiež vplyv na geologický charakter určitého územia. Príklady takýchto náhlych zmien nájdeme aj v našej krajine. Významné je taktiež pozorovanie povrchových depresií, označovaných v odbornej literatúre termínom Sinkholes. Príkladom je pozorovanie týchto depresíí na ostrove Elba v Taliansku (Obr. 7.12).



Obr. 7.12 Interpretácia zosuvov prostredníctvom dlhodobého interferogramu. **Fig. 7.12** Interpretation of landslides by long-term interferogram. Source: Intrieri et al., 2015

7.4.1.2. Surface mining

Do tejto kategórie možno zaradiť monitoring stability povrchových baní, kameňolomov a iných lokalít, kde sú vykonávané banské činnosti, a činnosti vykonávané banským spôsobom. Je všeobecne známe, že aj v takýchto oblastiach môže dôjsť k zosuvom. Potenciálne riziko zosuvov a deformácií takisto môžu predstavovať opustené areály, v ktorých sa už dobývacia činnosť skončila a tiež odkaliská, z ktorých niektoré nemusia byť monitorované na pravidelnej báze z hľadiska stability. Príkladom znázornenia zosuvov v týchto územiach je nasledujúca snímka z roku 2016 (Obr. 7.13).



Obr. 7.13 Uplatnenie SAR interferometrie v oblasti povrchového dobývania. **Fig. 7.13** Application of SAR interferometry in surface mining. Source: Carlá, et al., 2019

7.4.1.3. Civil Engineering

Ďalším odvetvím, kde je aplikácia SAR interferometrie vhodným nástrojom je segment stavebníctva. Stavebné inžinierstvo (výstavba, údržba a monitorovanie) predstavuje činností, ktoré si vyžadujú vysokú časopriestorovú presnosť a detailnosť pri pozorovaní stavu rôznorodých objektov. Možno teda povedať, že uplatnenie SAR interferometrie v oblasti stavebníctva je hlavne v oblastí správy stavebných objektov, sledovanie posunov a pretvorení výškových stavieb, prípadne monitorovaní stavebných objektov v rizikových oblastiach. Práve monitoring stavieb v rizikových oblastiach pomocou SAR interferometrie predstavuje efektívny nástroj na predikciu pred geohazardmi . Tie môžu mať negatívny dopad na majetok a životy obyvateľstva. Ako príklad možno uviesť obec Koš v regióne Horná Nitra na Slovensku (Obr. 7.14), ktorá predstavuje potenciálne riziko pre niektoré stavby v miestach poddolovaných lokalít. Do úzkej spojitosti so stavebníctvom možno zakomponovať aj sledovanie stavu a stability objektov s historickým prívlastkom. Tie predstavujú značnú časť kultúrneho dedičstva, a preto je obzvlášť dôležité venovať aj týmto stavbám osobitnú pozornosť. V neposlednom rade má SAR interferometria svoje uplatnenie v oblasti stavebníctva aj pri územnom plánovaní. Na podklade dlhodobých interferometrických pozorovaní v spojitosti s ďalšími terestrickými metódami merania (inklinometria, veľmi presná nivelácia a pod.), možno vypracovať relevantné podklady pre územné plánovanie samospráv.



Obr. 7.14 Znázornenie časového radu posunu v nestabilnom poddolovanom území. **Fig. 7.14** Representation of the time series of shifts in an unstable mined area. Source: Bakoň et al., 2020

7.4.1.4. Transport Infrastructure

Do tejto kategórie možno zaradiť najmä pozorovania v sektore železničnej, cestnej a leteckej dopravy. Široké uplatnenie radarovej interferometrie v oblasti dopravy je hlavne pri správe cestných a železničných stavieb ako mosty (Obr. 7.15), viadukty, estakády a pod. Je zrejmé, že monitorovanie deformácií mostov je nevyhnutným krokom pre zaistenie bezpečnosti miest a ľudských životov. V súčasne dobe existuje niekoľko technológií na monitorovanie dopravných stavieb ako infračervená termografia, georadar, laserové skenovania, GNSS observácie a iné. Vhodným doplnením týchto observačných metód je práve SAR interferometria, ktorá predstavuje rýchlu, presnú a finančne nenáročnú metódu monitorovania stability mostných objektov. Použitie tejto metódy je pri podrobnom sledovaní posunov a pretvorení dopravných stavieb, čo je nevyhnutné pri zabezpečení ich prevádzkyschopnosti. Signifikantný význam použitia metódy InSAR je aj v súvislosti so sledovaním letísk. Napríklad monitorovanie deformácií na vzletových a pristávacích dráhach letísk a priľahlých oblastiach je kľúčové najmä v prípadoch výskytu podložia s nízkou únosnosťou.



Obr. 7.15 Využitie SAR interferometrie pri sledovaní výškových zmien mosta. **Fig. 7.15** Use of SAR interferometry in monitoring the vertical changes of bridge. Source: Gagliardi et al., 2020

7.4.1.5. Other applications of SAR interferometry

Využiteľnosť SAR interferometrie je okrem stavebníctva, dopravy, geológie a dobývania je táto metóda využiteľná aj v ďalších odvetviach, napríklad:

- vodohospodárstvo v súvislosti so sledovaním priehrad, vodných nádrží a iných vodohospodárskych stavieb (Obr. 7.16),
- ťažobný priemysel zameraný na strategicky energetické suroviny, ako ťažba, transfer a uskladňovanie ropy a zemného plynu.
- a d'alšie.



Obr. 7.16 Využitie SAR interferometrie pri sledovaní výškových zmien vodnej nádrže. **Fig. 7.16** Use of SAR interferometry in monitoring the height changes of the water dam. Source: Biondi et al., 2020

7.4.2. Applications of SAR Polarimetry

7.4.2.1. Forestry

Druhou kategóriou využitia SAR snímok je SAR polarimetria. Azda medzi najrozšírenejšie oblasti patrí sektor lesníctva. Jednou z oblasti záujmu je napríklad sledovanie výšky lesných porastov, ktorá je dôležitým ukazovateľom lesnej biomasy na účely hospodárenia, ako aj na hodnotenie zásob uhlíka. Ďalšou oblasťou uplatnenia SAR polarimetrie je mapovanie lesnej štruktúry a biomasy v krajine. Práve takzvaná lesná nadzemná biomasa ukladá podstatnú časť lesného uhlíka a je kľúčovým biofyzikálnym parametrom na charakterizáciu rastu a podmienok lesného povrchu. Existuje veľké množstvo štúdií zaoberajúcich sa kvantifikáciou množstva biomasy integráciou viacfrekvenčných SAR dát z rôznych senzorov. Dôležitým odvetvím, kde sú využiteľné SAR dáta je tiež pozorovanie zmien v ekosystéme a lesný manažment. Ďalšou možnosťou využitia SAR snímok je pre potreby monitorovania deforestácie (Obr. 7.17). Deforestáciu, čiže odlesňovanie možno formálne definovať ako trvalú zmenu lesnej oblasti na iný typ povrchu. Odhaduje sa, že celosvetovo odlesňovanie a degradácia lesov predstavuje

približne 20% antropogénnych emisií CO². Vzhľadom na fakt, že úbytok lesov má v súčasnosti celosvetový charakter, je aplikácia SAR polarimetrie v oblasti lesníctva široko uplatniteľná.



Detection of deforestation and degradation with Sentinel-1

Obr. 7.17 Detekcia odlesňovania a degradácie pôdy pomocou snímok Sentinel-1. **Fig. 7.17** Detection of deforestation and degradation with Sentinel-1 data. Source: Hoekman et al., 2020

7.4.2.2. Agriculture

Vďaka schopnosti SAR signálu prenikať atmosférou a oblačnosťou majú tieto dáta široké uplatnenie aj v oblasti poľnohospodárstva, keďže značná časť poľnohospodárskej pôdy je častokrát zakrytá oblačnosťou. Možno teda povedať, že presné sledovania rozsahu a pokrytia poľnohospodárskej pôdy sú dôležité pre monitorovanie globálnej potravinovej bezpečnosti, ekonomickej stability a zachovania priaznivých environmentálnych podmienok. Medzi najčastejšie spôsoby využitia SAR polarimetrie v poľnohospodárstve patria sledovanie obsahu pôdnej vlhkosti, drsnosti pôdy, výšky vegetačnej vrstvy, pri manažmente v poľnohospodárstve (Obr. 7.18), pri sledovaní vlhkosti vegetačnej vrstvy, monitorovaní dezertifikácie a ďalších odvetviach.



Obr. 7.18 Dáta Sentinel-1 a manažment poľnohospodárskej pôdy. **Fig. 7.18** Sentinel-1 data and agricultural land management. Source: www.linkedin.com/pulse/sentinel-1-sar-data-visualize-growth-dynamic-croplanddietrich-heintz

7.4.2.3. Cryosphere and Hydrology

Ďalšou oblasťou uplatnenia SAR polarimetrie je odvetvie hydrológie a kryosféry. Možno povedať, že mapovanie vodných tokov a ich okolia pomocou mikrovlnného diaľkového prieskumu Zeme predstavuje rýchlu, nepretržitú a efektívnu metódu a je kľúčovým nástrojom na zachytenie zmien vodných zdrojov pre prípadné predpovedanie nebezpečenstiev. Široké využitie analýz zo SAR snímok v oblasti hydrológie je pri monitorovaní povodní (Obr. 7.19). Možno povedať, že povodňové udalosti však zvyčajne sprevádza daždivé počasie a veľká oblačnosť. Vďaka schopnosti mikrovlnného žiarenia efektívne prenikať oblačnosťou je metóda SAR polarimetrie efektívnejšia než metódy využívajúce optické senzory. Vďaka takto získaným relevantným dátam je možné vypracovať včasné analýzy na zistenie rozsahu povodne. SAR polarimetria má v oblasti hydrológie zastúpenie aj pri sledovaní dlhodobých geomorfologických zmien vo vodných tokoch. Ide nielen o vysokohorské rieky s vysokým spádom a relatívne rýchlymi procesmi akumulácie sedimentov, ale aj o rozsiahlejšie rieky meandrujúceho a divočiaceho charakteru, pretekajúce nižšie položenými oblasťami. Teda sledovaním vodných tokov v rôznych geologických prostrediach a s rôznym pozdĺžnym profilom toku možno z dlhodobého hľadiska získať trend migrácie koryta rieky. Týmto spôsobom je možné pomerne jednoducho identifikovať zmeny prirodzeného vývoja riečnych systémov a sledovanie korytotvorných procesov. Uplatnenie SAR polarimetrie v hydrológií je taktiež pri sledovaní vodných nádrží, jazier a podobne.

Oblasť kryosféry reprezentuje akékoľvek miesto na zemskom povrchu charakterizované prítomnosťou vody v pevnom skupenstve. Jej uplatnenie v SAR polarimetrii je napríklad:
- pri topografii charakteristika krajiny
- sledovaní zmien ekosystému vplyvom globálneho otepľovania
- zániku trvale zaľadnených oblastí priestorové zmeny v tzv. permafroste
- sledovanie hĺbky snehovej vrstvy rýchle a presné mapovanie snehovej pokrývky je nevyhnutné pre monitorovanie prírodných zdrojov, regionálnych klimatických zmien a prirodzený vývoj životného prostredia (Croce et al., 2018).
- pri monitoringu globálneho otepľovania ľadovcové jazerá sú dôležitými ukazovateľmi regionálnej dynamiky ľadovcov v reakcii na otepľovanie klímy a meniace sa zrážky.



Obr. 7.19 SAR polarimetria v oblasti monitorovania povodní. **Fig. 7.19** SAR polarimetry in flood monitoring. Source: Carreño Conde et al., 2019

7.4.2.4. Built-up areas

Rýchle priestorové zmeny a rozširovanie ľudských sídiel vyvoláva už niekoľko rokov potrebu presných nástrojov na monitorovanie zastavaných oblastí nástrojmi DPZ. Charakteristiky spätného rozptylu rádiových vĺn sú vhodným nástrojom na detekciu mestských objektov. Mestské oblasti sú vo všeobecnosti zložitým povrchom z hľadiska rozptylu, v dôsledku veľkej diverzity štruktúr a materiálov. Môžu sa však zovšeobecniť vysokou koncentráciou trvalých rozptylov. Vďaka týmto vlastnostiam sa SAR polarimetria považuje za efektívny prístup pri mapovaní miest, monitorovaní urbanizovaných oblastí, sledovaní geometrických vlastnosti miest a pod. (Obr. 7.20).



Obr. 7.20 Mapovanie rozsahu urbanizácie mesta pomocou SAR. **Fig. 7.20** Mapping the extent of urbanization using SAR. Source: Carreño Conde et al., 2019

7.4.2.5. Other applications of SAR polarimetry

SAR polarimetriu je možné aplikovať aj pri sledovaní a monitorovaní ďalších objektov a javov na zemskom povrchu a tiež v oblasti svetových oceánov a morí. Uplatniteľnosť môže byť nasledovná: Oceánografia – meranie pobrežného veterného poľa, detekcia olejových a ropných škvŕn na vodnej hladine a s ním spojeného rozsahu škôd. Námorníctvo – detekcia lodí za účelom mapovania vyťaženosti prístavu, monitorovania lodných trás, klasifikácia lodí a podobne (Obr. 7.21).



Obr. 7.21 Detekcia lodí prostredníctvom SAR snímok Sentinel-1. **Fig. 7.21** Ship detection using Sentinel-1 SAR images. Source: Yu et al., 2022

References

Books

Dobrovolný, Petr: Dálkový prôskum Země: Digitální zpracování obrazu, Brno: Masarykova univerzita, 1998. IV, 208 s. ISBN 80-210-1812-7 (brož.)

Ferretti, A. Monti-Guarnieri, A. Prati, C.: InSAR Principles: Guidelines for SAR Interferometry Processing and Interpretation. Noordwijk: ESA Publications, 2007. 234 s. ISBN: 92-9092-233-8

Hanssen, R. F.: Radar Interferometry Data Interpretation and Error Analysis. Dordrecht: Springer, 2001. 308 s. ISBN 978-0-7923-6945-5

Hlaváčová, Ivana: Interferometric stacks in partially coherent areas: Dizertačná práca. Praha: ČVÚT, 170p.

Ketelaar, V. B. H.: Satellite Radar Interferometry – Subsidence Monitoring Techniques. Dordrecht: Springer, 2009. 252 s. ISBN 978-1-4020-9427-9

Leško, M.: Využitie radarovej interferometrie na tvorbu digitálneho modelu terénu: Bakalárska práca. Bratislava, 2014. 54p.

Lee, J.S. and Pottier, E.: Polarimetric Radar Imaging: From Basics to Applications. CRC Press, 2009.

Mott, H.: Remote Sensing with Polarimetric Radar. John Wiley & Sons, Inc. 2007. ISBN-13: 978-0-470-07476-3

Richards, J. A.: Remote Sensing with Imaging Radar, Berlin: Springer, 2009. 373 s. ISBN 978-3-642-02019-3

Schoot, J.R.: Fundamentals of Polarimetric Remote Sensing: : Society of Photo-Optical Instrumentation Engineers. Spie, 2009.

Soergel, U.: Radar Remote Sensing of Urban Areas, Netherlands: Springer, 2010. 278 s. ISBN 978-90-481-3750-3

West, P. Tree and Forest Measurement, 2nd ed.; Springer: Berlin/Heidelberg, Germany, 2009.

Papers, manuals, reports

Aobpaet, A. Cuenca, M. C. Trisirisatayawong I.: PS-InSAR Measurement of Land Subsidence in Bangkok Metropolitan Area. 2009. 6s

Bakon, M.; Czikhardt, R.; Papco, J.; Barlak, J.; Rovnak, M.; Adamisin, P.; Perissin, D.: remotIO: A Sentinel-1 Multi-Temporal InSAR Infrastructure Monitoring Service with Automatic Updates and Data Mining Capabilities. Remote Sens. 2020, 12, 1892.

Bianchini Ciampoli, L.; Gagliardi, V.; Ferrante, C.; Calvi, A.; D'Amico, F.; Tosti, F. Displacement Monitoring in Airport Runways by Persistent Scatterers SAR Interferometry. Remote Sens. 2020, 12, 3564.

Biondi F, Addabbo P, Clemente C, Ullo SL, Orlando D. Monitoring of critical infrastructures by micro-motion estimation: the Mosul dam destabilization. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing . 2020 Oct 14;13:6337-6351.

Boerner, W.-M. and M.B. El-Arini: Polarization dependence in electromagnetic inverse problem, IEEE Transactions on Antennas and Propagation, 29(2), 262–271, 1981.

Boerner, W.M.: Introduction to radar polarimetry with assessments of the historical development and of the current state-of-the-art, Proceedings of International Workshop on Radar Polarimetry, JIPR-90, 20–22 March 1990, Nantes, France.

Bouvet, A.; Mermoz, S.; Ballère, M.; Koleck, T.; Le Toan, T. Use of the SAR Shadowing Effect for Deforestation Detection with Sentinel-1 Time Series. Remote Sens. 2018, 10, 1250.

Buša, J.: História, súčasnosť a charakteristika radarovej satelitnej interferometrie InSAR – ako perspektívna monitorovacia metóda svahových deformácií: Geomorphologica Slovaca et Bohemica, 2017. 21s.

Carlà, T., Intrieri, E., Raspini, F. et al. Perspectives on the prediction of catastrophic slope failures from satellite InSAR. Sci Rep 9, 14137 (2019).

Carreño Conde, F.; De Mata Muñoz, M. Flood Monitoring Based on the Study of Sentinel-1 SAR Images: The Ebro River Case Study. Water 2019, 11, 2454.

Croce, P.; Formichi, P.; Landi, F.; Mercogliano, P.; Bucchignani, E.; Dosio, A.; Dimova, S. The Snow Load in Europe and the Climate Change. Clim. Risk Manag. 2018, 20, 138–154.

Crosetto, M. Crippa, B. Barzaghi, R.: Quantitative subsidence monitoring using SAR interferometry. Toronto, Ontario, Canada: IEEE International Geoscience and Remote Sensing Symposium, 2002. pp. 1231-1233 vol.2. ISBN: 0-7803-7536-X Doblas, J.; Shimabukuro, Y.; Sant'Anna, S.; Carneiro, A.; Aragão, L.; Almeida, C. Optimizing Near Real-Time Detection of Deforestation on Tropical Rainforests Using Sentinel-1 Data. Remote Sens. 2020, 12, 3922

FAO. Global Forest Resources Assessment 2020-Key Findings; Food and Agriculture Organization of the United nations: Rome, Italy, 2020.

Feng, J.; Cao, Z.; Pi, Y. Polarimetric Contextual Classification of PolSAR Images Using Sparse Representation and Superpixels. Remote Sens. 2014, 6, 7158-7181.

Ferretti, A. Fumagalli, A. Novali, F. Prati, C. Rocca, F. Rucci, A.: A New Algorithm for Processing Interferometric Data-Stacks: SqueeSAR. IEEE Transactions on Geoscience and Remote Sensing, vol. 49, no. 9, pp. 3460-3470, Sept. 2011

Ferretti, A. Prati, C. Rocca, F.: Permanent Scatterers in SAR Interferometry. in IEEE Transactions on Geoscience and Remote Sensing, vol. 39, no. 1, 2001. pp. 8-20 ISSN: 1558-0644

Gagliardi, V; Bianchini Ciampoli, L; D'Amico, F; Alani, A.M; Tosti, F; Battagliere, M.L; Benedetto, A: "Bridge monitoring and assessment by high-resolution satellite remote sensing technologies", Proc. SPIE 11525, SPIE Future Sensing Technologies, 1152506 (8 November 2020)

Hajnsek, I.; Desnos, Y.: Polarimetric Synthetic Aperture Radar: Principles and Application. Springer, vol. 25. ISSN 2215-1842

Hajnsek, I.: Principles and Basics of InSAR. Prezentácia. 6th ESA Advanced Course on Radar Polarimetry, 2021. 137 s.

Hanssen, R. F. Feijt. A first quantitative evaluation of atmospheric effects on SAR interferometry. In fringe96, ESA SP-406, 1996. pp. 277–282.

Hejmanowski, R. Malinowska, A. Witkowski, W. Guzy, A.: An Analysis Applying InSAR of Subsidence Caused by Nearby Mining-Induced Earthquakes. Switzerland: Geosciences, 2019. 16 s.

Hoekman, D.; Kooij, B.; Quiñones, M.; Vellekoop, S.; Carolita, I.; Budhiman, S.; Arief, R.; Roswintiarti, O. Wide-Area Near-Real-Time Monitoring of Tropical Forest Degradation and Deforestation Using Sentinel-1. Remote Sens. 2020, 12, 3263.

Hooper, Andrew et al.: Recent advances in SAR interferometry time series analysis for measuring crustal deformation. Tectonophysics volume 514-517, 2012. pp. 1-13

Hooper, A; Bekaert, D; Hussain, E; Spaans, K: StaMPS/MTI Manual: Version 4.1b: School of Earth and Environment: University of Leeds. 2018. 44s.

Huynen, J.R.: The Stokes parameters and their interpretation in terms of physical target properties, Proceedings of the International Workshop on Radar Polarimetry, JIPR-90, 20–22 March 1990, Nantes, France.

Intrieri, E., Gigli, G., Nocentini, M., Lombardi, L., Mugnai, F., Fidolini, F., & Casagli, N. (2015). Sinkhole monitoring and early warning: An experimental and successful GB-InSAR application. Geomorphology, 241, 304-314.

Jiang, M. et al.: Modeling minimum and maximum detectable deformation gradients of interferometric SAR measurements. International Journal of Applied Earth Observation and Geoinformation 13-5, 2011. pp. 766-777

Kilburn, Christopher RJ, and David N. Petley.: "Forecasting giant, catastrophic slope collapse: lessons from Vajont, Northern Italy." Geomorphology 54.1-2 (2003): 21-32.

López-Martínez C., Pottier E. (2021) Basic Principles of SAR Polarimetry. In: Hajnsek I., Desnos YL. (eds) Polarimetric Synthetic Aperture Radar. Remote Sensing and Digital Image Processing, vol 25. Springer, Cham.

Lüneburg, E.: Principles of radar polarimetry, Proceedings of the IEICE Transactions on the Electronic Theory, E78-C, 10, 1339–1345, 1995

Lv, Z.; Li, F.; Qiu, X.; Ding, C. Effects of Motion Compensation Residual Error and Polarization Distortion on UAV-Borne PolInSAR. Remote Sens. 2021, 13, 618.

Maghsoudi, M.: Interferometric Synthetic Aperture Radar (InSAR) Technology and Geomorphology Interpretation. 2013. 4 s.

Malinowska, A. A. et al.: Sinkhole occurrence monitoring over shallow abandoned coal mines with satellitebased persistent scatterer interferometry: Engineering Geology 2019. 13 s.

Paul, K.I.; Larmour, J.; Specht, A.; Zerihun, A.; Ritson, P.; Roxburgh, S.H.; Sochacki, S.; Lewis, T.; Barton, C.V.; England, J.R. Testing the generality of below-ground biomass allometry across plant functional types. For. Ecol. Manag. 2019, 432, 102–114.

Perski, Z. Hanssen, R. Wojcik, A. Wojciechowski, T.: InSAR analyses of terrain deformation near the Wieliczka Salt Mine, Poland: Engineering Geology 106, 2009. pp. 58- 67. Petrushevsky, N.; Manzoni, M.; Monti-Guarnieri, A. Fast Urban Land Cover Mapping Exploiting Sentinel-1 and Sentinel-2 Data. Remote Sens. 2022, 14, 36.

Pottier, E.: Radar polarimetry: Towards a future standardization, Annales des Télécommunications, 54(1–2), 1– 5, January 1999.

Pottier, E.: SAR POLARIMETRY Basic & Advanced Concepts and Applications: Prezentácia. 6th Advanced Course on Radar Polarimetry 2021, France, 2021. 359 s.

Salepci, N. Thiel, Ch.: SAR techniques & Applications for Forestry: Prezentácia. ESA PECS Training Course Bratislava, Slovensko 2018. 74 s.

Santi, E.; Paloscia, S.; Pettinato, S.; Fontanelli, G.; Mura, M.; Zolli, C.; Maselli, F.; Chiesi, M.; Bottai, L.; Chirici, G. The potential of multifrequency SAR images for estimating forest biomass in Mediterranean areas. Remote Sens. Environ. 2017, 200, 63–73.

Semenzato, A.; Pappalardo, S.E.; Codato, D.; Trivelloni, U.; De Zorzi, S.; Ferrari, S.; De Marchi, M.; Massironi, M. Mapping and Monitoring Urban Environment through Sentinel-1 SAR Data: A Case Study in the Veneto Region (Italy). ISPRS Int. J. Geo-Inf. 2020, 9, 375.

Strozzi, T.; Wegmuller, U. Delimitation of Urban Areas with SAR Interferometry. In Proceedings of the IGARSS '98. Sensing and Managing the Environment—1998 IEEE International Geoscience and Remote Sensing— Symposium Proceedings. (Cat. No.98CH36174), Seattle, WA, USA, 6–10 July 1998; Volume 3, pp. 1632–1634.

Tarayre, H. Massonnet, D.: Atmospheric propagation heterogeneities revealed by ERS-1 interferometry, IN igrass94, 1994. pp. 717-719.

Van der Werf, G.R.; Morton, D.C.; DeFries, R.S.; Olivier, J.G.J.; Kasibhatla, P.S.; Jackson, R.B.; Collatz, G.J.; Randerson, J.T. CO2 emissions from forest loss. Nat. Geosci. 2009, 2, 737–738.

Wu, Q.; Jia, C.; Chen, S.; Li, H.: SBAS-InSAR Based Deformation Detection of Urban Land, Created from Mega-Scale Mountain Excavating and Valley Filling in the Loess Plateau: The Case Study of Yan'an City. Remote Sens. 2019, 11, 1673.

Yang, H.; Wang, H.; Lu, J.; Zhou, Z.; Feng, Q.; Wu, Y. Full Lifecycle Monitoring on Drought-Converted Catastrophic Flood Using Sentinel-1 SAR: A Case Study of Poyang Lake Region during Summer 2020. Remote Sens. 2021, 13, 3485.

Yu, J.; Zhou, G.; Zhou, S.; Qin, M. A Fast and Lightweight Detection Network for Multi-Scale SAR Ship Detection under Complex Backgrounds. Remote Sens. 2022, 14, 31.

Yu, X.; Ge, H.; Lu, D.; Zhang, M.; Lai, Z.; Yao, R. Comparative study on variable selection approaches in establishment of remote sensing model for forest biomass estimation. Remote Sens. 2019, 11, 1437.

Zhang, L.; Duan, B.; Zou, B. Research on Inversion Models for Forest Height Estimation Using Polarimetric SAR Interferometry. Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. 2017, 42, 659–663.

Zhu, J.; Li, Z.; Hu, J. Research Progress and Methods of InSAR for Deformation Monitoring. Acta Geod. Cartogr. Sin. 2017, 46, 1717–1733.

Web sources

parviztarikhi.wordpress.com/features-2/insar-a-new-generation/insar-new-generation

www.fiberoptics4sale.com/blogs/wave-optics/102087110-jones-vector-representation-of-polarization-states

www.unavco.org/education/professional-development/short-courses/course-materials/insar/2016-insar-iscegiant-course-materials/Hooper_Lecture%20SB.pdf



Applications of RS -Land use/Land cover, Agriculture

The land cover represents the natural as well as the artificial cover of the Earth's surface, including biota, soils, topography, surface and groundwater, and human-made structures. The land use is also related to this, i.e. the way the soil's biophysical properties are manipulated and the purpose for which the soil is used. Remote sensing is an effective technology for mapping land cover and land use and for monitoring and managing land resources. Current applications, products and publications show that a huge amount of effort has been made in recent years to map, monitor and model landscape cover and land use at local, regional and global scales.

Landscape cover characterisation, mapping, monitoring and land use are among the important and typical applications of remotely sensed Earth observation data. The availability of accurate and up-to-date land cover data plays an important role in many global change studies.

Recent and current developments in Earth observation satellite technology, information technology, computer hardware and software, and infrastructure are helping to produce better quality land cover datasets. As a result, such data are becoming more accessible, the user base is continuously expanding, the application areas are broadening, and the potential for many more applications is increasing.

This chapter discusses general knowledge about land cover, its use and change. It describes the needs for its mapping, the CORINE Land Cover project and its content, and the basic areas of land cover monitoring using EO. A large part is devoted to qualitative crop monitoring using different vegetation indices. Another large part is devoted to current EO and agricultural projects.

·eesa 🕁 fberg

8.1. Land Cover

Krajinná pokrývka predstavuje prírodnú rovnako ako aj človekom vytvorenú pokrývku zemského povrchu vrátane bioty, pôdy, topografie, povrchovej a podzemnej vody a ľudských štruktúr (Obr. 8.1). S tým súvisí aj využívanie pôdy, t.j. spôsob akým sa manipuluje s biofyzikálnymi vlastnosťami pôdy a účel na ktorý sa pôda využíva. Diaľkový prieskum Zeme je efektívna technológia na mapovanie krajinnej pokrývky a využívania pôdy a na monitorovanie a riadenie zdrojov krajiny. Aktuálne aplikácie, produkty a publikácie dokazujú, že v posledných rokoch sa vynaložilo obrovské množstvo úsilia na mapovanie, monitorovanie a modelovanie krajinnej pokrývky a využívania pôdy na miestnej, regionálnej, ale aj globálnej úrovni.



Obr. 8.1 Typy krajinnej pokrývky. **Fig. 8.1** Types of land cover. Source: observer.globe.gov

Charakterizácia, mapovanie a monitorovanie krajinnej pokrývky a jej využitie patria medzi dôležité a typické aplikácie dát získaných z diaľkového prieskumu Zeme. Dostupnosť presných a aktuálnych údajov o krajinnej pokrývke zohráva dôležitú úlohu v mnohých štúdiách o globálnych zmenách. Viacero národných a medzinárodných programov v posledných rokoch zdôraznilo nevyhnutnú potrebu kvalitnejších dát o krajinnej pokrývke a zmenách krajinnej pokrývky na miestnej, národnej, kontinentálnej a globálnej úrovni. Jedná sa napr. o Medzinárodný Program Biosféry–Geosféry (IGBP), americký program pre vedu o zmene klímy - program Land Cover and Land Use Change (LCLUC) Národného Úradu pre Letectvo a Vesmír (NASA), Global Land Project, Global Observation of Forest and Land Cover Dynamics (GOFC/GOLD), resp. Group on Earth Observations (GEO). Všetky tieto projekty stáli v popredí pri základnom vedeckom výskume v oblasti vedy o zmenách krajiny.

Nedávny a súčasný vývoj v oblasti satelitných technológií na pozorovanie Zeme, informačných technológií, počítačového hardvéru a softvéru a infraštruktúry pomáha

vytvoriť kvalitnejšie súbory údajov o krajinnej pokrývke (Obr. 8.2). Výsledkom je, že takéto údaje sú čoraz dostupnejšie, používateľská základňa sa neustále rozširuje, aplikačné oblasti sa rozširujú a zvyšuje sa potenciál pre mnoho ďalších aplikácií.



Obr. 8.2 Vznik mapy krajinnej pokrývky zo satelitnej snímky. **Fig. 8.2** Origin of a land cover map from a satellite image. Source: after Uddin et al., 2015

8.1.1.Evironmental aspects of land cover and its use

Krajinná pokrývka zemského povrchu sa od nepamäti mení a je pravdepodobné, že sa bude meniť aj v budúcnosti. Tieto zmeny sa vyskytujú v rôznych priestorových mierkach od miestnych po globálne a v časových frekvenciách dní až tisícročí. Za tieto zmeny sú zodpovedné prírodné ako aj antropogénne činitele. Prírodné sily, ako napr. kontinentálny drift, zaľadnenie, záplavy a cunami; a antropogénne sily, ako je premena lesa na poľnohospodársku pôdu, rozrastanie miest, resp. vysádzanie lesných monokultúr vo forme lesných plantáží, zmenili dynamiku typov využívania pôdy/krajinnej pokrývky na celom svete. V posledných desaťročiach antropogénne zmeny využívania pôdy/krajinnej pokrývky postupujú oveľa rýchlejšie ako prirodzené zmeny.

Táto bezprecedentná miera zmien je v súčasnosti celosvetovo veľkým environmentálnym problémom. Výsledkom je, že takmer všetky ekosystémy sveta boli výrazne zmenené alebo sú pozmenené ľuďmi, čím sa narúša schopnosť ekosystémov planéty poskytovať prirodzené prostredie a jeho produkty. Dve hlavné sily zodpovedné za antropogénne zmeny sú technologický rozvoj a rastúca ľudská populácia.

Zmeny krajinnej pokrývky zohrávajú významnú úlohu v globálnom kolobehu uhlíka v prostredí, ako aj pri výmene skleníkových plynov medzi zemským povrchom a

8 Applications of RS – Land use/Land cover, Agriculture

atmosférou (Obr. 8.3). Napríklad odlesňovanie uvoľňuje oxid uhličitý do atmosféry a mení mieru odrazivosti zemského povrchu, evapotranspiráciu a oblačnosť, čo následne ovplyvňuje klimatické zmeny a variabilitu. Na rozdiel od toho zalesňovanie a obnova lesov odstraňujú uhlík z atmosféry. Nedávne dôkazy ukazujú, že človekom vyvolané zmeny vo využívaní/krajinnej pokrývke za posledných 150 rokov viedli k uvoľneniu obrovského množstva uhlíka do atmosféry. Hoci spaľovanie fosílnych palív je dominantným zdrojom uvoľňovania uhlíka do atmosféry, využívanie pôdy stále prispieva významnou časťou (~20%) k antropogénnym emisiám, najmä v tropických oblastiach.



Pozn. Čas vegetačného vrcholu, teda mesiac, v ktorom sa vyskytuje maximum zelene je znázornený červenými (jar) a zelenými (leto) až modrými tónmi (jeseň a zima). Variabilita vegetačnej zelene je reprezentovaná svetlými tónmi v oblastiach s nízkou amplitúdou ako napr. obhospodarované trávnaté porasty, pričom vysoké amplitúdy predstavujú nasýtené farebné tóny. Oblasti s nízkou biomasou, ako sú mestské oblasti a otvorené vodné plochy, sú zobrazené čiernou farbou, zatiaľ čo oblasti s vyššou biomasou sa zobrazujú v sivobielych tónoch.

Obr. 8.3 Globálna mapa dynamiky krajinnej pokrývky. **Fig. 8.3** Global map of land-cover dynamics.

Source: contains modified Copernicus Sentinel data (2016–18), processed by GeoVille

Zmeny krajinnej pokrývky a využívania pôdy môžu mať pozitívne alebo negatívne účinky na ľudskú spoločnosť a môžu mať aj zamýšľané alebo nezamýšľané dôsledky. Premena lesov na ornú pôdu poskytovala potraviny, palivo a množstvo ďalších produktov rastúcej ľudskej populácii počas celej ľudskej histórie. Odlesňovanie tropických oblastí zároveň znížilo biodiverzitu, zhoršilo povodia, zvýšilo eróziu pôdy a následne zvýšilo riziko neúmyselných, no ničivých lesných požiarov. V dôsledku rýchlych a bezprecedentných zmien využívania pôdy/krajinnej pokrývky v posledných rokoch sa negatívne dôsledky, ako je erózia pôdy, strata biodiverzity, znečistenie vody a ovzdušia, zvýšili. Prínosy a ekonomické zisky, ktoré ekosystémy poskytujú sa postupne zmazávajú, pretože tieto výhody sa získavajú na úkor degradácie týchto ekosystémov (Obr. 8.4). 8 Applications of RS – Land use/Land cover, Agriculture



Obr. 8.4 Zmena krajinnej pokrývky a využitia pôdy s negatívnym dopadom na ekosystém; Stolické vrchy, Slovensko.

Fig. 8.4 Change of the land cover and land use with a negative impact on the ecosystem; Stolické vrchy, Slovakia.

Source: https://dennikn.sk/, photo – Ján Kristofory

8.1.2. Needs and possibilities for land cover mapping

Pochopenie distribúcie a dynamiky krajinnej pokrývky je kľúčové pre lepšie pochopenie základných charakteristík a procesov Zeme, vrátane produktivity krajiny, rozmanitosti rastlinných a živočíšnych druhov a bio-geo-chemických a hydrologických cyklov. Hodnotenie a monitorovanie distribúcie a dynamiky lesov, kríkov, pastvín, ornej pôdy, neplodnej pôdy, mestskej pôdy a vodných zdrojov sú dôležitými prioritami v štúdiách o globálnych zmenách životného prostredia, ako aj v každodennom plánovaní a riadení. Informácie o krajinnej pokrývke a zmene krajinnej pokrývky sú potrebné pre manažment prírodných zdrojov a monitorovanie globálnych environmentálnych zmien a ich dôsledkov.

Medzi hlavných odberateľov dát získaných z pozorovania a monitorovania krajinnej pokrývky a jej využitia patria:

- Národné, regionálne alebo miestne samosprávy, ktoré potrebujú informácie, ktoré im pomôžu pri rozvoji a implementácii ich politík a ktoré im pomôžu splniť požiadavky z toho vyplývajúce,
- Medzinárodné iniciatívy na pomoc pri rozvoji a financovaní programov pre krajiny, ktoré potrebujú informácie na rozvoj svojich politík a operačných stratégií,
- Mimovládne organizácie,
- Vedci, výskumníci, ktorí potrebujú informácie na zlepšenie nášho chápania procesov spojených so zemským systémom,
- Bežný občan, ktorý potrebuje zrozumiteľné a spoľahlivé informácie o globálnych environmentálnych trendoch,

• Súkromný sektor, ktorý potrebuje informácie, ktoré mu pomôžu stať sa partnerom ostatnými odberateľmi.

Vďaka pokroku v oblasti satelitných technológií, geografických informačných systémov (GIS) a počítačového hardvéru je v súčasnosti možné hodnotiť a monitorovať zmeny využívania krajiny/krajinnej pokrývky na viacerých priestorových a časových úrovniach. Pre tento účel ponúka diaľkový prieskum Zeme viacero výhod. Ide o relatívne lacnú a rýchlu metódu získavania aktuálnych informácií na veľkom geografickom území vďaka prehľadnému pokrytiu a opakovanému snímaniu tohto územia. Dáta ktoré sa zvyčajne získavajú v digitálnej forme, sa ľahšie manipulujú a analyzujú; možno ich získať nielen z viditeľného spektra, ale aj z častí EM spektra, ktoré sú pre ľudské oči neviditeľné; možno ich získať zo vzdialených oblastí, kde je problémom dostupnosť; a poskytujú nezaujatý pohľad na využitie krajiny/krajinnú pokrývku. Historické údaje pochádzajú už zo 70. rokov minulého storočia a postupne sa stávajú voľne dostupnými. Na mapovanie, monitorovanie a hodnotenie krajinnej pokrývky je v súčasnosti k dispozícii viacero typov dát z diaľkového prieskumu Zeme.

Na rozdiel od krajinnej pokrývky je monitorovanie využitia pôdy náročnejšie, pretože zamýšľané využitie pôdy sa môže líšiť od skutočného využitia. To, čo na satelitných snímkach vidíme, sú fyzické artefakty použitia. Napríklad les je v mnohých krajinách definovaný ako pôda označená vládou ako les bez ohľadu na to, či je pôda pokrytá stromami alebo nie. Z pohľadu krajinnej pokrývky by to mohla byť neúrodná pôda, ak oblasť nepokrývajú stromy. Niektoré typy využitia územia, ako sú priemyselné oblasti, možno mapovať pomocou údajov o satelitných snímok, najmä pomocou satelitov s veľmi vysokým rozlíšením, leteckých fotografií, pomocných údajov a/alebo in situ dát (Obr. 8.5). Určité typy využitia krajiny možno odvodiť z pozorovaných typov krajinnej pokrývky, pretože sféry využitia krajiny a krajinnej pokrývky sú vzájomne prepojené. Pozorovanie využitia krajiny pomocou údajov zo satelitných snímok sa stáva komplikovaným, ak je jedna trieda krajinnej pokrývky spojená s viacerými použitiami a viaceré typy krajinnej pokrývky sa používajú na jedno použitie. Napríklad lesná pôda sa môže použiť na produkciu dreva, výrobu palivového dreva, rekreáciu, ochranu biodiverzity, lov/zber, ochranu pred povodňami, ochranu pôdy a pod. Okrem toho niekoľko typov krajinnej pokrývky, ako sú orná pôda, trávne porasty, lesy a sídla, sa môže použiť pre jeden poľnohospodársky systém.



Obr. 8.4 Mapa krajinnej pokrývky pre Luxembursko vo vysokom rozlíšení (2018) získaná z LiDAR dát a časovej série snímok Sentinel-2. **Fig. 8.4** The high-resolution land cover map for Luxembourg (2018) obtained based on LiDAR data and time series of Sentinel-2 images. Source: http://space4environment.com

8.1.3. Definition of land cover, land cover use and land use change

Krajinná pokrývka a využitie krajinnej pokrývky sa v literatúre a tiež v každodennej praxi často zamieňajú. **Krajinná pokrývka** sa vzťahuje na pozorované biotické a abiotické zoskupenia na zemskom povrchu a bezprostredne pod povrchom. Príkladmi hlavných typov krajinnej pokrývky sú lesy, kroviny, pasienky, orná pôda, neúrodná pôda, ľad a sneh, mestské oblasti a vodné tvary (vrátane podzemných vôd). Tento pojem teda zahŕňa nielen vegetáciu ktorá pokrýva krajinu, ale aj ľudské štruktúry, ako sú cesty, zastavané oblasti a bezprostredné podpovrchové prvky, ako je podzemná voda. **Využitie krajiny** je definované ako spôsob akým pôdu využívajú alebo zaberajú ľudia. Stručne povedané, krajinná pokrývka predstavuje viditeľný dôkaz využívania krajiny. Krajina pokrytá vegetáciou môže predstavovať les pri pohľade zo zeme alebo na satelitných snímkach; rovnaký lesný úsek však možno využiť na výrobné, rekreačné, alebo ochranárske účely. Inými slovami, krajinná pokrývka je pozorovaná fyzická pokrývka, zatiaľ čo využitie krajiny je založené na funkcii alebo sociálno-ekonomickom účele, na ktorý sa pôda využíva. Pozemok môže mať iba jeden krajinný kryt (napr. lesy), ale môže mať viac ako jedno využitie územia (napr. rekreačné, vzdelávacie a ochranné).

Zmenu využitia krajiny možno charakterizovať ako zmenu a úpravu krajinnej pokrývky. Zmena krajinnej pokrývky je zmena z jednej kategórie krajinnej pokrývky do druhej a úprava je zmena stavu v rámci kategórie krajinnej pokrývky. Príkladom zmeny je zmena z ornej pôdy na mestskú pôdu a príkladom úpravy je degradácia lesov. Degradácia lesa môže byť spôsobená zmenou fenológie, biomasy, hustoty lesa, napadnutím drevokazným hmyzom, záplavami a poškodením víchricou. Zmena sa

pomocou údajov z diaľkového prieskumu Zeme vo všeobecnosti ľahšie identifikuje a monitoruje ako úprava pokrývky. Zmena je zvyčajne dlhodobý proces a môže vyžadovať viacročné a viacsezónne údaje na presnú kvantifikáciu. Zmena využívania krajiny je zmena vo využívaní alebo obhospodarovaní pôdy ľuďmi. Zmena využívania pôdy sa môže zmeniť bez premeny alebo úpravy krajinnej pokrývky. Napríklad produkčný les môže byť vyhlásený za chránené územie a návštevnosť v rekreačnom lese sa môže meniť bez úpravy krajinnej pokrývky. Naopak, krajinná pokrývka sa môže zmeniť aj vtedy, ak využitie krajiny zostane nezmenené; zmena využívania pôdy však pravdepodobne spôsobí zmenu krajinnej pokrývky.

8.2. CORINE Land Cover (CLC)

8.2.1. Definition, history and content of CLC

Mapovanie krajinnej pokrývky a jej zmien aplikáciou satelitných snímok na úrovni jednotlivých štátov sa uskutočňuje v rámci rôznych medzinárodných programov a projektov. Jedným z pozoruhodných príkladov dokumentujúcich plnenie takéhoto cieľa v európskych štátoch je program CORINE - "Koordinácia informácií o životnom prostredí" (Coordination of Information on the Environment). Tento program 27. júna 1985 schválila Európska Komisia, s cieľom utvoriť informačný systém o stave prostredia v štátoch Európskeho spoločenstva. V roku 1991 sa na zasadnutí ministrov životného prostredia európskych štátov v Dobříši (ČR) rozhodlo, že realizácia projektov Biotopes, Corinair a Land Cover uvedeného programu sa rozšíri aj do štátov strednej a východnej Európy. V roku 1992 sa do riešenia projektu Land Cover zapojila aj Slovenská republika. Cieľom tohto projektu bolo vytvoriť jednotnú bázu údajov o krajinnej pokrývke Európy a jej zmenách v mierke 1 : 100 000, použitím najmä snímok Landsat TM, SPOT a neskôr v nadväzujúcich projektoch CLC použitím snímok z ďalších satelitov (IRS, Spot, Sentinel).

Súpis CORINE Land Cover (CLC) sa začal v roku 1985 má teda takmer 40-ročnú históriu. Aktualizácie boli vytvorené postupne v rokoch 2000, 2006, 2012 a 2018 (pozri Tab. 8.1). Pozostáva zo súpisu krajinnej pokrývky v 44 triedach. Hlavným cieľom bolo určenie environmentálnej politiky a správne posúdiť účinky tejto politiky a začleniť environmentálny rozmer do iných politík. Európska komisia potrebovala správne údaje o životnom prostredí a pochopenie prebiehajúcich procesov. Ďalším cieľom programu CORINE bolo spojiť všetky pokusy, ktoré sa v priebehu rokov uskutočnili na rôznych úrovniach (medzinárodnej, komunitárnej, národnej a regionálnej) s cieľom získať viac informácií o životnom prostredí a jeho zmenách, a to vypracovaním postupov na ich porovnávanie, a výmeny údajov o životnom prostredí v členských štátoch.

Všetky výsledky projektov CLC sú spracované ako štandardné GIS vrstvy s polygónovou topológiou, pre ktoré má užívateľ k dispozícii aj metainformácie na úrovni mapových listov v mierke 1 : 100 000 Slovenska, ako aj na úrovni jednotlivých participujúcich štátov Európy. Zo Slovenska sú tieto údaje uložené na serveroch Slovenskej agentúry životného prostredia (SAŽP). Uvedené údajové vrstvy a s nimi spojené aplikácie sú prístupné širokej verejnosti prostredníctvom mapového serveru Atlas krajiny Slovenskej republiky na adrese <u>https://app.sazp.sk/atlassr/</u>.

Tab. 8.1 Vývoj CORINE Land Cover.

Tab. 8.1 The evolution of CORINE Land Cover.

Source: CORINE Land Cover Product User Manual (Version 1.0)

	CLC1990	CLC2000	CLC2006	CLC2012	CLC2018
Družice	Landsat-5 MSS/TM jediný dátum	Landsat-7 ETM jediný dátum	SPOT-4/5 a IRS P6 LISS III duálny dátum	IRS P6 LISS III a RapidEye duálny dátum	Sentinel-2 a Landsat-8 na vypInenie medzier
Časová konzistentnosť	1986-1998	2000 +/- 1 rok	2006+/- 1 rok	2011-2012	2017-2018
Geometrická presnosť / družice	≤ 50 m	≤ 25 m	≤ 25 m	≤ 25 m	≤ 10 m (Sentinel-2)
Min. mapovacia jednotka / šírka	25 ha / 100m	25 ha / 100m	25 ha / 100m	25 ha / 100m	25 ha / 100 m
Geometrická presnosť / CLC	100 m	lepšia ako 100 m	lepšia ako 100 m	lepšia ako 100 m	lepšia ako 100 m
Tematická presnosť / CLC	≥ 85% (pravdepodobne nedosiahnutá)	≥ 85% (dosiahnutá)	≥ 85%	≥ 85% (pravdepodobne dosiahnutá)	≥ 85%
Mapovanie zmien / CHA	nerealizované	zmena/posun hranice min. 100 m; zmena plochy pre existujúce polygóny ≥ 5 ha; pre izolované zmeny ≥ 25 ha	zmena/posun hranice min. 100 m; všetky zmeny ≥ 5 ha sa majú zmapovať	zmena/posun hranice min. 100 m; všetky zmeny ≥ 5 ha sa majú zmapovať	zmena/posun hranice min. 100 m; všetky zmeny ≥ 5 ha sa majú zmapovať
Tematická presnosť / CHA	-	nekontrolovaná	≥ 85% (dosiahnutá)	≥ 85%	≥ 85%
Produkčný čas	10 rokov	4 roky	3 roky	2 roky	1.5 roka
Dokumentácia	neúplné metadáta	štandardné metadáta	štandardné metadáta	štandardné metadáta	štandardné metadáta
Prístup k dátam (CLC, CHA)	nejasná politika šírenia	politika šírenia informácií dohodnutá od začiatku	bezplatný prístup pre všetkých používateľov	bezplatný prístup pre všetkých používateľov	bezplatný prístup pre všetkých používateľov
Zapojené krajiny	26 (27 s oneskorenou implementáciou)	30 (35 s oneskorenou implementáciou)	38	39	39

Kritériami pre tvorbu CLC je 44 definovaných tried krajinnej pokrývky, ktoré sú záväzné pre všetky európske štáty (pozri Tab. 8.2); detailnosť databáz zodpovedá mierke spracovania 1 : 100 000, minimálna rozloha identifikovaného areálu je 25 ha (v mierke 1 : 100 000 štvorec 5 x 5 mm), minimálna šírka líniového objektu 100 m (v mierke 1 : 100 000 minimálna šírka 1 mm) a minimálna veľkosť zmeny areálu krajinnej pokrývky 5 ha. Zmeny stavu krajinnej pokrývky sú odvodené porovnaním údajových vrstiev CLC v jednotlivých rokoch využitím GIS nástrojov. Pod zmenou rozumieme konverziu jednej triedy krajinnej pokrývky, prípadne jej častí na inú triedu.

Tab. 8.2 Triedy krajinnej pokrývky Corine Land Cover.

 Tab. 8.2 Standard CORINE Land Cover nomenclature.

Source: CORINE Land Cover Product User Manual (Version 1.0)

Úroveň 1	Úroveň 2	Úroveň 3		
	1.1. Urbanizovaná (sídelná) zástavba	1.1.1. Súvislá sídelná zástavba 1.1.2. Nesúvislá sídelná zástavba		
1. Urbanizované a technizované	1.2. Priemyselné, obchodné a dopravné areály	 1.2.1. Priemyselné a obchodné areály 1.2.2. Cestná a železničná sieť a priľahlé areály 1.2.3. Areály prístavov 1.2.4. Areály letísk 		
areály	1.3. Areály ťažby, skládok a výstavby	1.3.1. Areály ťažby nerastných surovín1.3.2. Areály skládok (smetiská)1.3.3. Areály výstavby		
	1.4. Areály sídelnej (nepoľnohospodárskej) vegetácie	 1.4.1. Areály sídelnej vegetácie 1.4.2. Areály športu a zariadení voľného času 		
	2.1. Orná pôda	2.1.1. Nezavlažovaná orná pôda2.1.2. Permanentné zavlažovaná orná pôda2.1.3. Ryžové polia		
2. Poľnohospodárske	2.2. Trvalé kultúry	2.2.1. Vinice2.2.2. Ovocné stromy a plantáže ovocnín2.2.3. Olivové sady		
areály	2.3. Areály tráv	2.3.1. Trávnaté porasty (lúky a pasienky)		
	2.4. Heterogénne poľnohospodárske areály	 2.4.1. Jednoročné plodiny s trvalými kultúrami 2.4.2. Mozaika polí, lúk a trvalých kultúr 2.4.3. Prevažne poľnohospodárske areály s výrazným podielom prirodzenej vegetácie 2.4.4. Poľnohospodársko-lesné areály 		
		3.1.1. Listnaté lesy		
	3.1. Lesy	3.1.2. Ihličnaté lesy 3.1.3. Zmiešané lesy		
3. Lesné a poloprírodné areály	3.2. Kroviny alebo trávne areály	 3.2.1. Prirodzené lúky 3.2.2. Vresoviská, slatiny a kosodrevina 3.2.3. Tvrdolistá vegetácia 3.2.4. Prechodné leso-kroviny 		
	3.3. Holiny s riedkou vegetáciou alebo bez vegetácie	 3.3.1. Pláže, duny, piesky 3.3.2. Skaly 3.3.3. Areály s riedkou vegetáciou 3.3.4. Spáleniská 3.3.5. L'adovce a večný (trvalý) speh 		
	4.1. Vnútrozemské mokrade	4.1.1. Močiare 4.1.2. Rašeliniská		
4. Zamokrené areály	4.2. Prímorské močiare	4.2.1. Slané močiare4.2.2. Saliny4.2.3. Prílivové územia		
	5.1. Vnútrozemské vody	5.1.1. Vodné toky 5.1.2. Vodné plochy		
5. Vody	5.2. Morské vody	5.2.1. Pobrežné lagúny 5.2.2. Ústia riek 5.2.3. Moria a oceány		

Hlavné technické parametre CLC odrážajú potreby hlavného používateľa – Európskej komisie. Národné potreby používateľov sa do CLC môžu zaviesť tromi spôsobmi:

- 1. Používanie vyššieho geometrického rozlíšenia ako štandardných 25 ha,
- 2. Používanie väčšej tematickej podrobnosti (t. j. kategórie 4. alebo 5. úrovne), ako je uvedené v štandardnej nomenklatúre (Tab. 8.2),
- 3. Voľnosť krajín pri rozhodovaní o niektorých špecifikáciách metodiky a o použitých pomocných údajoch, pokiaľ sú výsledky v súlade so špecifikáciami produktu CLC.

Národné databázy CLC sú vytvárané sieťou Eionet National Reference Centers Land Cover (NRC/LC), a následne koordinované a integrované Európskou environmentálnou agentúrou EEA. Viacero krajín využíva poloautomatizované spracovanie využívajúce kombináciu in-situ meraní a spracovania satelitných snímok s následnou integráciou do GIS. CLC má širokú škálu aplikácií, ktoré podporujú rôzne politiky v oblastiach životného prostredia, ale aj poľnohospodárstva, dopravy, územného plánovania atď. (Obr. 8.5).

Od roku 2012 je projekt CORINE Land Cover zahrnutý do programu Copernicus (pozri Kapitola 1.4).



Obr. 8.5 Mapa CORINE Land Cover Európy z roku 2018. **Fig. 8.5** CORINE Land Cover Map of Europe 2018. Source: ©European Environment Agency (EEA)

8.2.2. Corine Land Cover in Slovakia

Program CLC na Slovensku je realizovaný **Slovenskou Agentúrou Životného Prostredia SAŽP** (Slovak Environment Agency) v spolupráci s Národným poľnohospodárskym a potravinárskym centrom, Národným lesníckym centrom a Geografickým ústavom SAV.

Základné práce pozostávali z verifikácie lokálnych komponentov, produktu Corine Land Cover (CLC) 2018 a verifikácie snímok s vysokým rozlíšením HRL 2015. Hlavná časť projektu CLC 2018 bola zameraná na aktualizáciu vrstvy CLC 2012 (revízia pôvodnej vrstvy) a tvorby novej vrstvy CLC 2018 (zmeny CLC 2018). Pod aktivity projektu boli zahrnuté na hodnotenie sústavy vrstiev Natura 2000, Urban atlas (mestských zón), Riparian zone (okrajové – pobrežné zóny).

Aktivity projektu poskytli doplňujúce informácie založené na regionálnych miestnych znalostiach o špecifikách (ako doplnok k systematickým kvantitatívnym výsledkom validácie) v rámci európskeho rozsahu. Obohatenie existujúcich vrstiev o nové informačné atribúty (napr. školy, nemocnice, prechodové pobrežné zóny, či chránené oblasti) napomáhajú pri ich využívaní.

Informácie o projekte je možné nájsť na adrese https://copernicus.sazp.sk/.

Mapový prehliadač s vrstvami CLC (Obr. 8.6) je dostupný na adrese <u>https://geo.enviroportal.sk/corine/</u>.



Obr. 8.6 Mapa CORINE Land Cover Slovenska z roku 2018. **Fig. 8.6** CORINE Land Cover Map of Slovakia 2018. Source: ©Slovak Environment Agency (SAŽP)

8.3. Remote Sensing in Agriculture

Z historického hľadiska patrí poľnohospodárstvo medzi najväčšie aplikačné oblasti diaľkového prieskumu Zeme. Potreba, aby bolo poľnohospodárstvo trvalo udržateľné a nepoškodzovalo prírodné prostredie, je čoraz dôležitejšia. Tak isto je dôležitý monitoring rozsahu a rozloženia obrábanej, resp. neobrábanej pôdy a s tým spojená úroveň biodiverzity, z čoho je možné určiť, či dochádza k poškodeniu lokálnych ekosystémov.

Medzi najdôležitejšie využitie satelitných dát v poľnohospodárstve patrí klasifikácia druhov plodín, hodnotenie stavu plodín a včasné odhalenie problémov, podpora pre "presné poľnohospodárstvo", a iné formy manažmentu plodín.

Klasifikácia druhov plodín je založená na predpoklade, že špecifické typy plodín možno identifikovať podľa ich spektrálnej odrazivosti a textúry na snímke. Úspešná identifikácia plodín si vyžaduje znalosť jednotlivých vývojových štádií každej plodiny v oblasti, ktorá sa monitoruje (Obr. 8.7). Kvôli zmenám v charakteristikách plodín počas vegetačného obdobia je často potrebné použiť na identifikáciu plodín snímky získané v rôznych dátumoch počas ich vegetačného cyklu. Plodiny, ktoré sa v jeden deň javia veľmi podobne, budú v inom čase vyzerať celkom inak a na získanie jedinečného vzoru spektrálnej odrazivosti z každého typu plodiny môže byť potrebných viacero snímok z rôznych období. Použitie snímky v nepravých farbách pomocou infračerveného pásma alebo multispektrálnej snímky so spektrálnymi pásmami v blízkom a strednom infračervenom pásme umožňuje podrobnejšiu a presnejšiu klasifikáciu plodín ako panchromatické snímky alebo RGB snímky v pravých farbách.



Obr. 8.7 Fázy cyklu plodín s príslušnými fázami vývoja rastlín. **Fig. 8.7** Stages of the crop cycle with corresponding stages of plant development. Source: Bloomfield et al., 2014

Monitoring stavu plodín sa môže vykonávať aj vizuálne priamo na snímke, ale čoraz častejšie sa využívajú dáta z multispektrálnych alebo hyperspektrálnych snímok ako vstup modelov, ktoré využívajú konkrétne kombinácie spektrálnych pásiem na výpočet parametrov ako je Index Listovej Plochy LAI (Leaf Area Index) (Obr. 8.8), podiel absorbovaného fotosynteticky aktívneho žiarenia (fPAR), obsah vody v listoch a pod. Tieto modely však vyžadujú snímky opravené o vplyv atmosféry, aby sa zabezpečilo, že spektrálna odrazivosť na snímkach bude reprezentovať skutočnú spektrálnu odrazivosť na povrchu.



Obr. 8.8 Globálne rozloženie hodnôt LAI z CGLS PROBA-V 300 m VI pre 20. jún 2017. **Fig. 8.8** Global distribution of LAI values from CGLS PROBA-V 300 m VI for 20 June 2017. Source: Fuster et al., 2020

Presné poľnohospodárstvo alebo "presný manažment plodín" (Precision Crop Management - PCM) bolo definované ako informačný a technologický systém riadenia poľnohospodárstva, ktorý identifikuje, analyzuje a riadi priestorovú a časovú variabilitu pôdy a plodín v rámci polí s cieľom dosiahnuť optimálnu ziskovosť, udržateľnosť a ochranu. Cieľom PCM je zacieliť aplikačné dávky na miestne špecifické podmienky vyskytujúce sa v rámci poľa a tým maximalizovať ziskovosť a minimalizovať plytvanie energiou a znečistenie povrchových a podzemných vôd. Zatiaľ čo PCM je relatívne mladé, vizuálna interpretácia satelitných snímok má dlhú históriu v manažmente poľnohospodárskych plodín. Napríklad snímky s vysokým rozlíšením sa ukázali ako užitočné na monitorovanie škôd spôsobených chorobami plodín, poškodením hmyzom, stresom rastlín z iných príčin a poškodením spôsobeným katastrofami. Úspešne sa tiež využívali infračervené snímky vo falošných farbách s vysokým rozlíšením získané v konkrétnych časových úsekoch, často v dvoch alebo viacerých dátumoch počas vegetačného obdobia. Okrem "detekcie stresu vegetácie" môžu takéto satelitné snímky poskytnúť viacero ďalších informácií dôležitých pre manažment plodín.

Interpretácia satelitných snímok na posúdenie aktuálneho stavu plodín je oveľa náročnejšia úloha ako ich interpretácia pre zdokumentovanie typu plodiny a veľkosti príslušnej plochy. Základom sú pozemné referenčné údaje a vo väčšine doterajších štúdií sa porovnávali zdravé a stresované porasty rastúce na susedných poliach alebo pozemkoch. Za týchto podmienok vieme pri interpretácii rozlišovať jemnejšie rozdiely v spektrálnej odozve, ako by bolo možné pri neporovnávacej analýze. Takisto by bolo ťažšie rozlíšiť účinky chorôb, poškodenia hmyzom, nedostatku živín alebo sucha od rozdielov spôsobených odrodou rastlín, zrelosťou rastlín, alebo rýchlosťou výsadby. Keďže mnohé účinky stresu sú najzreteľnejšie počas obdobia sucha, snímky by sa nemali získavať príliš skoro po daždivom počasí. Na to, aby boli účinky stresu pozorovateľné, môže byť potrebných niekoľko dní suchého počasia.

Diaľkový prieskum Zeme môže výrazne prispieť k poskytnutiu včasných a presných informácií o poľnohospodárskom sektore. Taktiež predstavuje nákladovo najefektívnejší prostriedok na zhromažďovanie včasných, podrobných a spoľahlivých informácií o veľkých oblastiach s vysokou časovou frekvenciou satelitných snímok.

Aplikácie DPZ v oblasti poľnohospodárstva sa dajú rozdeliť na:

- Odhady biomasy a výnosov,
- Informácie o výmere plodín,
- Objektívne a neskreslené posúdenie stavu plodín na veľkom území (poľnohospodárskych) oblastí s vysokou časovou frekvenciou snímok,
- Mapovanie vegetačného stresu,
- Hodnotenie katastrofických klimatických udalostí na poľnohospodársku produkciu,
- Identifikácia modelov pestovania plodín a poľnohospodárskych výrobných systémov,
- Informácie potrebné pre pochopenie možných účinkov zmeny klímy,
- Identifikácia oblastí s nedostatkom výnosov,
- Mapovanie fenologického vývoja plodín,
- Mapovanie zavlažovaných plôch a požiadaviek na vodu,
- Zvýšenie efektívnosti produktivity prostredníctvom presného poľnohospodárstva,
- Monitorovanie rozširovania poľnohospodárstva/opustenia poľnohospodárskej pôdy.

8.3.1. Use of RS for crop and biomass assessment

Poľnohospodárska vegetácia sa vyvíja od zasiatia po zber úrody v závislosti od meteorologických premenných (napr. teplota, slnečné žiarenie a zrážky). Rast rastlín ďalej modifikujú vlastnosti pôdy a rastlín (genetika), ako aj poľnohospodárske postupy. Keďže zmeny vitality, hustoty, zdravotného stavu a produktivity plodín ovplyvňujú optické vlastnosti vegetačne pokrývky, vývoj a rast plodín možno monitorovať aj na diaľku.

Vzťah medzi spektrálnymi vlastnosťami plodín a ich biomasou/výnosom je známy od prvých spektrometrických experimentov s poľnými rastlinami. Už začiatkom 80. rokov 20. storočia sa preukázalo, že poľnohospodársku plodinu možno monitorovať prostredníctvom jej spektrálnych odrazových vlastností. Využitie spektrálnych údajov sa intenzívne skúmalo pomocou satelitných snímok po vypustení prvej civilnej družice na pozorovanie Zeme (Landsat-1). Avšak až od začiatku 80. rokov 20. storočia, s rastúcou dostupnosťou snímok s nízkym priestorovým rozlíšením zo senzora s veľmi vysokým rozlíšením (AVHRR) na palube meteorologických satelitov série známej ako National Oceanic and Atmospheric Administration (NOAA), sa podobné analýzy rozšírili na veľké územia vrátane mnohých krajín so suchým podnebím. Systémy s nízkym rozlíšením majú vďaka svojej veľkej šírke záberu oveľa lepší synoptický prehľad a časovú frekvenciu opätovných preletov nad daným územím v porovnaní so senzormi s vysokým priestorovým rozlíšením. Nevýhoda týchto senzorov súvisí s ich nízkym priestorovým rozlíšením, pričom veľkosť pixla je približne 1 km2, teda ďaleko viac ako typické rozmery jednotlivých polí. V dôsledku toho sú zaznamenané spektrálne odrazy zložené väčšinou zo zmiešaných informácií z viacerých typov povrchov. To potom komplikuje interpretáciu (a validáciu) dát, ako aj spoľahlivosť odvodených informačných produktov.

Veľký počet satelitných senzorov, ktoré využívajú ako aktívne tak aj pasívne senzory, v súčasnosti poskytuje údaje v širokom spektrálnom rozsahu (od optických až po mikrovlnné) (Obr. 8.9). Údaje sa získavajú z rôznych obežných dráh a v rôznom priestorovom a časovom rozlíšení. Na analýzu zaznamenaných snímok a na získanie hľadaných informácií bolo vyvinuté veľké množstvo analytických nástrojov. Okrem analýzy zaznamenaných spektrálnych a časových dát možno analyzovať aj smerové vlastnosti reflektivity vegetácie. Ďalšie užitočné informácie možno získať aj z priestorového usporiadania pixelov, teda z textúry snímky.



Obr. 8.10 Podiel celkovej ornej pôdy určenej na pestovanie potravinárskych plodín v porovnaní so všetkými ostatnými plodinami.

Fig. 8.10 The fraction of the total cropland dedicated to growing food crops versus all other crop uses.

Source: Foley et al., 2011

8.3.2. Qualitative crop monitoring

Metódy monitorovania plodín, ktoré sú založené na kvalitatívnej (alebo porovnávacej) interpretácii ukazovateľov získaných diaľkovým prieskumom Zeme, sa dajú zhrnúť pod pojmom "kvalitatívne monitorovanie plodín". Vo všeobecnosti sú tieto metódy založené na porovnaní aktuálneho stavu plodín s predchádzajúcimi sezónami, alebo s tým, čo možno považovať za priemernú alebo "normálnu" situáciu. Zistené odchýlky (alebo "anomálie") sa potom používajú na vyvodenie záverov o možných obmedzeniach úrody.

Na kvalitatívne monitorovanie rastu plodín sa používa veľké množstvo vegetačných indexov získaných z nástrojov DPZ alebo rôznych biofyzikálnych produktov. Postupne sa do popredia dostalo používanie indexu NDVI (Normalizovaný Diferenčný Vegetačný Index) poľnohospodárskej (a prirodzenej) vegetácie (Obr. 8.11).

Už začiatkom 80. rokov 20. storočia sa prišlo na užitočnosť charakterizovania vegetácie pomocou aritmetických kombinácií odrazivosti vegetácie v rôznych spektrálnych pásmach (tzv. "*vegetačné indexy*"). Na základe viacerých vedeckých prác bol navrhnutý index NDVI, pričom bol definovaný na základe odrazivosti v červenom a blízkom infračervenom pásme. NDVI sa následne stalo najobľúbenejším ukazovateľom na štúdium zdravotného stavu vegetácie a produkcie plodín pomocou kvalitatívneho monitorovania.

Na regionálne až kontinentálne monitorovanie vegetácie pomocou vegetačných indexov sú najvhodnejšie satelity s nízkym rozlíšením, pretože ponúkajú vysokú časovú frekvenciu opakovaných preletov nad daným územím s veľkým geografickým pokrytím, zároveň pri nízkych nákladoch na výsledné dáta prepočítané na jednotku zobrazenej plochy.



Obr. 8.11 Zobrazenie NDVI vegetačného indexu na základe snímky Sentinel-2 pre oblasť v Alberte, Kanada.

Fig. 8.11 The view of NDVI vegetation index based on Sentinel-2 image for the area in Alberta, Canada.

Source: https://www.usgs.gov

Systémy monitorovania plodín využívajúce "mapy anomálií" sú užitočné najmä v suchých a polosuchých krajinách, kde časová a geografická premenlivosť zrážok vedie k veľkým medziročným výkyvom v primárnej produkcii a k veľkému riziku hladomorov. Takéto environmentálne udalosti spolu so širokým rozsahom oblastí na monitorovanie a všeobecne slabou dostupnosťou efektívnych systémov zberu poľnohospodárskych údajov predstavujú situáciu, kedy kvalitatívne monitorovanie môže poskytnúť informácie pre včasné varovania o možnom vegetačnom strese plodín. Takéto systémy sa zvyčajne používajú v mnohých krajinách s nedostatkom potravín. Kvalitatívne monitorovanie plodín však nie je nevyhnutne spojené iba s kontextom včasného varovania v suchých oblastiach, ale môže byť tiež veľmi užitočné na získanie rýchleho prehľadu o vegetačnom strese pre veľké oblasti v miernych klimatických zónach.

Dáta z DPZ sa na monitorovanie vegetácie využívajú najmä vo forme informácie o odrazivosti elektromagnetických vĺn od vegetačnej pokrývky pomocou pasívnych satelitných senzorov. Je všeobecne známe, že odrazivosť spektier EMŽ od rastlín sa mení v závislosti od typu rastliny, obsahu vody v tkanivách a ďalších vnútorných faktorov. Odrazivosť EMŽ od vegetácie (spektrálna odrazivosť alebo emisné charakteristiky vegetácie) je určená chemickými a morfologickými vlastnosťami povrchu rastlinných orgánov alebo listov (Obr. 8.12).

Hlavné aplikácie DPZ pre monitorovanie vegetácie sú založené na týchto spektrálnych pásmach EMŽ:

- 1. ultrafialové pásmo (UV) s vlnovou dĺžkou od 10 do 380 nm,
- 2. viditeľné spektrum, ktoré sa skladá z modrého (450 495 nm), zeleného (495 570 nm) a červeného (620 750 nm) pásma;
- 3. blízke a stredné infračervené pásmo (850 1700 nm).



Obr. 8.12 Bunková štruktúra listov a jej interakcia s elektromagnetickým žiarením. Väčšina viditeľného svetla je absorbovaná, zatiaľ čo takmer polovica žiarenia z blízkej infračervenej oblasti sa odráža.

Fig. 8.12 Leaf cell structure and its interaction with electromagnetic radiation. Most of the visible light is absorbed, while almost half of the radiation from the near-infrared is reflected. Source: seos-project.eu/agriculture/agriculture-c01-s01.html

Miera vyžarovania povrchu listov (ekvivalentná absorpčnej schopnosti v tepelnom vlnovom pásme) plne dospelej zelenej rastliny bez akéhokoľvek biotického alebo abiotického stresu sa vo všeobecnosti pohybuje v rozsahu 0,96 - 0,99. Naopak, v prípade suchých rastlín má miera vyžarovania vo všeobecnosti väčší rozsah, ktorý sa pohybuje od 0.88 do 0.94.

Vyžarovanie vegetácie v blízkej a strednej infračervenej oblasti možno priradiť k celému radu vegetačných charakteristík pre kvantifikáciu rastu a vitality rastlín, ktoré súvisia okrem iného s obsahom vody, pigmentov, cukrov a sacharidov, bielkovín a aromatických látok.

Rôzne aplikácie pre kvalitatívne monitorovanie závisia od maximálnej odrazivosti pre špecifické zlúčeniny v rámci viditeľnej a blízkej/strednej infračervenej oblasti EMŽ spektra.

Odrazivosť vegetácie v tepelnom infračervenom spektre (8–14 µm) sa riadi zákonom žiarenia čierneho telesa, čo umožňuje považovať vyžarovanie rastlín za priamy súvis s teplotou vegetácie. Indexy získané z tohto rozsahu spektra sa teda môžu použiť ako zástupný ukazovateľ na posúdenie rýchlosti transpirácie rastlín. Ďalšie indexy sa môžu použiť ako indikátor stavu vody v rastlinách, resp. úrovne abiotického/biotického stresu. Z toho vyplýva, že kvantitatívna interpretácia informácií z DPZ z vegetácie je komplexná úloha.

Krivka spektrálnej odrazivosti EMŽ pre vegetáciu je znázornená na Obr. 8.13.

8 Applications of RS – Land use/Land cover, Agriculture



Obr. 8.13 Krivka spektrálnej odrazivosti vegetácie s vyznačenými hlavnými absorpčnými a odrazovými vlastnosťami.

Fig. 8.13 Vegetation spectral reflectance curve with the main absorption and reflectance properties plotted.

Source: Coriolan Horațiu Opreanu et al., 2016

Často sa teda kombinujú údaje z blízkych infračervených a červených pásiem rôznymi spôsobmi podľa svojich špecifických cieľov.

Takéto kombinácie však majú aj svoje nevýhody (napr. nedostatočnú citlivosť) pretože, na zisťovanie, napríklad, biomasy vegetácie sa používa jedno spektrálne pásmo alebo ich obmedzená skupina. To sa potom prejavuje najmä pri snahe aplikovať tieto typy vegetačných indexov pre zmiešané kombinácie pôdy, burín, krycích plodín, a záujmovej vegetácie. To potom sťažuje rozlišovanie záujmovej vegetácie a určenie vegetačných indexov, konkrétne vtedy, keď má záujmová vegetácia rôzne hodnoty indexov v dôsledku priestorovej variability alebo hodnoty indexov zodpovedajúce inej vegetácii (burine a krycím plodinám). Aj keď teda existuje viacero limitácií, použitie vegetačných indexov sa stalo jednoduchým a účinným nástrojom na meranie stavu vegetácie na zemskom povrchu.

Vegetačné indexy kombinujúce viditeľné a NIR pásma výrazne zlepšili citlivosť detekcie zelenej vegetácie. Rôzne prostredia majú svoje vlastné premenlivé a komplexné vlastnosti, ktoré je potrebné zohľadniť pri použití rôznych indexov. Preto má každý index svoj špecifický prejav pri zelenej vegetácii, vlastnú vhodnosť na špecifické použitie a niektoré obmedzujúce faktory. Pre praktické aplikácie je preto vždy potrebné vybrať konkrétny index, komplexne zvážiť a analyzovať výhody a obmedzenia existujúcich indexov a potom ich skombinovať tak, aby sa dali použiť v konkrétnom prostredí. Týmto spôsobom možno používanie indexov prispôsobiť konkrétnym aplikáciám, použitým prístrojom a platformám. S rozvojom hyperspektrálnej a multispektrálnej technológie diaľkového snímania sa vyvíjajú nové vegetačné indexy, ktoré rozšíria oblasti výskumu.

V súčasnosti existuje už viac ako 500 druhov indexov s rôznou oblasťou ich využitia. Podľa typov pásiem a spôsobu ich použitia môžeme indexy využiteľné v poľnohospodárstve rozdeliť na 6 základných kategórií.

8.3.2.1. Vegetation Broadband Greenness - Sentinel-2

Zelenosť v širokých spektrálnych pásmach popisuje silu a zdravie zelenej vegetácie. Ide o kombinácie meraní odrazivosti, ktoré sú citlivé na kombinované účinky koncentrácie chlorofylu v listoch, plochy listov koruny, zhlukovania listov a stavby koruny stromov. Tieto indexy sú navrhnuté tak, aby poskytovali meranie celkového množstva a kvality fotosyntetického materiálu vo vegetácii, čo je nevyhnutné na pochopenie stavu vegetácie na akýkoľvek účel. Medzi hlavné indexy tejto kategórie patria:

a) **Jednoduchý pomer SR** (*Simple Ratio*) – jeho hodnota narastá v závislosti množstva zelenej vegetácie obsiahnutej v jednom pixely snímky:

$$\mathbf{SR} = \frac{NIR}{Red} = \frac{B8}{B4} \tag{8.1}$$

Hodnoty indexu sa pohybujú od 0 po viac ako 30, pričom vegetácia nadobúda hodnoty medzi 2 až 8.

 b) Normalizovaný Diferenčný Vegetačný Index NDVI (Normalized Difference Vegetation Index) – vyjadruje mieru nadzemného množstva živej biomasy, najvyššie hodnoty predstavujú hustú zelenú vegetáciu (Obr. 8.14):

$$\mathbf{NDVI} = \frac{NIR - Red}{NIR + Red} = \frac{B8 - B4}{B8 + B4}$$
(8.2)

Hodnoty indexu sa pohybujú v intervale <-1; 1>, pričom vegetácia vo všeobecnosti nadobúda hodnoty medzi 0.2 až 0.8.



Obr. 8.14 NDVI pre zdravú a nezdravú vegetáciu. **Fig. 8.14** NDVI for healthy and stressed vegetation. Source: own processing

c) Vylepšený Vegetačný Index EVI (Enhanced Vegetation Index) - v oblastiach s hustým porastom, kde je index listovej plochy (LAI) vysoký, môžu byť hodnoty NDVI vylepšené využitím informácií v pásme pre vlnovú dĺžku modrej farby. Informácie v tejto časti spektra môžu pomôcť opraviť signály pozadia z pôdy a atmosférické vplyvy:

$$\mathbf{EVI} = 2.5 * \frac{NIR - Red}{NIR + 6 * Red - 7.5 * Blue + 1}$$

$$\mathbf{EVI} = 2.5 * \frac{B8 - B4}{B8 + 6 * B4 - 7.5 * B2 + 1}$$
(8.3)

Hodnoty indexu sa pohybujú v intervale <-1; 1>, pričom vegetácia nadobúda hodnoty medzi 0.2 až 0.8.

d) Vegetačný Index Odolný voči Atmosfére ARVI (Atmospherically Resistant Vegetation Index) – predstavuje vylepšenie NDVI. Je relatívne odolný voči atmosférickým faktorom, ako je aerosól. Funguje tak, že využíva merania odrazivosti v modrých vlnových dĺžkach na korekciu účinkov atmosférického rozptylu, ktoré sa registrujú v červenom spektre odrazu. ARVI je najužitočnejší v oblastiach s vysokým obsahom atmosférických aerosólov:

$$\mathbf{ARVI} = \frac{NIR - Red - 2 * (Red - Blue)}{NIR + Red - 2 * (Red - Blue)}$$

$$\mathbf{ARVI} = \frac{B8 - B4 - 2 * (B4 - B2)}{B8 + B4 - 2 * (B4 - B2)}$$
(8.4)

Hodnoty indexu sa pohybujú v intervale <-1; 1>, pričom vegetácia nadobúda hodnoty medzi 0.2 až 0.8.

Porovnanie týchto indexov pre poľnohospodársku oblasť je znázornené na Obr. 8.15 a pre dažďový prales na Obr. 8.16.



Obr. 8.15 Porovnanie vegetačných indexov pre poľnohospodársku oblasť na základe Sentinel-2. **Fig. 8.15** Comparison of vegetation indices for an agricultural area based on Sentinel-2 imagery. Source: Copernicus Sentinel data [2021]. Retrieved from Copernicus SciHub [02/18/2022], processed by FBERG TUKE



Obr. 8.16 Porovnanie vegetačných indexov pre oblasť Amazonského dažďového pralesa na základe snímky Sentinel-2

Fig. 8.16 Comparison of vegetation indices for an area in Amazon rainforest based on Sentinel-2. Source: Copernicus Sentinel data [2021]. Retrieved from Copernicus SciHub [02/18/2022], processed by FBERG TUKE

8.3.2.2. Vegetation Narrowband Greenness

Podobne ako pre indexy vyjadrujúce zelenosť vegetácie v širokých pásmach, tak aj indexy vyjadrujúce zelenosť vegetácie v úzkych pásmach sú navrhnuté tak, aby poskytovali mieru celkového množstva a kvality fotosyntetického materiálu vo vegetácii. Tieto indexy využívajú merania odrazivosti v červenej a blízkej infračervenej oblasti spektra Červený okraj je názov používaný na opis prudko naklonenej časti krivky odrazivosti v egetácie medzi 690 nm a 740 nm, ktorá je spôsobená prechodom z absorpcie chlorofylu a rozptylu listov v blízkosti infračerveného žiarenia. Použitie hodnôt v blízkej infračervenej oblasti, s oveľa väčšou hĺbkou prieniku cez pokrývku vegetácie ako v červenej oblasti, umožňuje odhadnúť celkové množstvo zelenej vegetácie. Meranie hodnôt v úzkych spektrálnych pásmach na červenom okraji umožňuje, aby boli tieto indexy citlivejšie na menšie zmeny v zdraví vegetácie, najmä v podmienkach hustej vegetácie. Tieto indexy sú určené na použitie pre snímky s vysokým spektrálnym rozlíšením, ako sú snímky získané hyperspektrálnymi senzormi.

a) Normalizovaný Diferenčný Vegetačný Index pre Okraj Červeného Pásma RENDVI (Red Edge Normalized Difference Vegetation Index) – modifikácia široko-spektrálneho NDVI. Využíva dáta z hyperspektrálnych senzorov. RENDVI sa od NDVI líši použitím úzkej časti spektrálneho pásma pri okrajovej časti červeného pásma. Využíva citlivosť vegetácie v tomto pásme na malé zmeny v obsahu lístia v korunách stromov, podiel medzier medzi listami a starnutie rastlín. Využíva sa najmä v presnom poľnohospodárstve, pre monitorovanie lesov a detekciu vegetačného stresu.

$$\mathbf{RENDVI} = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705}}$$
(8.5)

Hodnoty indexu sa pohybujú v intervale <-1; 1>, pričom zelená vegetácia nadobúda hodnoty medzi 0.2 až 0.9.

b) Modifikovaný Jednoduchý Pomer pre Kraj Červeného Pásma MRESR (Modified Red Edge Simple Ratio Index) - modifikácia tradičného SR pre široké spektrálne pásma. Od štandardného SR sa líši tým, že používa úzke časti spektrálneho pásma pri okrajovej časti červeného pásma a obsahuje korekciu pre reflektivitu povrchu listov. Využíva sa najmä v presnom poľnohospodárstve, pre monitorovanie lesov a detekciu stresovanej vegetácie.

$$\mathbf{MRESR} = \frac{\rho_{750} - \rho_{445}}{\rho_{705} - \rho_{445}} \tag{8.6}$$

Hodnoty indexu sa pohybujú od 0 po viac ako 30, pričom zelená vegetácia nadobúda hodnoty medzi 2 až 8.

c) Modifikovaný Normalizovaný Diferenčný Vegetačný Index pre Kraj Červeného Pásma MRENDVI (Modified Red Edge Normalized Difference Vegetation Index) – modifikácia RENDVI. Od RENDVI sa líši tým, že obsahuje korekciu pre reflektivitu povrchu listov. Využíva sa najmä v presnom poľnohospodárstve, pre monitorovanie lesov a detekciu stresovanej vegetácie.

$$\mathbf{MRENDVI} = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705} - 2 * \rho_{445}}$$
(8.7)

Hodnoty indexu sa pohybujú v intervale <-1; 1>, pričom zelená vegetácia nadobúda hodnoty medzi 0.2 až 0.7.

8.3.2.3. Light Use Efficiency

Indexy efektivity využitia svetla umožňujú kvantifikovať schopnosť vegetácie využívať dopadajúce svetlo na fotosyntézu. Z celého elektromagnetického spektra využívajú rastliny počas fotosyntézy len jeho malý rozsah. Tento rozsah spadá do viditeľnej časti spektra - od 400 nm do 700 nm. Schopnosť rastliny efektívne absorbovať energiu v tomto rozsahu môže byť dobrým ukazovateľom na predpovedanie rýchlosti rastu a produkcie biomasy.

a) Index Fotochemickej Odrazivosti PRI (Photochemical Reflectance Index) – využíva zmeny karotenoidných pigmentov, konkrétne xantofylových pigmentov (žltých), ktoré sú absorbované živou zeleňou. Tieto pigmenty predstavujú efektívnosť využitia fotosyntetického svetla a sú užitočné na kvantifikáciu produkcie vegetácie a jej stresu. Tento index je užitočný najmä na meranie zdravia vegetácie pred jej starnutím.

$$\mathbf{PRI} = \frac{\rho_{531} - \rho_{570}}{\rho_{531} + \rho_{570}} \tag{8.8}$$

Hodnoty indexu sa pohybujú v intervale <-1; 1>, pričom zelená vegetácia nadobúda hodnoty medzi -0.2 až 0.2.

b) Index Pigmentu Necitlivého na Štruktúru SIPI (Structure Insensitive Pigment Index) - index vhodný na použitie v oblastiach s vysokou variabilitou štruktúry vegetačnej pokrývky alebo indexu listovej plochy. Tento index maximalizuje citlivosť na pomer objemových karotenoidov k chlorofylu a zároveň minimalizuje vplyv variabilnej štruktúry vegetačnej pokrývky. 8 Applications of RS – Land use/Land cover, Agriculture

$$\mathbf{SIPI} = \frac{\rho_{800} - \rho_{445}}{\rho_{800} - \rho_{680}} \tag{8.9}$$

Hodnoty indexu sa pohybujú v intervale <0; 2>, pričom zelená vegetácia nadobúda hodnoty medzi 0.8 až 1.8.

c) Normalizovaný Diferenčný Index Dusíka NDNI (Normalized Difference Nitrogen Index) - vysoká odrazivosť pri 1510 nm naznačuje vysokú koncentráciu dusíka a celkovú biomasu v zeleni. Naopak, hodnoty odrazivosti v 1680 nm obsahujú podobný signál v dôsledku biomasy zelene bez vplyvu absorpcie dusíka. Tento index sa používa na meranie silnej citlivosti na zmenu stavu dusíka, keď je vegetačná pokrývka zelená. Aplikácie zahŕňajú presné poľnohospodárstvo, analýzu ekosystémov a správu lesov.

$$\mathbf{NDNI} = \frac{\log\left(\frac{1}{\rho_{1510}}\right) - \log\left(\frac{1}{\rho_{1680}}\right)}{\log\left(\frac{1}{\rho_{1510}}\right) + \log\left(\frac{1}{\rho_{1680}}\right)}$$
(8.10)

Hodnoty indexu sa pohybujú v intervale <0; 1>, pričom zelená vegetácia nadobúda hodnoty medzi 0.02 až 0.1.

8.3.2.4. Dry or Senescent Carbon

Vegetačné indexy pre suchý alebo starnúci uhlík využívajú vlastnosti detegované vo vegetačných zložkách počas starnutia, ako sú zmeny lignínu a celulózy. Lignín používajú rastliny na výrobu štrukturálnych komponentov, ako sú drevené stonky. Celulóza sa využíva v štruktúre bunkového tkaniva. Keď vegetácia prechádza alebo sa blíži k starnutiu, koncentrácia týchto materiálov sa môže zvýšiť. Toto zvýšenie spôsobuje, že vegetačný materiál je vysoko horľavý; preto sú tieto indexy vynikajúce pre analýzy horľavých materiálov.

 a) Normalizovaný Diferenčný Index Lignínu NDLI (Normalized Difference Lignin Index) - navrhnutý tak, aby stanovil relatívne množstvo lignínu obsiahnutého vo vegetačných pokrývkach. Vysoká odrazivosť v 1754 nm je do značnej miery určená koncentráciou lignínu v listoch, ako aj celkovou biomasou vegetačného porastu. Ako referenčná hodnota sa používa odrazivosť v 1680 nm. Normalizovaný Diferenčný Index Lignínu sa používa najmä v experimentálnych aplikáciách.

$$\mathbf{NDLI} = \frac{\log\left(\frac{1}{\rho_{1754}}\right) - \log\left(\frac{1}{\rho_{1680}}\right)}{\log\left(\frac{1}{\rho_{1754}}\right) + \log\left(\frac{1}{\rho_{1680}}\right)}$$
(8.11)

Hodnoty indexu sa pohybujú v intervale <0; 1>, pričom zelená vegetácia nadobúda hodnoty medzi 0.005 až 0.5.

b) Index Absorpcie Celulózy CAI (Cellulose Absorption Index) – kvantifikuje exponované povrchy, ktoré obsahujú vysušený rastlinný materiál. Silné absorpčné vlastnosti prítomné v rozsahu 2000 nm až 2200 nm naznačujú silnú prítomnosť celulózy. Využíva sa najmä pre monitorovanie zvyškov úrody, starnutie vegetačnej pokrývky, pomery horľavých materiálov a riadenie pasenia.

$$\mathbf{CAI} = 0.5 * (\rho_{2000} + \rho_{2200}) - \rho_{2100} \tag{8.12}$$

Hodnoty indexu sa pohybujú od -3 po viac ako 4, pričom zelená vegetácia nadobúda hodnoty medzi -2 až 4.

c) Index Odrazivosti Starnutia Rastlín PSRI (Plant Senescence Reflectance Index) - navrhnutý tak, aby maximalizoval citlivosť indexu na pomer objemových karotenoidov (napríklad alfa-karotén a beta-karotén) k chlorofylu. Zvýšenie hodnoty PSRI naznačuje zvýšený stres porastu (karotenoidný pigment), začiatok starnutia porastu a dozrievanie plodov rastlín. Využíva sa pre monitorovanie zdravia vegetácie, detekciu fyziologického stresu rastlín, produkciu plodín a analýzu výnosov.

$$\mathbf{PSRI} = \frac{\rho_{680} - \rho_{500}}{\rho_{750}} \tag{8.13}$$

Hodnoty indexu sa pohybujú v intervale <-1; 1>, pričom zelená vegetácia nadobúda hodnoty medzi -0.1 až 0.2.

8.3.2.5. Leaf Pigment

Vegetačné indexy listového pigmentu sú navrhnuté tak, aby poskytovali mieru pigmentov súvisiacich so stresom prítomných vo vegetácii. Pigmenty súvisiace so stresom zahŕňajú karotenoidy (žlté pigmenty) a antokyány (ružové, fialové a červené pigmenty), ktoré majú tendenciu byť prítomné vo vyšších koncentráciách, keď je vegetácia v oslabenom stave. Karotenoidy pôsobia v procesoch absorpcie svetla v rastlinách, ako aj pri ochrane rastlín pred škodlivými účinkami výrazných svetelných podmienok. Antokyány sú vo vode rozpustné pigmenty, ktoré sa hojne vyskytujú v novovzniknutých listoch a starnúcich listoch. Vegetačné indexy listového pigmentu nemerajú chlorofyl – ten sa zisťuje pomocou indexov zelenosti. Tieto indexy sa využívajú najmä pre monitorovanie plodín, štúdie ekosystémov, analýzy stresu porastu a presné poľnohospodárstvo.

a) Index Odrazivosti Karotenoidov 1 CRII (Carotenoid Reflectance Index 1) – stanovanie odrazivosti, ktorá je citlivá na karotenoidové pigmenty v listoch rastlín. Odhad obsahu karotenoidov v listoch z odrazivosti je oveľa ťažší ako odhad chlorofylu z dôvodu prekrývania sa medzi absorpčnými vrcholmi chlorofylu a karotenoidov a z dôvodu vyššej koncentrácie chlorofylu vo väčšine listov. Pri 510 nm je recipročná odrazivosť karotenoidov maximálna, ale túto hodnotu ovplyvňuje aj chlorofyl. Na odstránenie účinku chlorofylu sa používa recipročná odrazivosť pri 550 nm, ktorá je ovplyvňovaná len samotným chlorofylom. Vyššie hodnoty CRII znamenajú vyššiu koncentráciu karotenoidov v porovnaní s chlorofylom.

$$\mathbf{CRI1} = \frac{1}{\rho_{510}} - \frac{1}{\rho_{550}} \tag{8.14}$$

Hodnoty indexu sa pohybujú od 0 po viac ako 15, pričom zelená vegetácia nadobúda hodnoty medzi 1 až 12.

b) Index Odrazivosti Antokyanínov 1 ARII (Anthocyanin Reflectance Index 1) – stanovanie odrazivosti, ktorá je citlivá na antokyanín v listoch rastlín. Recipročná odrazivosť antokyanínu je najvyššia okolo 550 nm; avšak hodnota recipročnej odrazivosti pri 550 nm je tiež ovplyvnená chlorofylom. Recipročná odrazivosť pri 700 nm sa používa ako referenčná miera obsahu chlorofylu na odstránenie vplyvu chlorofylu z odrazivosti v 550 nm. Zvýšenie hodnoty ARII naznačuje zmeny v listoch prostredníctvom nového rastu vegetácie alebo jej odumieraniu.

$$\mathbf{ARI1} = \frac{1}{\rho_{550}} - \frac{1}{\rho_{700}} \tag{8.15}$$

8 Applications of RS – Land use/Land cover, Agriculture

Hodnoty indexu sa pohybujú od 0 po viac ako 0.2 pričom zelená vegetácia nadobúda hodnoty medzi 0.001 až 0.1.

8.3.2.6. Canopy Water Content

Vegetačné indexy obsahu vody vo vegetačnej pokrývke sú navrhnuté tak, aby poskytovali mieru množstva vody obsiahnutej vo vegetácii. Obsah vody je dôležitým ukazovateľom, pretože vyšší obsah vody často naznačuje zdravšiu vegetáciu, ktorá pravdepodobne porastie rýchlejšie a bude odolnejšia voči požiaru. Vegetačné indexy obsahu vody využívajú merania odrazivosti v blízkych infračervených a krátkovlnných infračervených oblastiach, aby sa využili známe absorpčné vlastnosti vody a hĺbka prieniku svetla v blízkej infračervenej oblasti pre stanovenie celkového obsahu vody vo vodnom stĺpci. V porovnaní s indexmi zelene sú indexy obsahu vody vo vegetačnej pokrývke schopné "vidiet" hlbšie do hrubej pokrývky a sú citlivejšie na tenké ako na hrubé tkanivá.

a) Vodný Index WBI (Water Band Index) – stanovenie odrazivosti, ktoré je citlivé na zmeny v obsahu vody vo vegetačnej pokrývke. So zvyšujúcim sa obsahom vody vo vegetačných pokrývkach sa zvyšuje sila absorpcie okolo 970 nm v porovnaní s 900 nm. WBI sa využíva najmä pre analýzu stresu pokrývky, predikciu a modelovanie produktivity, analýzu nebezpečenstva požiaru, manažment ornej pôdy a štúdie fyziológie ekosystémov.

$$\mathbf{WBI} = \frac{\rho_{900}}{\rho_{970}} \tag{8.16}$$

Zelená vegetácia nadobúda hodnoty medzi 0.8 až 1.2.

b) Normalizovaný Diferenčný Infračervený Index NDII (Normalized Difference Infrared Index) – stanovenie odrazivosti, ktorá je citlivá na zmeny obsahu vody v korunách rastlín. NDII používa normalizovanú diferenciu namiesto jednoduchého pomeru a hodnoty indexu sa zvyšujú so zvyšujúcim sa obsahom vody. Aplikácie zahŕňajú manažment poľnohospodárskych plodín, monitorovanie lesnej vegetácie a detekciu stresovanej vegetácie.

$$\mathbf{NDII} = \frac{\rho_{819} - \rho_{1649}}{\rho_{819} + \rho_{1649}} \tag{8.17}$$

Hodnoty indexu sa pohybujú v intervale <-1; 1>, pričom zelená vegetácia nadobúda hodnoty medzi 0.02 až 0.6.

Prehľadný zoznam a popis indexov podľa aplikácie/typu senzora je možné nájsť na web adrese:

https://www.indexdatabase.de/

Okrem uvedených vegetačných indexov poznáme aj viacero doplňujúcich indikátorov pomocou ktorých je možné hodnotiť priebeh vegetačného obdobia. Patrí tu napríklad teplota, vlhkosť povrchu zeme, alebo produkcia suchej hmoty:

Produkcia suchej hmoty DMP (*Dry Matter Productivity*) – uvádza sa v kg suchej hmoty/ha/deň a vyjadruje nárast suchej hmoty biomasy za deň:

$$\mathbf{DMP} = R * 0.48 * fAPAR * \varepsilon(T_1) * 10\ 000 , \qquad (8.18)$$

pričom:

 R [J/m²/deň] predstavuje dopadajúcu krátkovlnnú slnečnú radiáciu, z ktorej priemerne 48% tvorí fotosynteticky aktívna radiácia PAR;

- fAPAR je súčasťou PAR, ktorú absorbuje zelená vegetácia;
- $\varepsilon(T_1)$ [kg suchej hmoty/ J_{PAR}] je koeficient efektívnosti, vyjadrujúci konverziu absorbovanej energie do biomasy a straty spôsobené transportom produktov fotosyntézy;
- konštanta 10 000 [m²/ha] transformuje metre štvorcové na hektáre.

8.3.3. Identification of production zones from RS data

Okrem aktuálneho hodnotenia stavu vegetácie a plodín je tiež možné využiť satelitné multispektrálne dáta pre stanovenie dlhodobých trendov nevyrovnanosti pozemkov, tzv. produkčné zóny či mapy úrodového potenciálu (Obr. 8.17). Na rozdiel od úrodových záznamov, multispektrálne snímky neprinášajú informáciu o dosiahnutej úrode, ale identifikujú rozdiely v rozložení relatívnej úrody na základe hodnotenia stavu vegetácie spektrálnym meraním – vegetačnými indexami. Stanovenie vychádza z analýzy viacročného radu (min. 5 až 10 rokov) vegetačných indexov vypočítaných z multispektrálnych satelitných snímok z druhej polovice vegetačného obdobia s vyfiltrovanou oblačnosťou a ďalšími nežiadúcimi javmi.

Cieľom je vyhodnotiť heterogenitu pozemkov za sledované obdobie a identifikovať nadpriemerne či podpriemerne úrodné plochy, vrátane percentuálneho vyhodnotenia rozdielu voči priemernej hodnote dosiahnutej úrody plodiny. Takto spracované úrodové zóny môžu byť významným zdrojom pre popis plošnej variability pozemkov v precíznom poľnohospodárstve a ako už bolo povedané v úvodnej kapitole, slúžia ako podklad pre diferenciáciu pestovateľských zásahov. Znázorňujú aj ekonomickú efektivitu pestovania, kalkuláciu bilancie živín podľa úrovne odberu živín odvezenou produkciou v jednotlivých častiach pozemkov, či úpravu užívania pozemkov úpravou hraníc podľa produkčných zón.



Obr. 8.17 Príklad mapy produkčných zón členených po 5 % (úrodového potenciálu) zo satelitných dát.

Fig. 8.17 Example map of production zones (yield potential) from satellite data divided by 5%. Source: nasepole.sk

8.4. Radar Remote Sensing in Agriculture

Vzhľadom na vlastnosti radarového DPZ a jeho výhody oproti optickému DPZ má SAR DPZ značný potenciál v oblasti poľnohospodárstva a mapovania plodín. Veľké množstvo a rozdielne charakteristiky súčasných (ale aj minulých) SAR senzorov (Seasat, ERS-1/2, JERS-1, RADARSAT-1,2, ENVISAT/ASAR, SIR-C/X-SAR, ALOS/PALSAR, Sentinel-1, TerraSAR-X, Cosmo-SkyMed, a iné) nám umožňujú získať široké spektrum podrobných informácií. SAR teda zohráva dôležitú úlohu v oblasti poľnohospodárskeho DPZ, pretože v súčasnosti je na výber viac zdrojov údajov ako kedykoľvek predtým. Okrem toho, s rozvojom ľahkých a malých systémov SAR použiteľných aj ako UAV, má aplikácia SAR v poľnohospodárstve v budúcnosti veľký potenciál.

V posledných rokoch bolo navrhnutých viacero nových polarizačných parametrov, metód dekompozície, modelov spätného rozptylu signálu pre vegetáciu, a podobne. Pomocou nových techník sa neustále zlepšuje presnosť identifikácie plodín, extrakcia parametrov plodín/pôdy, resp. odhady výnosov plodín.

8.4.1. Identification and mapping of areas for crop production

Identifikácia plodín a mapovanie oblastí pre pestovanie plodín sú základnými aplikáciami SAR DPZ v poľnohospodárstve. Mapovanie rozmiestnenia plodín je nevyhnutné pre mnohé aplikácie, ako je odhad parametrov a predpovedanie výnosov plodín, ako aj analýza rizika sucha, povodní a chorôb. Preto sa včasné a presné monitorovanie priestorových distribúcií druhov plodín a ich rozsahu považuje za najdôležitejšie aplikácie v poľnohospodárskom DPZ. S rýchlym vývojom systémov SAR sú v súčasnosti prístupné radarové dáta s vysokým priestorovým a temporálnym rozlíšením a multipolarizáciou, čo urýchľuje a spresňuje identifikáciu mapovanie oblastí plodín.

Údaje SAR majú značný potenciál na použitie pri identifikácii a mapovaní druhov plodín vďaka dostupnosti niekoľkých vysokokvalitných zdrojov údajov SAR.

8.4.1.1. Crop identification using SAR Remote Sensing

Spätný rozptyl SAR signálu od plodín je ovplyvnený štruktúrou biomasy, stavom pôdy, drsnosťou povrchu a konfiguráciou senzorov (frekvencia, polarizácia a uhol dopadu). Plodiny so štruktúrami, ktoré sa menia počas vegetačného obdobia, majú rôzne reakcie rozptylu pre rôzne polarizácie a rôzne frekvencie. Presnosť identifikácie plodín sa v princípe zlepšuje pri použití viacerých polarizácií, pričom najvýznamnejšou charakteristikou pri identifikácii plodín je časová variácia v rámci fenológie plodín. Viaceré vedecké štúdie zistili, že lepšie výsledky pri identifikácii plodín a monitorovaní rastu plodín sa dosahujú pri použití multi-temporálnych, multi-polarizačných a viac-frekvenčných snímok SAR. Vo všeobecnosti sa pre identifikáciu plodín v zmysle ich fenologických variácií sa používajú multi-polarimetrické údaje SAR s vysokým temporálnym rozlíšením.

Využitie rôznych kombinácií SAR polarizácie/frekvencie

Spätný rozptyl radarového signálu od plodín je citlivý na štruktúru porastu a stav podkladovej pôdy. Spätný rozptyl sa mení s režimami polarizácie a vlnovými dĺžkami, pričom SAR signály s rôznymi vlnovými dĺžkami majú rôzne penetračné schopnosti. Plodiny s vyššou biomasou môžu byť dobre klasifikované pomocou údajov v L-pásme, plodiny s nižšou biomasou môžu byť zase dobre klasifikované pomocou údajov v Cpásme. Rozdiely medzi výsledkami HH- a VV-polarizácie nie sú také výrazné. Avšak účinnosť rôznych polarizácií sa medzi jednotlivými typmi plodín líši. Rôzne vedecké práce hodnotili klasifikačnú účinnosť údajov SAR plne polarimetrických, duálne polarizovaných a s jednou polarizáciou, s C-, L- a P-pásmami na klasifikáciu 9 typov plodín a dospeli k záveru, že plne polarimetrický režim fungoval najlepšie pre C- a L-pásma. Taktiež bolo zistené, že spojenie informácií o spätnom rozptyle z krížovo-polarizovaných dát s jednou ko-polárnou informáciou zvýšilo presnosť klasifikácie z 55 na 85 %. Spojenie fázových informácií s ko-polárnymi informáciami zase zvyšuje presnosť klasifikácie plodín v menšom rozsahu. Uvádza sa, že polarizácia HH bola najpresnejšia pre identifikáciu ďateliny a polarizácia HV bola najpresnejšia pre identifikáciu kukurice a pšenice. Platí tiež, že polarizácia VV lepšie rozlišuje typy plodín ako polarizácia VH. Príklad využitia rôznych pásiem a rôznych polarizácií je znázornený na Obr. 8.18 a Obr. 8.19.



Obr. 8.18 Porovnanie C a L SAR pásiem a výstupov z nich pre monitorovanie nadzemnej biomasy. **Fig. 8.18** Comparison of C and L SAR bands and their outputs for monitoring aboveground biomass. Source: Mohan et al., 2011



Obr. 8.19 Porovnanie rôznych SAR polarizácií pre monitorovanie typov plodín. **Fig. 8.19** Comparison of different SAR polarizations for monitoring crop types. Source: Mohan et al., 2011
8 Applications of RS – Land use/Land cover, Agriculture

Využitie multi-temporálnych SAR dát

Potenciál koeficientov spätného rozptylu odvodených z multi-temporálnych údajov SAR na identifikáciu typov plodín bol preukázaný viacerými vedeckými štúdiami a praktickými aplikáciami. Časovú variáciu spätného rozptylu SAR možno považovať za veľmi unikátnu charakteristiku monitorovania plodín. Ukázalo sa, že aplikovanie multipolarizačných a multi-temporálnych údajov jednoznačne zlepšilo klasifikáciu plodín. Preto časová variácia spätného rozptylu SAR robí údaje SAR cennými pre mapovanie plodín a monitorovanie stavu plodín. Množstvo štúdií odhalilo, že údaje SAR v časových radoch poskytujú presnejšie výsledky ako výsledky získané z jedného časového súboru údajov (Obr. 8.20). Pri analýze multi-temporálnych SAR údajov pre posúdenie výkonnosti rôznych režimov polarizácie (jednoduchej, duálnej a plnej polarizácie) na klasifikáciu plodín bolo zistené, že režimy s dvojitou a plnou polarizáciou boli lepšie ako režim s jednou polarizáciou, pričom najlepšie celkové výsledky sa dosiahli pri použití multitemporálnych dát. V posledných rokoch bol taktiež vyvinutý prístup multi-temporálneho filtrovania na zníženie šumu v SAR dátach a výsledok ukázal, že presnosť klasifikácie bola takmer 90 % alebo presahovala 90 % pre každú z jednotlivých tried. Zároveň platí, že parametre multi-temporálneho polarimetrického rozkladu poskytujú presnejšie výsledky ako lineárne polarizácie.



Obr. 8.20 Príklad multi-temporálnej RGB kompozície Sentinel-1 s VH polarizáciou pre klasifikáciu plodín.

Fig. 8.20 Example of Sentinel-1 multi-temporal RGB composition in VH polarization for crop classification.

Source: Tomppo et al., 2019

8.4.1.2. Crop identification and mapping using a combination of SAR and optical RS

Šum prítomný v SAR dátach môže sťažiť interpretáciu týchto dát a tým ovplyvniť presnosť klasifikácie plodín. Dáta z optických senzorov môžu túto nevýhodu eliminovať a zlepšiť presnosť identifikácie. Viaceré vedecké práce už preukázali, že integrované používanie optických údajov a údajov SAR môže výrazne zlepšiť presnosť klasifikácie. Napríklad integrácia údajov RapidEye a TerraSAR-X zlepšila presnosť klasifikácie o 10–15 % v porovnaní s použitím samotných optických údajov RapidEye. Ďalším príkladom je kombinácia údajov časových radov Landsat 8 a X-pásma COSMOSkyMed pre identifikáciu 7 druhov plodín počas ich príslušných ročných období s dosiahnutou celkovou presnosťou vyššou ako 86%. Celkovo je možné povedať, že spoločné použitie SAR a optických údajov prináša lepšie výsledky ako použitie samotných optických údajov (Obr. 8.21).



Obr. 8.21 Klasifikácia a mapovanie plodín; a) časove rady pre vegetačné indexy zo Sentinel-2 a pre polarizácie Sentinel-1; b) NDVI pre optickú snímku Sentinel-2; c) Typy plodín extrahované z dát S1 a S2 na základe strojového učenia.

Fig. 8.21 Crop classification and mapping; a) time series for vegetation indices from Sentinel-2 and for Sentinel-1 polarizations; b) NDVI for Sentinel-2 optical imagery; c) Crop types extracted from S1 and S2 data based on machine learning.

Source: ©Beatrice Gottardi, ESA. Contains modified Copernicus Sentinel data (2019)

Na identifikáciu plodín pomocou SAR sa dá použiť viacero klasifikačných prístupov. Tieto metódy sú rozdelené do dvoch kategórií: metódy založené na pixeloch a objektovo orientované metódy. Väčšina štúdií využíva metódy založené na pixeloch, ako sú Support Vector Machine, rozhodovací strom, maximálna pravdepodobnosť, neurónové siete a Random Forrest. Metódy založené na pixeloch klasifikujú každý pixel jednotlivo a výsledné mapy často obsahujú výraznejší šum v dôsledku koherentnej povahy snímok SAR. Tieto metódy preto často vedú k nízkej presnosti klasifikácie. Objektovo orientovaná klasifikácia, ktorá najprv spája pixely do objektov a potom klasifikuje každý objekt, však môže tento šum znížiť. Vo všeobecnosti môžu byť objektovo orientované klasifikácie vhodnejšie pri klasifikácii SAR údajov.

8.4.2. Crop and cropland parameters

Časopriestorové monitorovanie a hodnotenie druhov plodín ako potravinových zdrojov má zásadný význam v sociálno-ekonomických otázkach spoločnosti a je nevyhnutné pre udržateľné riadenie poľnohospodárskych činností. Rozhodovacie orgány tak môžu mať k dispozícii presné a aktuálne informácie týkajúce sa riadenia plodín, plánovania poľnohospodárskej výroby, podpory stability potravinovej bezpečnosti, trhu s plodinami atd. Okrem toho poľnohospodári tiež profitujú zo získavania včasných informácií o raste plodín, ako aj z odhadu výnosov. Vlastnosti radarových techník DPZ a možnosti technológie SAR presvedčili výskumníkov a vládnych úradníkov, aby ju uplatňovali ako široko používaný, praktický a účinný nástroj v takýchto aplikáciách. Systém SAR je citlivý na biofyzikálne premenné vegetácie a dynamické charakteristiky rastlinných objektov a základné pôdne parametre, ako je obsah vody v rastlinách, geometrické vlastnosti, vychýlenie a nepravidelnosť, drsnosť a vlhkosť povrchu pôdy. Ka, Ku, X, C a L sú rôzne viacfrekvenčné konfigurácie získavania údajov SAR týkajúce sa skúmania biofyzikálnych premenných plodín. Pásma Ka, Ku a X majú vysoké frekvencie a krátke vlnové dĺžky v porovnaní s pásmami C a L. Dlhšia vlnová dĺžka môže preniknúť do koruny plodín viac ako kratšia vlnová dĺžka, a preto je menej ovplyvnená pôdou. CVäčšie dĺžky, ako napríklad L-pásmo (~24 cm), môžu prenikať do podpovrchovej vrstvy, čo má za následok vyšší príspevok rozptylu pôdy, zatiaľ čo kratšie vlnové dĺžky, ako napríklad X-pásmo (~3 cm) a C-pásmo (~6 cm), interagujú najmä s hornou časťou vegetácie. Preto polarimetrický SAR DPZ využívajúci C-pásmo má vysoký potenciál na odhad biomasy a rozsahu plodín.

Viaceré štúdie preukázali citlivosť polarimetrického SAR na premenné týkajúce sa monitorovania plodín, ako je Index Listovej Plochy LAI (Leaf Area Index) a rozsah biomasy. Spracovanie a analýza indexov radarových signálov pri rôznych vlnových dĺžkach, frekvenciách, uhloch dopadu a polarizácii patrí medzi techniky používané pri štúdiách biofyzikálnych charakteristík plodín. Aby sa maximalizovala citlivosť senzorov SAR na monitorovanie rastového cyklu kukurice a zmiernenie vplyvu pôdnej vlhkosti na signál a časové rady SAR, bol vyvinutý model simulácie signálu vo všetkých možných konfiguráciách (polarizácia a uhly dopadu v C-pásme) pre snímky ENVISAT, RADARSAT a ERS a bolo zistené, že indexy duálnej polarizácie sú citlivejšie na rast kukurice a menej citlivé na kolísanie pôdnej vlhkosti. Vzájomné interakcie medzi konfiguráciou radaru (frekvencia, vlnová dĺžka, polarita a uhol dopadu), ako aj ich interakcia s premennými rastlín, spôsobili, že používanie a interpretácia radarových údajov je užitočná, ale komplikovaná. V poľnohospodárskych štúdiách by sa mali zámerne skúmať radarové parametre, ktoré ovplyvňujú rozptyl signálu a cieľové parametre, ktoré ovplyvňujú šírenie signálu. Cieľové parametre závisia hlavne od dielektrickej konštanty a geometrických vlastností. Dielektrická konštanta úzko súvisí s objemom vody v rastline, pričom tvar, veľkosť a orientácia listov, stoniek a plodov sú relevantné pre geometrické vlastnosti.

Medzi dve hlavné monitorované premenné patrí výška plodín a rozsah plodín. Aby bolo možné identifikovať stav plodiny a predpovedať jej účinnosť, je potrebné prepojiť každú z variácií (fenologické zmeny) s podmienkami pestovania plodín (výška a rozsah) aplikovaním mechanizmov a parametrov spätného rozptylu. Výška plodiny úzko súvisí s biomasou plodín a rastovými štádiami a je dôležitou premennou pre pozorovanie vývoja plodín, identifikáciu plodín a odhad výnosov. Rozsah plodín sa používa na odhad oblasti vplyvu plodiny a definuje sa ako percento pevnej plochy pokrytej pokrývkou jednotlivého rastlinného druhu k holej pôde na jednotkovej ploche. Celkový rozsah plodiny môže dosiahnuť sto percent (úplne pokrytý), nakoľko rastliny sa môžu prekrývať.

8.4.2.1. SAR Backscatter

Viaceré štúdie o spracovaní radarových údajov naznačujú, že fenologické štádiá rastliny majú vplyv na spätný rozptyl signálu a existuje významná korelácia medzi biofyzikálnymi parametrami rastlín, vrátane výšky, indexu listovej plochy, vegetačnej hmoty, obsahu vody v rastline a spätným rozptylom radarového signálu. Spätný rozptyl z vegetácie je funkciou polarizácie vlnových dĺžok a frekvencie. Rôzne frekvencie a polarizácie umožňujú odvodiť rôzne a doplnkové informácie z jedného objektu. V poľnohospodárskych aplikáciách kombinácia polarizácií (ko-polarizácia a krížová polarizácia) umožňuje analytikovi extrahovať ďalšie informácie o charakteristikách plodín. Polarizácia spätného rozptylu indikuje cieľové štrukturálne vlastnosti a vizualizuje rozptylové charakteristiky pozorovaných prvkov. Väčšina vesmírnych radarových systémov často vysiela iba jednu polarizáciu a prijíma obe polarizácie, čo vedie k vzniku duálnych polarimetrických údajov SAR (napr. Sentinel-1 s polarizáciou VH a VV), zatiaľ čo niektoré poskytujú tzv. štvor-polarizáciu (HH, VV, HV a VH) snímky (napr. PALSAR, TerraSAR-X a RADARSAT-2).

Technika Polarimetrického SAR (PolSAR) viedla k viacerým výskumom a zlepšeniam v oblasti monitorovania rastu plodín, odhadu výnosov, predpovedania a prevencie katastrof s plodinami a vo všeobecnosti poskytuje presné informácie pre presné poľnohospodárstvo.

V SAR monitorovaní v poľnohospodárstve sa používa aj alternatíva k optickému DPZ a indexu NDVI. Pre monitorovanie úrovne rastu vegetácie v rámci analýzy časových radov sa používa **Radarový Vegetačný Index RVI** (*Radar Vegetation Index*):

$$\mathbf{RVI} = \frac{8 * \sigma_{HV}^0}{\sigma_{HH}^0 + \sigma_{VV}^0 + 2 * \sigma_{HV}^0}$$
(8.19)

V rozsahu od 0 do 1 sa RVI používa na meranie náhodnosti rozptylu v mikrovlnnom signáli. Blíži sa k 0 pre hladký holý povrch, a ako vegetácia rastie tak sa jeho hodnota zvyšuje, kým plodina nedosiahne koniec rastového cyklu a je ovplyvnená obsahom vody vo vegetácii. Klasický výpočet RVI vyžaduje štvor-polarizáciu (HH, VV, HV a VH) SAR dát.

Pre SAR dáta poskytujúce duálnu polarizáciu dát sa používa modifikovaný index RVI, upravený na základe predpokladu :

$$\mathbf{RVI} = \frac{4 * \sigma_{VH}^0}{\sigma_{VV}^0 + \sigma_{VH}^0}$$
(8.20)

Príklad vývoja RVI pre mapovanie stavu plodín na základe snímok Sentinel-1 GRD je znázornený na Obr. 8.22. Na ďalšom obrázku Obr. 8.23 je zobrazené využitie kombinácie NDVI zo snímok Sentinel-2 a RVI zo snímok Sentinel-1 pre odhad podielu vegetačného krytu.





Obr. 8.22 Časová séria RVI pre mapovanie stavu plodín pomocou Sentinel-1. **Fig. 8.22** RVI time series for crop condition monitoring. Source: custom-scripts.sentinel-hub.com/custom-scripts/sentinel-1/radar_vegetation_index



Obr. 8.23 Integrácia NDVI z Sentinel-2 a RVI z Sentinel-1 pre stanovenie podielu vegetačného krytu.

Fig. 8.23 Integration of NDVI from Sentinel-2 and RVI from Sentinel-1 to determine the proportion of vegetation cover.

Source: Agapiou, 2020

8.4.3. Sentinel-1 Interferometric Coherence for Vegetation and Mapping (SINCOHMAP)

SINCOHMAP bol projekt ESA s cieľom vyvinúť, analyzovať a overiť nové metodológie pre mapovanie krajinnej pokrývky a vegetácie pomocou Sentinel-1 Interferometric Coherence Evolution (Obr. 8.24). Jedným z hlavných cieľov projektu bolo kvantifikovať vplyv pri používaní údajov S-1 InSAR v porovnaní s tradičným mapovaním krajinnej pokrývky a vegetácie pomocou optických údajov (najmä Sentinel-2) resp. prístupy založené na SAR.



Obr. 8.24 Vývoj interferometrickej koherencie pre po sebe nasledujúce interferometrické páry 6, 12 a 18 dní - Doñana (Španielsko).

Fig. 8.24 Evolution of interferometric coherence for successive interferometric pairs of 6, 12 and 18 days - Doñana (Spain).

Source: www.sincohmap.org

Medzi hlavné výstupy tohto projektu patria:

- 1. InSAR coherence fingerprint metodika prispôsobená na využitie vývoja koherencie,
- 2. Prístup strojového učenia na úrovni pixelov pomocou Sentinel-1 a Sentinel-2,
- 3. Prístup strojového učenia na objektovej úrovni pomocou Sentinel-1 a Sentinel-2,
- 4. Alternatívne stratégie.

Využívajú sa dva typy údajov:

Komplexný korelačný koeficient – medzi dvomi komplexnými snímkami SAR SI a S2, predstavuje normalizovanú koreláciu medzi týmito dvomi SAR snímkami. V prípade interferometrie SAR je komplexný korelačný koeficient určený rôznymi fyzikálnymi javmi tak, že jeho konečnú hodnotu možno rozložiť ako súbor multiplikatívnych faktorov.

Multi-temporálna kovariančná matica – vzhľadom na časový rad *N* snímok SAR S_1 , S_2 , ..., S_N je možné definovať časovú kovariančnú maticu pre celý súbor interferometrických snímok. Táto matica obsahuje rádiometrické informácie na hlavnej

diagonále a interferometrické informácie na zvyšných miestach. Práve tieto členy mimo hlavnej diagonály obsahujú informácie o koherencii dvoch snímok SAR. Príklad takýchto údajov je znázornený na Obr. 8.25.



Obr. 8.25 Príklad temporálnych kovariančných matíc pre oblasť Doñana (Španielsko). **Fig. 8.25** Example of temporal covariance matrices - Doñana (Spain). Source: www.sincohmap.org/coherence

Pre riešenie tohto projektu boli zvolené 4 rôzne referenčné testovacie oblasti s veľmi presnými referenčnými údajmi na vykonávanie kvantitatívneho hodnotenia a validácie:

- 1. *Doñana* (*Španielsko*) špecifická testovacia lokalita pre poľnohospodárstvo a súvisiace druhy pôdy v blízkosti Sevilly v juhozápadnej časti Španielska; obsahuje tri rôzne lokality zaujímavé pre tento projekt: mokrade, ryžové polia, iné plodiny;
- 2. *Južné Tirolsko (Taliansko) -* 44 % územia Južného Tirolska pokrývajú lesy, ktoré sú dôležité z hospodárskeho hľadiska;
- Západné Veľkopoľsko (Poľsko) nachádza sa v západnej časti Poľska, v jednom z najintenzívnejších poľnohospodárskych regiónov krajiny, ktorý veľmi často trpí suchom. Oblasť obsahuje tri lokality, ktoré predstavujú rôzne typy krajinnej pokrývky: poľnohospodárska lokalita, mestská lokalita, lesná lokalita;
- 4. *Sondakylä* (*Fínsko*) lokalita v severnom Fínsku; na hodnotenie odvodených metodík v boreálnych lesných porastoch. Na analýzu zasneženej pôdy sa tu vyskytujú dva hlavné typy pôdnej pokrývky: boreálny les a rašeliniská/močiare.

Pre tieto oblasti existujú súčasné aj historické súbory údajov; pričom počas projektu boli realizované aj terénne merania, aby sa zabezpečila správna validácia dát. Navrhované oblasti boli komplementárne a pokrývali základné triedy (t. j. plodiny, les a mestské prostredie) s rôznymi podmienkami prostredia.

Pre získavanie dát boli definované dve obdobia akvizície snímok Sentinel-1:

- 2015-2016: predbežná analýza a tréningové dáta,
- 2017-2018: hodnotiaca fáza, testovanie výkonnosti navrhovaného spracovania, a rozšírenie vyvinutých postupov a metodík.

8 Applications of RS – Land use/Land cover, Agriculture

8.4.3.1. Results of SINCOHMAP project

Klasifikácia krajinnej pokrývky - Počas hodnotiacej a posudzovacej fázy projektu sa hodnotili a porovnávali alternatívne metodiky klasifikácie krajinnej pokrývky s využitím funkcie multitemporálnej interferometrickej koherencie. Identifikovali sa potenciálne silné stránky, ďalšie možnosti, a slabé stránky interferometrickej koherencie na klasifikáciu pôdnej pokrývky. Výsledky klasifikácie (Obr. 8.26) využívajú dekompozíciu vlastných hodnôt Multibaseline interferometrickej koherencie a algoritmus Random Forest.



Obr. 8.26 Výsledky klasifikácie krajinnej pokrývky pre oblasť Južného Tirolsko (Taliansko). **Fig. 8.26** Land cover classification results for the South Tyrol region (Italy). Source: www.sincohmap.org/results

Porovnanie interferometrických prvkov

Sentinel-1 umožňuje vytvárať dátové zásobníky pre InSAR dáta viacerými spôsobmi s využitím veľmi nízkeho temporálneho rozlíšenia (až 6 dní opakovaného prechodu pomocou S-1 A a B) a polarimetrických možností (ko- a krížové polarizácie získané v štandardnom režime). V rámci projektu sa analyzoval vplyv týchto alternatívnych možností a funkcií na klasifikáciu.

Polarimetria - senzory Sentinel-1 A/B umožňujú zachytávať polarimetrické údaje v ko-polarizácii a krížovej polarizácii. V predvolenom režime sa tieto údaje získavajú s vertikálne (V) polarizovanou vlnou a získavajú sa vertikálne (VV, ko-polarizované) aj horizontálne (VH, krížovo-polárizované) dáta. Vplyv na klasifikačný výkon pri zohľadnení prvého, druhého alebo oboch kanálov súčasne je znázornený na nasledujúcom obrázku (Obr. 8.27).



Obr. 8.27 Výsledky klasifikácie pôdnej pokrývky, pri ktorých sa berú do úvahy polarimetrické kanály VV, VH a duálne polarimetrické prvky VV+VH - Doñana (Španielsko). **Fig. 8.27** Results of land cover classification considering polarimetric channels VV, VH and dual polarimetric elements VV+VH - Doñana (Spain). Source: www.sincohmap.org/results

Časová základnica - Sentinel-1 sa skladá z dvojičiek satelitov S-1 A a B, pričom každý z nich má nominálny čas opakovaného preletu 12 dní. V určitých oblastiach sveta, väčšinou v Európe, sa temporálne rozlíšenie znižuje na 6 dní, pričom oba systémy pracujú sekvenčne, t. j. získava sa záznam s interferometrickými schopnosťami. Porovnanie vplyvu klasifikácie pri posudzovaní pravidelného S-1 A/A alebo B/B s 12-dňovou frekvenciou v porovnaní s A/B alebo B/A so 6-dňovou frekvenciou je znázornené na Obr. 8.28.



Obr. 8.28 Výsledky klasifikácie krajinnej pokrývky vzhľadom na 12-dňové a 6-dňové interferometrické koherenčné páry počas celej sezóny – Doñana (Španielsko). **Fig. 8.28** Land cover classification results according to 12-day and 6-day interferometric coherence pairs throughout the season - Doñana (Spain). Source: www.sincohmap.org/results

Intenzita SAR vs. koherencia InSAR - povaha produktov SAR umožňuje pri práci s jednotlivými údajmi SAR využívať priamo len intenzitu údajov a v kontexte mapovania sa bežne používa. V tomto rámci sa vyhodnotil aj príspevok interferometrie, t. j. interferometrickej koherencie, v porovnaní s využitím intenzity SAR, ale aj v kombinácii s ňou (Obr. 8.29).



Obr. 8.29 Výsledky klasifikácie pôdnej pokrývky počas celého obdobia zohľadňujúce (hore) len údaje o intenzite, a (dole) kombináciu údajov o intenzite a interferometrickej koherencii – Doñana (Španielsko).

Fig. 8.29 Results of land cover classification over the whole period considering (top) intensity data only, and (bottom) a combination of intensity and interferometric coherence data - Doñana (Spain).

Source: www.sincohmap.org/results

Výsledky v širšej oblasti – výsledky klasifikácie pôdnej pokrývky na základe interferometrických koherenčných údajov počas celej sezóny v regionálnej mierke. Biely rámček na Obr. 30 označuje oblasť pre tréningové dáta (1 % vzoriek), test a validáciu.

8 Applications of RS – Land use/Land cover, Agriculture



Obr. 8.30 Výsledky klasifikácie pôdnej pokrývky počas celého obdobia pre väčšiu, regionálnu oblasť – Doñana (Španielsko). **Fig. 8.30** Results of land cover classification over the whole period for a larger, regional area -Doñana (Spain). Source: www.sincohmap.org/results

Výsledky mapovania typov plodín

V rámci projektu sa osobitná pozornosť venovala pestovateľským oblastiam, ako je oblasť nachádzajúca sa na juhu testovacej lokality Doñana. Na Obr. 8.31 je možné pozorovať vnútornú dynamiku prítomnú v interferometrickej koherencii tejto kultivovanej oblasti na juhozápade Španielska, ktorá pochádza priamo z multitemporálnej kovariančnej matice. Hlavná uhlopriečka zodpovedá 6-dňovej časovej základnej interferometrickej koherencii, ďalšia uhlopriečka 12-dňovej, 18-dňovej, 24dňovej a 30-dňovej.



Obr. 8.31 Vplyv multitemporálnej interferometrickej koherencie na mapovanie typov plodín – Doñana (Španielsko).

Fig. 8.31 Effect of multitemporal interferometric coherence on crop type mapping - Doñana (Spain).

Source: www.sincohmap.org/results

Pre analýzu a validáciu dát boli použité referenčné dáta o pôde na pozemkoch poskytnuté regionálnymi úradmi. Na základe získaných výsledkov sa preukázalo, že interferometrická koherencia predstavuje cennú vlastnosť na vytváranie automatických tematických máp typov plodín (Obr. 8.32). Celkovo sa dosiahla dobrá presnosť klasifikácie. Najlepšie výsledky sa dosiahli pri najkratšej časovej základnici (6 dní) a presnosť postupne klesá, keď sa zohľadňuje viac časových informácií (12 a 18 dní), keďže časová dekorelácia vyvoláva skreslenie klasifikácie.



Obr. 8.32 Výsledné tematické mapy plodín pre rôzne časové základnice – Doñana (Španielsko). **Fig. 8.32** Resulting thematic crop maps for different multi-temporal baselines - Doñana (Spain). Source: www.sincohmap.org/results

8.5. Applications of RS in Agriculture using ESA missions

V rámci spolupráce s ESA bolo realizovaných viacero národných ale aj globálnych, resp. celoeurópskych projektov využívajúcich dáta zo satelitných misií ESA. Tie najznámejšie sú zahrnuté v nasledovnej časti.

8.5.1. Sentinel-2 for Agriculture (Sen2-Agri)

Satelitná misia Sentinel-2 predstavuje jedinečnú príležitosť pre monitorovanie poľnohospodárstva od regionálnej až po globálnu úroveň vzhľadom na jej priestorové rozlíšenie 10-20 m, 5-dňovú frekvenciu opakovaných preletov nad územím, globálne pokrytie, a kompatibilitu s misiami Landsat.

V tejto súvislosti spustila ESA projekt Sentinel-2 pre poľnohospodárstvo (*Sen2-Agri*) ako hlavný príspevok k zložkám výskumu a vývoja a budovania národných kapacít v rámci rôznych iniciatív v oblasti poľnohospodárstva.

Projekt *Sen2-Agri* je navrhnutý tak aby vyvinul, demonštroval a uľahčil prínos časových radov zo snímok misie Sentinel-2 k monitorovaniu poľnohospodárstva. Projekt ukazuje prínos misie Sentinel-2 pre oblasť poľnohospodárstva naprieč celým radom rôznych typov plodín a poľnohospodárskych postupov.

Cieľom projektu je poskytnúť overené algoritmy, otvorený zdrojový kód a osvedčené postupy na spracovanie údajov Sentinel-2 snímok pre hlavné celosvetové reprezentatívne poľnohospodárske systémy distribuované po celom svete.

Systém *Sen2-Agri* je softvérové riešenie spracovávajúce satelitné snímky pre poľnohospodárske účely z časových radov Sentinel-2 (A&B) a Landsat 8 počas vegetačného obdobia. Jeho produkty pozostávajú z:

- mesačné kompozity s odfiltrovanou oblačnosťou zobrazujúce odrazivosť zemského povrchu v rozlíšení 10 – 20 m;
- mesačné dynamické masky poľnohospodárskej pôdy;
- mapy jednotlivých druhov pestovaných plodín s rozlíšením 10 m pre hlavné skupiny plodín, dodané dvakrát počas poľnohospodárskej sezóny;
- periodické mapy stavu vegetácie, NDVI a LAI, popisujúce vegetatívny vývoj plodín vždy, keď je možné získať snímky bez oblačnosti.

Systém *Sen2-Agri* je bezplatný a otvorený nástroj, ktorý umožňuje každému používateľovi vytvárať produkty takmer v reálnom čase prispôsobené jeho potrebám, buď na vlastnom lokálnom hardvéri alebo pomocou cloud computingu. Pozostáva z troch základných zložiek – súbor nezávislých modulov spracovania, centrálny komponent riadiaci automatizované vykonávanie jednotlivých modulov, grafické používateľské rozhranie.

Projekt Sen2-Agri poskytuje 4 základné produkty:

Kompozit

Kompozit poskytuje bezoblačnú časovú syntézu hodnôt odrazivosti zemského povrchu v 10 pásmach snímky Sentinel-2 (Obr. 8.33). Dodáva sa s niekoľkými maskami pre posúdenie jeho kvality. Pre vybranú lokalitu je možné zvoliť obdobie kompozície od 30 do 50 dní. To poskytuje flexibilitu vzhľadom na miestne atmosférické podmienky a oblačnosť. Produkt je dodávaný na mesačnej báze, aby sa zabezpečilo správne monitorovanie pozorovaných oblastí.



Obr. 8.33 Príklad bezoblačného kompozitu povrchovej odrazivosti pre Ukrajinu v roku 2016 s rozlíšením 10m zo snímok Sentinel-2.

Fig. 8.33 Example of cloud free reflectance composite image over Ukraine at 10m resolution obtained from Sentinel-2A images of July 2016.

Source: http://www.esa-sen2agri.org/products/composite/

Maska ornej pôdy

Produkt dynamická maska ornej pôdy pozostáva z binárnej mapy oddeľujúcej plochy ročnej ornej pôdy od ostatných plôch, čím zodpovedá maske pre plochy s každoročne obrábanou pôdou.

Jednoročná orná pôda je definovaná ako časť pôdy s minimálnou rozlohou 0,25 ha, ktorá je skutočne osiata/osadená a ktorý je možné zozbierať aspoň raz v priebehu roka nasledujúceho po dátume osiatia. Táto binárna mapa sa vytvára počas poľnohospodárskej sezóny na mesačnej báze, aby slúžila napríklad ako maska na monitorovanie podmienok pestovania plodín, ako základ pre stratifikáciu vzoriek, a pre poľnohospodárske poradenstvo (Obr. 8.34). Očakáva sa, že jej presnosť sa bude zvyšovať, pokiaľ sa do procesu vývoja začlenia ďalšie snímky.



Obr. 8.34 Časová séria snímok Sentinel-2 nad Belgickom; a zodpovedajúca dynamická maska ornej pôdy počas 7 mesiacov v roku 2016.

Fig. 8.34 Time series of Sentinel-2 images over Belgium; corresponding dynamic cropland mask over 7 months in 2016.

Source: http://www.esa-sen2agri.org/products/cropland-mask/

Mapa druhov plodín

Produkt Mapa druhov plodín (Obr. 8.35) je mapa hlavných typov alebo skupín plodín v danom regióne s minimálnou mapovacou jednotkou 0,01 ha, ktorá sa poskytuje spolu s niekoľkými znakmi kvality.

V každom regióne sa zohľadňuje 5 hlavných typov plodín. Hlavné typy plodín sú definované ako tie, ktoré pokrývajú minimálne 5 % ročnej ornej pôdy v regióne a predstavujú kumulovanú plochu vyššiu ako 75 % tejto plochy.

Produkt je doplnený indikátorom plochy plodín v ranom štádiu, odhadom podielu typu plodín vo vnútri pixelu s rozlohou 1 km², ktorý sa zvyčajne odvodí štatisticky spoľahlivým prístupom.



Obr. 8.35 Časová séria snímok Sentinel-2 a Landsat 8 pre vytvorenie mapy druhov plodín v regióne Occitanie, Francúzsko.

Fig. 8.35 Time series of Sentinel-2 and Landsat 8 images to create a crop type map in the region Occitanie, France.

Source: http://www.esa-sen2agri.org/products/crop-type-map/

Stav vegetácie

Produkt Indikátory stavu vegetácie (Obr. 8.36) pozostáva z niekoľkých máp informujúcich o vývoji zelenej vegetácie zodpovedajúcej vegetačnému vývoju plodín.

Produktom je súbor 3 ukazovateľov:

- NDVI, ukazovateľ používaný na monitorovanie vegetácie;
- LAI, vnútorná primárna premenná pokrývky vegetácie;
- fenologické indexy, ktoré informujú o špecifických kľúčových parametroch vegetačného obdobia (dátum začiatku, dĺžka a dátum maximálnej rýchlosti rastu).



Obr. 8.36 Časová séria znázorňujúca index listovej plochy LAI, odvodená zo snímok Sentinel-2 na monitorovanie vývoja plodín v Sudáne v roku 2016. **Fig. 8.36** Time series of leaf area index derived from Sentinel-2 images to monitor the crop

Fig. 8.36 Time series of leaf area index derived from Sentinei-2 images to monitor the crop development in Sudan in 2016.

Source: http://www.esa-sen2agri.org/products/vegetation-status/

8.5.2. Sentinels for Common Agricultural Policy (Sen4CAP)

Cieľom projektu **Sentinels for Common Agricultural Policy** - *Sen4CAP* je poskytnúť európskym a vnútroštátnym zainteresovaným stranám v rámci CAP overené algoritmy, produkty, pracovné postupy a osvedčené postupy pre monitorovanie poľnohospodárstva, ktoré sú dôležité pre riadenie CAP. Projekt venuje osobitnú pozornosť poskytovaniu dôkazov o tom, ako môžu informácie odvodené zo snímok misií Sentinel podporiť modernizáciu a zjednodušenie CAP v období po roku 2020 (Obr. 8.37).

Celkový prístup navrhovaný pre projekt *Sen4CAP* je úplne orientovaný na používateľa, aby sa zabezpečilo reagovanie na veľmi konkrétne potreby a požiadavky používateľov. Do skupiny používateľov projektu *Sen4CAP* patria platobné agentúry (PA) zo 6 vybraných pilotných krajín, ako aj súbor používateľov patriacich do Konferencie riaditeľov PA EÚ, platformy Panta Rhei a skupiny expertov pre poľnohospodárstvo programu Copernicus. Projekt sa začal v júli 2017 a trval 30 mesiacov, pričom sa uskutočnil v dvoch rôznych fázach.

Hlavné ciele *Sen4CAP* sú:

- identifikovať a špecifikovať produkty a služby EO vhodné na zvýšenie efektívnosti, sledovateľnosti, ako aj zníženie nákladov IACS (Integrovaný administratívny a kontrolný systém),
- vypracovať dokumenty teoretických základov algoritmov spolu s otvoreným zdrojovým kódom pre poľnohospodárske produkty EO založené na Sentinel-1 a -2, ktoré budú reagovať na požiadavky používateľov,
- demonštrovať a overovať vyvinuté poľnohospodárske produkty pomocou EO,

- poskytnúť dôkazy o užitočnosti produktov Sentinel v rámci postupov IACS na úrovni EÚ a na vnútroštátnej úrovni pre celý rad národných a regionálnych platobných agentúr, ktoré sú reprezentatívne pre rôznorodé poľnohospodárske postupy, krajinu a klímu v EÚ, ako aj určiť súvisiace obmedzenia a podmienky použitia,
- pripraviť a uľahčiť prenos vyvinutých produktov a služieb EO do platobných agentúr vrátane budovania kapacít a demonštrácie možností cloud computingu.



Obr. 8.37 Vľavo - mapa typov plodín s rozlíšením 10 m na základe časovej rady Sentinel-1 a Sentinel-2 z roku 2017; vpravo – zodpovedajúci klasifikačný indikátor spoľahlivosti. **Fig. 8.37** Left- crop type map at a 10-m resolution based on Sentinel-1 and Sentinel-2 time series; right – corresponding classification confidence indicator. Source: http://esa-sen4cap.org/

8.5.3. ESA Climate Change Initiative Land_Cover project

(ESA CCI LC)

Je to kontinuálne pokračujúci projekt poskytujúci dáta o krajinnej pokrývke s rozlíšením 300 m. Dáta sú dostupné online od roku 2017 a bol vyvíjaný 9 rokov v rámci projektu **ESA Climate Change Initiative** (*CCI*). Poskytuje globálne ročné mapy krajinnej pokrývky od roku 1992 (Obr. 8.38).

Celkovým cieľom projektu *Land_Cover_CCI* bolo prehodnotiť všetky systémy a algoritmy potrebné na vytvorenie globálneho produktu o krajine, a následne navrhnúť a uviesť do praxe systém, ktorý by v priebehu času a z rôznych nástrojov EO poskytoval konzistentným spôsobom globálne informácie o krajine zodpovedajúce potrebám kľúčových používateľov patriacich do komunity zaoberajúcej sa zmenou klímy. Dôraz sa kládol na misie ESA a členských štátov, ktoré poskytujú takmer denné globálne dáta odrazivosti krajinnej pokrývky so stredným priestorovým rozlíšením (MERIS FR & RR,

SPOT VEGETATION), ale zároveň sa využil aj prínos senzorov ESA SAR pre špecifické problémy rozlišovania pôdnej pokrývky.

Všetky dátové produkty vytvorené v rámci tohto projektu sú súčasťou balíka klimatických výskumných údajov CCI Land Cover (Land Cover CCI Climate Research Data Package – CRDP):

- časový rad konzistentných globálnych máp krajinnej pokrývky s priestorovým rozlíšením 300 m na ročnom základe od roku 1992 do roku 2015;
- používateľský nástroj na nastavenie, premietanie a výber vzoriek produktov spôsobom, ktorý je vhodný pre každý klimatický model.
- úplný archív 7-dňových kompozitov 1 km povrchovej odrazivosti z rokov 1992 až 1999;
- kompletný archív 7-dňových kompozitov odrazu povrchu MERIS od roku 2003 do roku 2011 (rozlíšenie 300 m a 1 km);
- 1 km časový rad 7-dňových kompozitov povrchovej odrazivosti PROBA-V od polovice marca 2014 do konca roka 2015;
- 1 statická mapa otvorených vodných plôch vrátane údajov ENVISAT ASAR;
- 3 globálne produkty sezónnosti zemského povrchu charakterizujúce zelenosť vegetácie, dynamiku snehu a spálených plôch.



Obr. 8.38 Mapa ESA CCI Land Cover s rozlíšením 300 m z roku 2015. **Fig. 8.38** ESA CCI Land Cover map with resolution 300 m from 2015. Source: https://www.esa-landcover-cci.org/?q=node/175/

8.5.4. High Resolution (HR) Land Cover (LC) project

Projekt **High Resolution (HR) Land Cover (LC) Essential Climate Variable (ECV)** zahŕňa presný opis a analýzu krajinnej pokrývky (LC) a zmien krajinnej pokrývky (LCC) pomocou údajov z pozorovania Zeme (EO) s vysokým priestorovým rozlíšením (10 - 30 m).

Krajinná pokrývka má kľúčovú úlohu zmeny povrchovej energie, vody a uhlíka. Okrem toho majú zmeny krajinnej pokrývky vplyv na odrazivosť, vlastnosti vyparovania, a ukladanie uhlíka s rôznymi účinkami na povrchovú teplotu, a zrážky. Tieto faktory boli zohľadňované pri modelovaní klímy Zeme v globálnom meradle s použitím údajov EO so stredným rozlíšením (t. j. 100 m).

Zdokonalenie technológie senzorov dosiahnuté v poslednom desaťročí však umožňuje získať údaje EO s vysokým priestorovým rozlíšením. Z týchto dôvodov projekt *HR_LandCover_CCI* vytvára mapy krajinnej pokrývky a jej zmien s vysokým priestorovým rozlíšením a skúma ich vplyv a rozhodujúcu úlohu priestorového rozlíšenia na klimatické modely v regionálnej mierke (Obr. 8.39).

Projekt bol zameraný predovšetkým na tri oblasti:

- 1. Južná Amerika (Amazonský prales),
- 2. západná Afrika (pásmo Sahelu),
- 3. západná Sibír.

Hlavné ciele projektu sú:

- 1. preskúmať úlohu priestorového rozlíšenia na podporu výskumu klímy;
- Štúdium zmien krajinnej pokrývky v kľúčových regiónoch vystavených extrémnym klimatickým podmienkam alebo charakterizovaných výraznými klimatickými zmenami v posledných desaťročiach.
- 3. Pochopenie variability klasifikácie v časopriestorových mierkach.

Hlavné výstupy projektu:

- 1. mapa HRLC na subkontinentálnej úrovni na úrovni 10 m ako referenčný statický vstup do klimatických modelov,
- 2. dlhodobý záznam regionálnych máp HRLC na úrovni 30 m v regiónoch určených na historickú analýzu každých 5 rokov,
- 3. informácie o zmenách v 30 m a ročnej mierke na podporu aktualizácie máp HRLC.

8 Applications of RS – Land use/Land cover, Agriculture





References

Books

Feranec, J. a kolektív, 2010. Slovensko očami satelitov. 1st ed. Bratislava: VEDA, vydavateľstvo Slovenskej akadémie vied. 263p. ISBN 978-80-224-1105-9.

Giri, C. P. (2016). Remote Sensing of Land Use and Land Cover: Principles and Applications (Remote Sensing Applications Series Book 8) (1st ed.). CRC Press. 469p. ISBN 978-1-4200-7075-0.

Manakos, I. and Braun, M. eds., (2014). Land Use and Land Cover Mapping in Europe. Remote Sensing and Digital Image Processing. Dordrecht: Springer Netherlands. 436p. ISBN 978-94-007-7969-3.

Gutman, G. and Radeloff, V. eds., (2017). Land-Cover and Land-Use Changes in Eastern Europe after the Collapse of the Soviet Union in 1991. Switzerland: Springer International Publishing. 248p. ISBN 978-3-319-42638-9.

Baghdadi, N. and Zribi, M. (2016). Land surface remote sensing in agriculture and forest. Remote Sensing Observations of Continental Surfaces Set ed. London: Iste Press Ltd ; Kidlington, Oxford. 479p. ISBN 978-1-78548-103-1.

Thenkabail, P.S., Lyon, J.G. and Huete, A. (2019). Hyperspectral Remote Sensing of Vegetation. Boca Raton, Fl: Crc Press. 1632p. ISBN 978-1138066250.,

Chu, D. (2020). Remote sensing of land use and land cover in Mountain Region : a comprehensive study at the Central Tibetan Plateau. Singapore: Springer. 240p. ISBN 978-981-13-7580-4.

Lavender, S. and Lavender, A. (2016). Practical handbook of remote sensing. Boca Raton: Crc Press, Taylor & Francis Group. 268p. ISBN 978-1-4987-0434-2.

Lillesand, T.M., Kiefer, R.W. and Chipman, J.W. (2015). Remote sensing and image interpretation. Hoboken, N.J.: John Wiley & Sons, Inc. 770p. ISBN 978-1-118-34328-9.

Thenkabail, P.S. (2016). Remote sensing handbook. Vol. I-III. Boca Raton, Fl: Crc Press. 858p. ISBN 978-1-4822-1795-7.

Coriolan Horațiu Opreanu, Vlad-Andrei Lăzărescu, & Institutul De Istorie Si Arheologie (Cluj-Napoca, Roumanie. (2016). Landscape archaeology on the northern frontier of the Roman Empire at Porolissum : an interdisciplinary research project. Mega Publishing House. ISBN 978-606-543-787-6.

Lopez-Sanchez J.M. et al. (2021) Agriculture and Wetland Applications. In: Hajnsek I., Desnos YL. (eds) Polarimetric Synthetic Aperture Radar. Remote Sensing and Digital Image Processing, vol 25. Springer, Cham. DOI: 10.1007/978-3-030-56504-6_3.

Papers, manuals, reports

European Union, Copernicus Land Monitoring Service 2021, European Environment Agency (EEA), 2021. CORINE Land Cover Product User Manual (Version 1.0). European Environment Agency (EEA), p.129.

Kubinský, D., Balážovič, Ľ., Koleda, P., Masný, M., Weis, K. and Fuska, J. (2019). Copernicus Land Monitoring Service - mapovanie krajinnej pokrývky na Slovensku. Geografická revue, 15(2), pp.58–73. doi: 10.24040/gr.2019.15.2.58-73.

Hutár, V., Halas, J., Pálka, B., Sviček, M. and Dodok, R. (2020). Presnosť, limity a dostupnosť pozorovania krajinnej pokrývky/využitia krajiny na Slovensku v rámci celoeurópskeho prieskumu Lucas. Geografická revue, 16(2), pp.15–25. doi: 10.24040/gr.2020.16.2.15-25.

Feranec, J., Oťaheľ, J., Kopecká, M., Pazúr, R. (2013). Applicability of Remote Sensing Data in Landscape Research. Životné prostredie, 47(1), pp.19 – 23.

Falťan, V., Petrovič, F., Oťaheľ, J., Feranec, J., Druga, M., Hruška, M., Nováček, J., Solár, V. and Mechurová, V. (2020). Comparison of CORINE Land Cover Data with National Statistics and the Possibility to Record This Data on a Local Scale—Case Studies from Slovakia. Remote Sensing, 12(15), p.2484.

Goga, T., Bobáľová, H., Sačkov, I. and Kopecká, M. (2019). Klasifikácia poškodenia lesa vo veľkej mierke na báze leteckých multispektrálnych snímok a lidarových dát – prípadová štúdia CHKO Dunajské luhy. Geografický časopis - Geographical Journal, 71(1).

Xue, J. and Su, B. (2017). Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. Journal of Sensors, 2017, pp.1–17.

Petlušová, V., Petluš, P., Moravčík, M., Bugár, G. (2020). Using Spatial Data from Remote Sensing in Precision Agriculture to Prevent Soil Erosion Development. Životné prostredie, 2020, 54(2), pp.78–82. d'Andrimont, R., Verhegghen, A., Lemoine, G., Kempeneers, P., Meroni, M. and van der Velde, M. (2021). From parcel to continental scale – A first European crop type map based on Sentinel-1 and LUCAS Copernicus insitu observations. Remote Sensing of Environment, 266, p.112708. doi: 10.1016/j.rse.2021.112708.

Foley, J.A., Ramankutty, N., Brauman, K.A., Cassidy, E.S., Gerber, J.S., Johnston, M., Mueller, N.D., O'Connell, C., Ray, D.K., West, P.C., Balzer, C., Bennett, E.M., Carpenter, S.R., Hill, J., Monfreda, C., Polasky, S., Rockström, J., Sheehan, J., Siebert, S. and Tilman, D. (2011). Solutions for a cultivated planet. Nature, [online] 478(7369), pp. 337–342. DOI: 10.1038/nature10452.

Uddin, K., Shrestha, H. L., Murthy, M. S. R., Bajracharya, B., Shrestha, B., Gilani, H., Pradhan, S., & Dangol, B. (2015). Development of 2010 national land cover database for the Nepal. Journal of Environmental Management, 148, 82–90. DOI: 10.1016/j.jenvman.2014.07.047.

Bloomfield, J. A., Rose, T. J., & King, G. J. (2014). Sustainable harvest: managing plasticity for resilient crops. Plant Biotechnology Journal, 12(5), 517–533. DOI: 10.1111/pbi.12198.

Fuster, B., Sánchez-Zapero, J., Camacho, F., García-Santos, V., Verger, A., Lacaze, R., Weiss, M., Baret, F., & Smets, B. (2020). Quality Assessment of PROBA-V LAI, fAPAR and fCOVER Collection 300 m Products of Copernicus Global Land Service. Remote Sensing, 12(6), 1017. DOI: 10.3390/rs12061017.

LIU, C., CHEN, Z., SHAO, Y., CHEN, J., Hasi, T., & PAN, H. (2019). Research advances of SAR remote sensing for agriculture applications: A review. Journal of Integrative Agriculture, 18(3), 506–525. DOI: 10.1016/s2095-3119(18)62016-7.

Nasirzadehdizaji, R., Balik Sanli, F., Abdikan, S., Cakir, Z., Sekertekin, A., & Ustuner, M. (2019). Sensitivity Analysis of Multi-Temporal Sentinel-1 SAR Parameters to Crop Height and Canopy Coverage. Applied Sciences, 9(4), 655. DOI: 10.3390/app9040655.

Mohan, S., Das, A., Halda, r D. and Maity, S. (2011). Monitoring and retrieval of vegetation parameter using multifrequency polarimetric SAR data, 2011 3rd International Asia-Pacific Conference on Synthetic Aperture Radar (APSAR), pp. 1-4.

Tomppo, E., Antropov, O., & Praks, J. (2019). Cropland Classification Using Sentinel-1 Time Series: Methodological Performance and Prediction Uncertainty Assessment. Remote Sensing, 11(21), 2480. DOI: 10.3390/rs11212480.

Mandal, D., Ratha, D., Bhattacharya, A., Kumar, V., McNairn, H., Rao, Y. S., & Frery, A. C. (2020). A Radar Vegetation Index for Crop Monitoring Using Compact Polarimetric SAR Data. IEEE Transactions on Geoscience and Remote Sensing, 58(9), 6321–6335. DOI: 10.1109/tgrs.2020.2976661.

Agapiou, A. (2020). Estimating Proportion of Vegetation Cover at the Vicinity of Archaeological Sites Using Sentinel-1 and -2 Data, Supplemented by Crowdsourced OpenStreetMap Geodata. Applied Sciences, 10(14), 4764. DOI: 10.3390/app10144764.

Web sources

https://www.esa.int/ https://earth.esa.int/ https://www.esa-landcover-cci.org/ https://land.copernicus.eu/ https://copernicus.sazp.sk/ www.l3harrisgeospatial.com/Learn/ http://www.esa-sen2agri.org/ http://esa-sen4cap.org/content/project-background esa-landcover-cci.org/ https://climate.esa.int/en/projects/high-resolution-land-cover/about/



Applications of RS -Geology and Mining Activities

The Earth has a complex and variable surface whose topographic relief and material composition reflect the bedrock and unconsolidated materials beneath each part of the surface, as well as any changes that have affected them. Anyone who seeks to describe and explain the materials and structures of the Earth's surface must understand geomorphological principles and be able to recognise the surface manifestations of different materials and structures. Applications of RS in geological mapping focus on identifying these materials and structures and assessing their properties and characteristics. Geological mapping usually requires a considerable amount of field survey, but the mapping process can be greatly facilitated by the use of visual interpretation of images and their digital analysis.

One of the important roles of RS in this field is the use of satellite imagery as a logistical aid for geological field mapping, especially in remote regions. Satellite imagery provides an efficient and relatively inexpensive way of obtaining information about an area compared to ground-based field surveys. The images are used to locate areas where rocks are exposed at the surface and are thus accessible to study and monitor key geological units. The images also allow important differences between landforms to be identified, linking them to the geological processes that have shaped them. Hyperspectral sensors can obtain reflectance values with a quality similar to laboratory measurements and can therefore provide unique spectral data at high spectral resolution. This allows accurate identification and mapping of minerals and rocks using a variety of hyperspectral sensors while determining the point, local and regional distribution of minerals for a range of geological and soil science investigations.

This chapter discusses the general knowledge of geological mapping using RS technology. A large part of the chapter is devoted to EO applications for monitoring mining activities and their environmental impacts.

· e esa

FBERG

9.1. Geologic mapping

Zem má zložitý a premenlivý povrch, ktorého topografický reliéf a materiálové zloženie odzrkadľujú podložie a nespevnené materiály nachádzajúce sa pod každou časťou povrchu, ako aj všetky zmeny, ktoré na ne pôsobili. Každý typ horniny, každý zlom alebo iný prejav podpovrchových zmien a pohybov, a každý erózny a depozičný prvok v sebe nesú stopy a pozostatky procesov, ktoré ich vytvorili. Každý, kto sa snaží opísať a vysvetliť materiály a štruktúry zemského povrchu, musí pochopiť geomorfologické princípy a vedieť rozpoznať povrchové prejavy rôznych materiálov a štruktúr. Aplikácie DPZ e v geologickom mapovaní sa zameriavajú na identifikáciu týchto materiálov a štruktúr a hodnotenie ich vlastností a charakteristík. Geologické mapovanie si zvyčajne vyžaduje značné množstvo terénneho prieskumu, ale proces mapovania možno značne uľahčiť použitím vizuálnej interpretácie snímok a ich digitálnou analýzou (Obr. 9.1).

Prvé letecké snímky zhotovené z lietadla na účely geologického mapovania boli použité na zostavenie mozaiky pokrývajúcej Benghází v Líbyi v roku 1913. Od 40. rokov 20. storočia sa používanie leteckých (a neskôr satelitných) snímok v geologickom mapovaní rozšírilo. Prvým a zrejme najbežnejším použitím snímok v geologickom mapovaní bolo zvyčajne vytvorenie podkladovej mapy pre manuálnu interpretáciu a zostavenie geologických jednotiek. Topografické výstupy odvodené zo snímok, ako napr. digitálne výškové modely a tieňované mapy reliéfu, sú významným podkladom pre geologické mapovanie.





Geologické mapovanie zahŕňa identifikáciu tvarov terénu, typov hornín a horninových štruktúr (vrásy, zlomy, a pod.) a zobrazenie geologických jednotiek a štruktúr na mape alebo inom zobrazení v ich správnom priestorovom vzťahu (Obr. 9.2). Prieskum nerastných surovín je taktiež dôležitým typom geologického mapovania. Nakoľko väčšina povrchových a blízko-povrchových ložísk nerastov bola nájdená v dostupných oblastiach, súčasný dôraz sa kladie na lokalizovanie ložísk hlboko pod zemským povrchom alebo v neprístupných oblastiach. Geofyzikálne metódy, ktoré umožňujú dostať sa hlboko pod zemský povrch, sú potrebné na lokalizáciu potenciálnych ložísk; a na potvrdenie ich existencie sú potrebné prieskumné vrty. Informácie o potenciálnych oblastiach výskytu minerálov sa však dajú získať aj interpretáciou povrchových prvkov na leteckých a satelitných snímkach.





Fig. 9.2 Example of a concept illustrating the process of 3D geological mapping and 3D mapping of geothermal potential.

Source: Siler et al., 2019

Jednou z dôležitých úloh DPZ v tejto oblasti je využitie satelitných snímok ako logistická pomôcka pre terénne geologické mapovanie, najmä v odľahlých regiónoch. Letecké a satelitné snímky poskytujú efektívny a pomerne lacný spôsob získania informácií o danej oblasti v porovnaní s pozemným terénnym prieskumom. Snímky sa používajú na lokalizáciu oblastí, kde sú horniny na povrchu odkryté, a sú tak prístupné na štúdium a sledovanie kľúčových geologických jednotiek v krajine. Snímky tiež umožňujú identifikovať dôležité rozdiely medzi tvarmi terénu, spájať ich s geologickými procesmi, ktoré ich formovali, a tak interpretovať geologickú históriu oblasti (Obr. 9.3).



Obr. 9.3 Zobrazenie geologických štruktúr na satelitnej snímke Sentinel-2 v oblasti Erongo, Namíbia.

Fig. 9.3 Display of geological structures on a satellite image Sentinel-2 in the Erongo region, Namibia.

Source: European Union, Copernicus Sentinel-2 imagery

Pri geologickom mapovaní sa zvyčajne používa viacstupňová interpretácia snímok. Väčšinou sa začína interpretáciou satelitných snímok v mierkach 1 : 250 000 až 1 : 1 000 000, následne leteckých snímok pri väčšej výške letu v mierkach od 1 : 58 000 do 1 : 130 000. Na podrobné mapovanie je možné použiť letecké snímky v mierke až 1 : 20 000.

Mapovanie v malých mierkach často zahŕňa mapovanie regionálnych lineárnych prvkov, ktoré sú spôsobené lineárnym usporiadaním morfologických prvkov, ako sú vodné toky, úbočia a horské pásma; a tonálnych prvkov, ktoré sú v mnohých oblastiach povrchovým vyjadrením zlomov alebo zlomových zón. Zvýšené zadržiavanie vlhkosti v materiáli v zlome alebo zlomovej zóne sa často prejavuje napríklad vo forme výraznej vegetácie. Hlavné línie môžu mať dĺžku od niekoľko až do stoviek kilometrov. Mapovanie lineárnych prvkov je tiež dôležité pri štúdiách nerastných surovín, pretože veľa rudných ložísk sa nachádza pozdĺž zlomových zón.

Odhaľovanie línií a iných topografických prvkov geologického významu ovplyvňuje niekoľko faktorov. Jedným z najdôležitejších je uhlový vzťah medzi objektom a zdrojom osvetlenia. Vo všeobecnosti znaky, ktoré sa vyvíjajú paralelne so zdrojom osvetlenia, nie sú identifikovateľné tak ľahko ako tie, ktoré sú orientované kolmo. Na detekciu jemných topografických lineárnych prvkov sú vhodnejšie mierne nízke uhly osvetlenia. Pri optických snímkach je uhol osvetlenia určený polohou slnka voči Zemi a satelitu. Alternatívnym riešením je použitie radarového satelitu, ktorého konfigurácia voči Zemi

môže byť použitá na zvýraznenie týchto jemných topografických prvkov. Ďalšou možnosťou je vytvoriť digitálny výškový model (DEM) z fotogrametrie, lidarových údajov alebo radarovej interferometrie a z neho potom tieňované reliéfne mapy, v ktorých sa zvolí uhol simulovaného osvetlenia, aby sa optimalizovala interpretovateľnosť topografie.

Na snímkach s tieňovaným reliéfom možno identifikovať viacero geologických prvkov. Obrázok 9.4 ukazuje povrchovú geológiu v štáte Maine (Nové Anglicko, USA) na DEM odvodenom z lidarových dát s vysokým rozlíšením. Osvetlenie je simulované zo severozápadu, čo by v skutočnosti pri slnečnom osvetlení v tejto lokalite nikdy nenastalo. Výskumníci z Maine Geological Survey identifikovali v tejto oblasti širokú škálu ľadovcových a postglaciálnych tvarov terénu, z ktorých mnohé je ťažké identifikovať na akýchkoľvek iných snímkach(alebo dokonca priamo v teréne) kvôli hustej vegetácii. V tomto vysokokvalitnom súbore údajov lidaru je možné zmapovať množstvo ďalších povrchových geologických prvkov a geologických prvkov podložia.



Obr. 9.4 Interpretácia povrchovej geológie z lidarových dát s vysokým rozlíšením v mierke 1:60 000 na hlavnej snímke, 1:20 000 v detailoch A a B.

Fig. 9.4 Interpretation of surface geology from high resolution lidar data at a scale of 1 : 60 000 on the main image, 1 : 20 000 in detail A and B.

Source: Lillesand, 2015

Pre identifikovanie nerastných surovín a pre litologické mapovanie je dôležitá odrazivosť povrchu najmä v pásmach EMŽ s vlnovou dĺžkou okolo 1,6 až 2,2 µm, čo je možné získať rôznymi multispektrálnymi a hyperspektrálnymi senzormi. Pre rozlišovanie rôznych typov hornín a minerálov sa tiež používa niekoľko úzkych pásiem v tepelnej infračervenej oblasti EMŽ.

Keďže približne 70 % zemského povrchu je pokrytých vegetáciou, tak je významným aj tzv. geobotanický prístup pre rozlišovanie geologických jednotiek. Základom geobotaniky je vzťah medzi požiadavkami rastliny na živiny a dvoma vzájomne

9 Applications of RS – Geologic and Mining Activities

súvisiacimi faktormi – dostupnosťou živín v pôde a fyzikálnymi vlastnosťami pôdy vrátane dostupnosti pôdnej vlhkosti. Rozloženie vegetácie sa často používa ako nepriamy indikátor zloženia podložných pôd a horninových materiálov. Obzvlášť dôležitým aspektom tohto prístupu je identifikácia vegetačných anomálií súvisiacich s mineralizovanými oblasťami. Geobotanické anomálie môžu byť vyjadrené rôznymi spôsobmi: (1) anomálna distribúcia druhov a/alebo rastlinných spoločenstiev, (2) zakrpatený alebo zvýšený rast a/alebo neobvykle riedka alebo hustá pôdna pokrývka, (3) zmena pigmentu listov a/alebo fyziologické procesy, ktoré spôsobujú zmeny farby listov, a (4) neobvyklé zmeny vo fenologickom cykle, ako je skorá zmena listov alebo starnutie na jeseň, zmena obdobia kvitnutia a/alebo neskoré opadávanie listov na jar. Takéto vegetačné anomálie sa najlepšie identifikujú analýzou snímok získaných niekoľkokrát počas roka, s dôrazom na vegetačné obdobie, od jari až po jesennú senescenciu. Pomocou tohto prístupu je možné vytvoriť "normálne" vegetačné podmienky a ľahšie identifikovať anomálne podmienky (Obr. 9.5).



Obr. 9.5 Zobrazenie vegetačnej anomálie v súvislosti s podzemným ropným ložiskom vo forme priemernej hodnoty NDVI vypočítanej za obdobie 10 rokov.

Fig. 9.5 Display of the vegetation anomaly associated with an underground oil field in the form of an average NDVI value calculated over a 10-year period.

Source: Krupnik and Khan, 2017

9.2. Hyperspectral geological mapping

Prieskum a mapovanie nerastov a hornín pomocou tradičných geologických techník je často únavné, finančne a časovo náročné. Vďaka technológii multispektrálneho DPZ, využitím niekoľkých širších pásiem EMŽ vo viditeľnej (VIS), krátkej infračervenej (SWIR) a termálnej infračervenej (TIR) oblasti, je možné rozlišovať a mapovať litológiu a minerály/horniny. Avšak kvôli nízkemu spektrálnemu rozlíšeniu (a tiež nižšiemu priestorovému rozlíšeniu) takýchto multispektrálnych senzorov je ťažké alebo nemožné podrobne zmapovať minerálne/horninové druhy/triedy a ich zloženie a odhadnúť relatívne množstvo minerálnych zložiek v rámci 1 pixelu snímky. Hyperspektrálne dáta boli využívané pre rôzne geologické aplikácie v podstate od nástupu spektroskopie resp. hyperspektrálneho DPZ na začiatku 80. rokov 20. storočia. Hyperspektrálne dáta sú veľmi vhodné pre geologické účely a identifikáciu a mapovanie pôdy nakoľko rôzne minerály/horniny a pôdne typy majú jedinečné vlastnosti pohlcovania EMŽ (resp. odrazivosti v jednotlivých pásmach) z dopadajúceho slnečného žiarenia.

Už začiatkom osemdesiatych rokov viacerí výskumníci z oblasti geológie využívali hyperspektrálne zobrazovacie údaje na identifikáciu minerálov a geologické mapovanie.

Hyperspektrálne senzory majú schopnosť získavať hodnoty odrazivosti s kvalitou podobnou laboratórnym meraniam a môžu teda poskytovať jedinečné spektrálne údaje vo vysokom spektrálnom rozlíšení (Obr. 9.6). To umožnilo presnú identifikáciu a mapovanie minerálov a hornín pomocou rôznych hyperspektrálnych senzorov, a zároveň stanovenie bodovej, lokálnej a regionálnej distribúcie minerálov pre celý rad geologických a pôdoznaleckých výskumov.







Fig. 9.6 Comparison of the spectral curve for the mineral alunite from four sensors with different spectral resolution.

Source: Smith et al., 2016

Postupne bolo otestovaných, a pre geologické mapovanie úspešne využitých, viacero hyperspektrálnych senzorov: leteckých – AVIRIS, HYDICE, DAIS, HyMap; aj satelitných – EO-1 Hyperion, EnMap.

Výsledky vedeckej práce tímov z USGS (United States Geological Survey), ktorí využili hyperspektrálne dáta z VNIR, SWIR a TIR pásiem EMŽ aby získali a zaznamenali hodnoty spektrálnych odrazivostí rôznych minerálov a hornín, dnes tvoria základ pre naše pochopenie a testovanie použiteľnosti leteckých a satelitných hyperspektrálnych senzorov pre aplikácie v geológii a vedách o pôde.

Hlavnou výhodou použitia hyperspektrálnych údajov v geológii je, že diagnostické (absorpčné) spektrálne vlastnosti rôznych minerálov a hornín v spektrálnych pásmach nám umožňujú určiť ich chemické zloženie a relatívne množstvo. Preto sa hodnoty odrazivosti získané hyperspektrálnymi senzormi s jemným spektrálnym rozlíšením môžu použiť na identifikáciu veľkého množstva rôznych minerálov a hornín na povrchu, ktoré nie je možné identifikovať na bežných snímkach s nízkym spektrálnym rozlíšením (Obr. 9.7). Tým tvoria cenný doplnok k tradičným metódam a poskytujú nám dáta, ktoré by sme inak nemali prístupné.



Obr. 9.7 Príklady spektrálnych kriviek pre rôzne typy hornín a minerálov. **Fig. 9.7** Examples of spectral curves for different types of rocks and minerals. Source: Núñez et al., 2014

V súčasnosti však stále existuje niekoľko obmedzení hyperspektrálneho DPZ pri prieskume a mapovaní minerálov / hornín a pôdy:

Údaje z hyperspektrálneho DPZ majú hĺbku prieniku pod povrch približne niekoľko mikrometrov v oblastiach VNIR–SWIR, niekoľko centimetrov v oblasti TIR, až po niekoľko metrov (v nadmerne suchých oblastiach) v oblasti mikrovlnnej časti EMŽ. Väčšinou preto používatelia hyperspektrálnych dát v geológii potrebujú aj nejaké nepriame indície, ako napr. všeobecné geologické pomery, alteračné zóny, a súvisiace typy hornín v danej oblasti. Hyperspektrálne údaje majú teda väčší význam pri prieskume a mapovaní minerálov ako iné údaje z DPZ, vďaka ich jedinečným diagnostickým spektrálnym vlastnostiam.

Spektrálne rozdiely a zmeny vlastností v odrazivosti materiálov sú medzi rôznymi minerálnymi/horninovými druhmi veľmi slabé. Preto, aby sme získali jemné a presné

spektrálne informácie z hyperspektrálnych údajov na prieskum a mapovanie minerálov/hornín a pôd, je nevyhnutné zavedenie presnej rádiometrickej a atmosférickej korekcie. Na rozdiel od toho, pri multispektrálnom DPZ je tento problém relatívne zanedbateľný.

Okrem spomínaných obmedzení je potrebné pamätať aj na to, že vrchná horninová vrstva, resp. pôdny horizont, nie sú väčšinou úplne vystavené slnečnému žiareniu. Čiastočné alebo úplné pokrytie vegetáciou sťažuje mapovanie a identifikáciu minerálov, hornín a pôdnych druhov, čo si vyžaduje použitie efektívnych algoritmov a techník na spracovanie a analýzu hyperspektrálnych dát s cieľom zlepšiť presnosť a kvalitu geologického prieskumu minerálov/hornín (Obr. 9.8).



Obr. 9.8 Výstup z hyperspektrálneho mapovania nerastných surovín – zobrazenie výskytu 6 rôznych minerálov na podklade RGB kompozície Sentinel-2. **Fig. 9.8** The result of hyperspectral minerals mapping - display of the distribution of 6 different minerals displayed over RGB composition from Sentinel-2. Source: Shebl et al., 2021

9.3. Application of SAR in geology

Zatiaľ čo priestorové a spektrálne informácie sa získavajú z optických snímok, radarový diaľkový prieskum Zeme v mikrovlnnom pásme EMŽ poskytuje nenahraditeľný zdroj informácií pre pozorovanie Zeme vo vysokom rozlíšení s možnosťou zaznamenávania dát počas dňa aj noci. SAR dáta môžu poskytnúť rôzne informácie o geológii a nerastných surovinách, ako napr. geologická štruktúra, litológia, skryté geologické telesá v súvislosti s vulkanickými ložiskami, dopadmi meteoritov a rozsiahlymi zlomami (Obr. 9.9). Pomocou SAR dát z radarových satelitných misií (napr. Sentinel-1) získaných v rôznom čase je taktiež možné získať kvantitatívne údaje o deformácii zemskej kôry v reálnom čase. Analýza SAR dát sa v súčasnosti bežne využíva aj v seizmickom výskume, resp. hodnotení katastrof v dôsledku zemetrasení. Medzi hlavné oblasti analýzy zemetrasení pomocou SAR údajov patria:

- lokalizácia hypocentier,
- lokalizácia a vyhodnotenie indukovaných sekundárnych katastrof (zosuvy pôdy, zosuvy bahna, morské zemetrasenia, povrchové trhliny, povrchové zrútenia),
- odhad krátkodobého priestorového vývoja seizmických aktivít.

Využitie SAR na monitorovanie povrchových deformácií a geologických katastrof sa v posledných rokoch stalo kľúčovou otázkou. Táto metóda, vhodná na identifikovanie a monitorovanie rozsiahlych deformácií zemského povrchu, sa využíva pri monitorovaní miest, povrchu v banských oblastiach, obvodového povrchu priehrad a pod.



Obr. 9.9 Mapovanie geologických štruktúr pomocou radarových snímok PALSAR a Sentinel-1B, a z nich manuálne identifikované lineamenty.

Fig. 9.9 Mapping of geological structures using PALSAR and Sentinel-1B radar images and manually identified lineaments.

Source: Zoheir et al., 2019

9.3.1. Suitability of RS data for applications in geology

Satelitné údaje z optického DPZ s vysokým priestorovým rozlíšením vykazujú vyššie rozlíšenie a viac vizuálnych obrazových informácií ako radarové údaje, čo zjednodušuje interpretáciu a identifikáciu geologických informácií. V porovnaní s optickými satelitnými snímkami SAR snímky poskytujú jasnú reprezentáciu reliéfu, dobrú detekciu rôznych tvarov terénu a ďalšie informácie. Aplikácia SAR snímok je vysoko citlivá na

rozdiely v morfológii a drsnosti povrchu; väčšina radarových údajov sa teda stále používa v oblastiach púští a iných oblastiach pokrytých nízkou vegetáciou. Spojenie radarových a optických snímok teda výrazne zjednodušuje proces detekcie a rozpoznávania objektov a zlepšuje presnosť identifikácie spojením výhod oboch metód.

Na základe dostupnej vedeckej literatúry a publikovaných vedeckých výsledkov sa vhodnosť/vyspelosť využitia optických/radarových dát DPZ v geológii dá zhrnúť nasledovne (Tab. 9.1):

Tab. 9.1 Vhodnosť DPZ dát pre geologické aplikácie.
Tab. 9.1 Suitability of RS data for geological applications

Aplikácia	Radarové dáta	Optické dáta
Geologické katastrofy	Stredná - vysoká	Vysoká
Zemetrasenia	Vysoká	Stredná - vysoká
Banská činnosť	Stredná - vysoká	Vysoká
Monitoring l'adovcov	Vysoká	Nízka - stredná
Topografické aplikácie	Nízka - stredná	Nízka
Identifikácia zlomov	Vysoká	Nízka
Litologické mapovanie	Nízka	Vysoká
Monitoring sopečnej činnosti	Nízka - stredná	Stredná - vysoká

Diaľkový prieskum Zeme ako nástroj geologického prieskumu má tiež určité obmedzenia, pretože snímky DPZ obsahujú najmä povrchové informácie alebo blízke podpovrchové informácie, zatiaľ čo väčšina geologických telies, geologických štruktúr a geologických javov odráža trojrozmerné informácie. Integrácia dostupných geologických údajov, údajov diaľkového prieskumu Zeme a geofyzikálnych údajov tieto obmedzenia potláča, čo znižuje nejednoznačnosť geologickej interpretácie a zlepšuje presnosť. Monitorovanie a pochopenie geologických procesov si teda vyžaduje aj multidisciplinárnu analýzu a integráciu údajov diaľkového prieskumu Zeme s pozorovaniami v teréne a podzemnými geofyzikálnymi údajmi. Pomocou nástrojov GIS je potom možné rôzne rastrové a vektorové údaje získané z terénu kombinovať s diaľkovým prieskumom Zeme, geofyzikou a geochemickou analýzou, ktorá dokáže komplexne analyzovať rôzne typy údajov a ich vzťahy, čím sa vytvára základ pre celkovú geologickú analýzu.

Využitie dát z DPZ v geologických aplikáciách je uvedené aj v Kapitole 12.

9.4. Applications in Slovakia

Podľa Feranec, et al. (2010), experimentálnym využívaním satelitných snímok na geologické účely sa na Slovensku začalo koncom 70. a začiatkom 80. rokov 20. storočia. Nadviazalo sa tým na dovtedajšie využívanie meračských leteckých snímok pri geologickom mapovaní, ktoré v oveľa väčšej miere aplikovali slovenskí geológovia pri zahraničných expertízach ako pri geologickom výskume územia Slovenska. Nadväzne, ale často aj súčasne so zostavením fotointerpretačných snímkach pristúpilo k ich

analýze a korelácii so známymi geofyzikálnymi a geologickými údajmi a pokusom o objasnenie ich genézy. Súčasným základným mapovým výstupom je tektonická mapa Slovenskej republiky (Obr. 9.10).



Obr. 9.10 Tektonická mapa Slovenskej republiky. **Fig. 9.10** The tectonic map of the Slovak republic. Source: ©2017 ŠGÚDŠ, Esprit, s.r.o.

9.4.1. Geological structures on satellite images of Slovakia

Geologické štruktúry zistené interpretáciou satelitných snímok sú väčšinou prehľadným spôsobom graficky vyjadrené v rôznych mapách a mapových schémach, obyčajne v rôznych kombináciách s geologickými a geofyzikálnymi údajmi prevzatými z iných podkladov. Takéto mapy predstavujú syntézu systematickej vizuálnej interpretácie satelitných snímok z celého územia Slovenska (resp. v rámci niekdajšieho Československa) a ich interpretáciu na geologické účely. Výsledky získané interpretáciou sú následne porovnávané so známymi geologickými údajmi predovšetkým štruktúrno-tektonického charakteru.

Na mapách sú znázornené veľké regionálne a interregionálne zlomy, ktorých prejavy sa v podobe fotolineárnych štruktúr identifikovali na satelitných snímkach. Všeobecne sa na nich najvýraznejšie prejavujú zlomové štruktúry poklesového a smerne posuvného pôvodu ako zlomy spojené s násunovou tektonikou (prešmyky a násuny). Na satelitných snímkach sú identifikované všetky významnejšie známe zlomové štruktúry, pričom v mnohých prípadoch bolo možné spresniť ich priebeh a vzájomnú nadväznosť niektorých zlomov lokálneho charakteru na regionálne zlomové štruktúry.

Z lineárnych štruktúr je najvýraznejší systém fotolineamentov, ktoré je možné sledovať z oblasti Viedenskej panvy cez Saštín - Senicu - Myjavu - Nové Mesto n. Váhom - Bánovsku kotlinu - Strážovské vrchy - Turčiansku kotlinu - Ružomberok až po západné ukončenie Tatier (Obr. 9.11).



Obr. 9.11 Výrazné zlomové ohraničenie Turčianskej kotliny na satelitnej snímke Sentinel-2 v Colour Infrared kompozícii.

Fig. 9.11 Significant fault boundary of the Turčianska basin on the Sentinel-2 satellite image in Colour Infrared composition.

Source: Copernicus Sentinel data [2020]. Retrieved from Copernicus SciHub [07/12/2021], processed by FBERG TUKE, after Feranec et al., 2010

Na satelitných snímkach sa väčšinou identifikujú aj početné nelineárne (kruhové) štruktúry, vo viacerých prípadoch interpretované ako prejavy magmatogénnych (vulkanických) štruktúr, s úzkymi vzťahmi k centrálnym zónam najvýznamnejších stratovulkánov v oblasti Slovenského stredohoria (Poľana, Lysec), Slanských vrchov (Zlatá Baňa, Makovica, Strechový vrch, Bogota) a Vihorlatu (Popriečny, Diel, Morské oko, Vihorlat, Kyjov), pozri Obr. 9.12.


Obr. 9.12 Vulkanické štruktúry identifikované na satelitných snímkach Sentinel-2 v Colour Infrared kompozícii v oblastiach najvýznamnejších stratovulkánov na Slovensku – Poľana, Slanské vrchy (Bogota, Strechov, Makovica) a Vihorlat (Vihorlat, Morské oko).

Fig. 9.12 Volcanic structures identified on Sentinel-2 satellite images in Colour Infrared composition in the areas of the most important stratovolcanoes in Slovakia - Poľana, Slanské vrchy (Bogota, Strechov, Makovica) and Vihorlat (Vihorlat, Morské oko).

Source: Copernicus Sentinel data [2020]. Retrieved from Copernicus SciHub [07/12/2021], processed by FBERG TUKE, after Feranec et al., 2010

Výsledky geologických interpretácií satelitných snímok a ich porovnanie so známymi geologickými a tektonickými štruktúrami na Slovensku potvrdili opodstatnenosť a prínos ich využívania, najmä v kontexte regionálne zameraných štruktúrno-tektonických výskumov aj v relatívne dobre geologicky preskúmaných Západných Karpatoch. Získané poznatky sa v mnohých prípadoch neskôr potvrdili a ďalej spresnili novším terénnym geologickým výskumom, založeným na moderných metódach štrukturno-geologického a tektonického zamerania.

9.5. Applications and projects using ESA satellite missions in Geology

9.5.1. Sentinels help with mineral mapping

Pomocou geologických máp je možné identifikovať rôzne horniny, minerály, geologické štruktúry, zlomy, podzemnú vodu, a výskyt ložísk. Okrem rizikových analýz a stavebnej infraštruktúry sú dôležité aj pre lokalizovanie a ťažbu nerastných surovín. V rámci celoafrickej iniciatívy ESA podporila zber, interpretáciu a šírenie satelitných dát o geológii a nerastných surovinách ako napr. železité rudy.

Aktivita financovaná agentúrou ESA pripravila cestu pre nemeckú geoinformačnú spoločnosť GAF, aby pomohla africkej iniciatíve Mineral Geoscience. Cieľom iniciatívy je katalogizácia geológie a nerastných zdrojov Afriky. Tento projekt využíva voľne dostupné dáta z misií Sentinel-1 a Sentinel-2, ako aj dáta z iných satelitov, ako radarová topografická misia raketoplánu NASA (Shuttle Radar Topography Mission) a WorldView-3.

Zámerom projektu bolo vytvoriť geologické mapy pre rôzne klimatické zóny a rôzne typy geológie, najmä v oblastiach, kde je nedostatok údajov, nie sú dostatočne podrobné alebo sú zastarané. Výsledky ukázali, že zatiaľ čo suché a polosuché oblasti sa dajú zmapovať relatívne presne, tak tropické oblasti sú problematické keďže sú zvyčajne pokryté hustou vegetáciou, cez ktorú optické senzory nedokážu získať informácie o krajine pod ňou. V týchto regiónoch sa použili radarové údaje a údaje o výške terénu, teda základom výsledných máp sú štrukturálne informácie (napr. riečne siete - Obr. 9.13).



Obr. 9.13 Geologická mapa regiónu v Namíbii. **Fig. 9.13** Geological map of a region in Namibia. Source: ©GAF; https://www.esa.int

Celkovo táto iniciatíva ukázala, ako sa dajú dôsledne a efektívne mapovať veľké územia, čo má osobitný význam pre prieskum regionálnej geológie a ťažbu nerastných surovín. Výsledky projektu dokazujú, že satelitné snímky v kombinácii s existujúcimi geofyzikálnymi údajmi predstavujú rýchly, efektívny a účinný spôsob podpory tvorby a interpretácie geologických máp vo všetkých mierkach - od prieskumného mapovania v malej mierke až po podrobné prieskumy - ktoré sú dôležité pre prieskum nerastných surovín.

Okrem toho sú tieto výsledky dôležité, pretože sa predpokladá, že presný a komplexný geologický katalóg môže do regiónu Afriky pritiahnuť ďalšie investície.

9.5.2. Earth Observation for the Mining of Raw Materials (EO4RM)

V súčasnosti ťažba prebieha po celom svete, často vo veľmi vzdialených lokalitách, rozptýlených medzi krajinami rôzneho stupňa bohatstva. Ťažobné spoločnosti čelia viacerým výzvam vo všetkých fázach - od prieskumu až po zatvorenie bane a následnú starostlivosť.

Informácie odvodené zo satelitov DPZ môžu poskytnúť nepretržitý tok informácií na monitorovanie poklesov, zosuvov, geológie, biológie, ekológie, sociálno-ekonomického rozvoja, dostupnosti zdrojov a pod. Môžu tiež poskytnúť údaje o veľmi vzdialených a neprístupných oblastiach.

Projekt Pozorovanie Zeme pre ťažbu nerastných surovín (*EO4RM*) spája odborníkov z ťažobného sektora a z oblasti DPZ, aby identifikovali kľúčové výzvy tohto sektora a vhodné riešenia čerpajúce z moderných a budúcich možností DPZ. Cieľom aktivity je stanoviť aktuálne informačné potreby a osvedčené postupy pre používanie produktov a služieb založených na pozorovaní Zeme. Rozsah činnosti zahŕňa všetky relevantné obchodné procesy (*"životný cyklus ťažby"*), od prieskumu a hodnotenia vplyvu až po ťažbu a po uzavretí, ako aj geoinformačné potreby príslušných regulačných agentúr.

Konečná analýza projektu by mala:

- identifikovať a konsolidovať kľúčové informačné požiadavky z ťažobného sektora,
- identifikovať príslušné produkty a služby založené na DPZ,
- poskytnúť plán pre prijatie služieb a produktov DPZ v ťažobnom priemysle.

Konzorcium kľúčových odborníkov z oboch odvetví realizuje viaceré prieskumy, workshopy a stretnutia používateľov s cieľom vypracovať plán osvedčených postupov a usmernenia pre používanie údajov o pozorovaní Zeme v ťažobnom sektore.

Pri týchto analýzach sa berú do úvahy nasledujúce štyri fázy životného cyklu ťažby:

- Prieskum
- Environmentálne hodnotenie a povolenie
- Konštrukcia a prevádzka
- Uzatváranie baní a následná starostlivosť

Medzi produkty a služby v oblasti geologického mapovania, poskytované v rámci projektu *EO4RM*, patrí napríklad:

9.5.2.1. Geophysical assessment

Oblasť, v ktorej prebieha ťažba, musí byť štrukturálne vhodná a nesmie byť náchylná na poklesy alebo kolapsy. Preto je pred akoukoľvek výstavbou, resp. ťažobnou činnosťou potrebné posúdenie danej oblasti. Taktiež je potrebné ďalšie monitorovanie počas banskej činnosti, najmä pre sledovanie konštrukčnej stability budov.

Tento produkt *EO4RM* monitoruje ťažobnú oblasť a zisťuje akékoľvek zmeny v reliéfe (Obr. 9.14). Detekcia zmeny sa zvyčajne vykonáva pomocou radarových satelitných snímok. Na sledovanie zmien sa porovnávajú snímky z rôznych časových období, pričom zistené odchýlky v odrazivosti poukazujú na morfologické zmeny, odchýlky pôdnej vlhkosti, rast vegetácie a antropogénne príčiny. Na posúdenie pohybov sa zároveň využíva aj metóda raradovej interferometrie.

V rámci tohto produktu sa využívajú satelitné dáta z misií Sentinel-1, TerraSAR-X a COSMO-SkyMed. Veľkosť minimálnej mapovacej jednotky môže dosiahnuť až 1 m. Dáta sú dostupné približne do 5 dní od vyhotovenia potrebných satelitných snímok.

9 Applications of RS – Geologic and Mining Activities



Obr. 9.14 Monitorovanie priestorových zmien v oblasti ropných plošín na základe data DPZ -Ghawar oil field, Saudi Arabia.

Fig. 9.14 Monitoring of spatial changes in the area of oil rigs based on remote sensing data -Ghawar oil field, Saudi Arabia.

Source: www.geoville.com

9.5.2.2. Lithology mapping and surface geology

Litologické prvky, litológiu a povrchovú geológiu (pôdy) možno rozlíšiť a zmapovať pomocou širokej škály senzorov DPZ a analytických techník, ktoré zvyknú zahŕňať použitie viacerých súborov dát z pozorovanie Zeme. Medzi produkty patria:

- geologické mapy, litologické mapy, pôdne/povrchové geologické mapy;
- mapy terénnych jednotiek (zahŕňajúce litológiu s triedami terénu);
- mapy priesakov uhľovodíkov na pevnine (podľa identifikácie zmenených hornín a pôd).

Produkty sa môžu líšiť podľa špecifických požiadaviek používateľa a závisia od kontextu (napr. geografického rozsahu a úrovne podrobností a presnosti).

Spektrálna analýza je v súčasnosti osvedčený nástroj využívajúci spektrálne vlastností povrchových materiálov (pomocou rôznych techník ako je kombinácia rôznych pásiem, pomer pásiem, a analýza hlavných komponentov - PCA). Litotypy možno rozlíšiť podľa spektrálnej charakteristiky spolu so vzťahmi s topografiou/geomorfológiou, najmä textúrou (drsnosť povrchu) a vzorom. Zmenené horniny a pôdy (napr. obohatenie železom a zmena ílových minerálov) spojené s presakovaním uhľovodíkov na pobreží môžu poskytnúť dôležité údaje pre geologické modelovanie a prieskum daného povodia.

Techniky multispektrálnej analýzy využívajú odrazené infračervené (VNIR, MIR) a tepelné vlnové dĺžky merané zo širokej škály senzorov v rôznych rozlíšeniach. Fúzia údajov medzi rôznymi senzormi a inými súbormi údajov vrátane DEM a geofyziky umožňuje lepšiu interpretáciu a litologickú klasifikáciu (Obr. 9.15).

V kombinácii s inými produktmi DPZ je možných viac aplikácií: Geomorfologická analýza vrátane DEM a analýzy tieňovaného reliéfu sa môže použiť na identifikáciu pôd podľa geomorfných foriem, ako sú fluviálne nánosy (riečne terasy, aluviálne vejáre, delty) a pieskové duny. Drsnosť povrchu a obsah vlhkosti môžu poskytnúť indikáciu stupňa zvetrávania a tvorby pôdy. DEM s vysokým rozlíšením sú prospešné na mapovanie geomorfných foriem súvisiacich s povrchovými ložiskami. Časová analýza môže poskytnúť informácie o mobilite povrchových ložísk, ako sú mobilné duny a riečne (riečne/delta) systémy. Hyperspektrálne údaje umožňujú rozlíšenie jemnejších úrovní detailov spektrálnej triedy a identifikáciu minerálov pre lepšiu litologickú diferenciáciu.

Geofyzikálne údaje z DPZ možno tiež efektívne začleniť do analýzy údajov z pozorovania Zeme, ak produkt založený iba na dátach z pozorovania Zeme nie je dostatočne podrobný a presný pre litologické použitie. Geofyzikálne údaje z DPZ v súčasnosti nemajú dostatočné rozlíšenie, aby umožnili podrobné litologické rozlíšenie. Údaje zozbierané zo satelitu GOCE (2009 – 2013) majú určitý prínos pre mapovanie geologických štruktúr v globálnom a širokom regionálnom meradle vrátane mapovania hĺbky zemskej kôry.

V rámci tohto produktu sa využívajú satelitné dáta z misií Landsat 8, Sentinel-2A, ASTER, EnMAP, GOCE. Pre odoberateľov týchto produktov sú väčšinou potrebné mapové výstupy aktualizované každoročne.



Obr. 9.15 Detail vrstiev z geologického mapovania v Západnej Sahare; zhora – RGB kompozit Sentinel-2, Analýza hlavných komponentov zo Sentinel-2, výškový model SRTM, výsledná geologická mapa v mierke 1:50 000.

Fig. 9.15 Detail vrstiev z geologického mapovania v Západnej Sahare; zhora – RGB kompozit Sentinel-2, Analýza hlavných komponentov zo Sentinel-2, výškový model SRTM, výsledná geologická mapa v mierke 1:50 000.

Source: ©GAF; https://www.esa.int

9.5.3. EIT Raw Materials

Minerály, kovy a pokročilé materiály sú kľúčovými faktormi, ktoré umožňujú dosiahnuť ciele Európskej zelenej dohody. Dnes sa v Európe vyrába len zlomok najdôležitejších surovín. To sa dá zmeniť prostredníctvom prístupu obehového hospodárstva, prostredníctvom inovácií v oblasti recyklácie, nahrádzania, spracovania, ťažby a prieskumu. Cieľom EIT RM je zabezpečiť udržateľné dodávky surovín podporou inovácií, vzdelávania a podnikania v rámci európskych priemyselných ekosystémov.

EIT RawMaterials poskytuje prostredie na spoluprácu pre prevratné a prelomové inovácie prepojením podnikania s akademickou obcou, výskumom a investíciami. Investuje tiež do budúcej generácie inovátorov v sektore surovín prostredníctvom iniciatív siahajúcich od vzdelávania študentov škôl až po vyššiu kvalifikáciu odborníkov v priemysle (Obr. 9.16).



Obr. 9.16 Základné inovačné témy EIT RawMaterials. **Fig. 9.16** Basic innovation themes of EIT RawMaterials. Source: eitrawmaterials.eu

Spoločnosť sa zaviazala podporovať prechod Európy na obehové, zelené a digitálne hospodárstvo a zároveň posilniť svoju globálnu konkurencieschopnosť a zabezpečiť zamestnanosť. Na tomto základe bola EIT RawMaterials poverená Európskou komisiou viesť a riadiť Európsku alianciu surovín (ERMA).

EIT RawMaterials je inovačné spoločenstvo v rámci Európskeho inštitútu pre inovácie a technológie (EIT). Je to organizácia sieťového typu s transparentnou štruktúrou riadenia, ktorá odráža jej orientáciu na poskytovanie služieb zainteresovaným stranám a budovanie excelentnosti z dvojitej perspektívy trhu a tematickej expertízy. Administratívna centrála (HQ) EIT RawMaterials a právne sídlo asociácie sídlia v Berlíne v Nemecku (Obr. 9.17).



Fig. 9.17 Structure of EIT RawMaterials. Source: eitrawmaterials.eu

9.5.3.1. RawMatCop program

EIT RawMaterial v rámci vzdelávania zahŕňa aj program RawMatCop (Obr. 9.18). Cieľom programu RawMatCop je rozvíjať zručnosti, odborné znalosti a aplikácie údajov programu Copernicus v sektore nerastných surovín. Z veľkej časti je financovaný sériou grantov Európskej komisie (DG GROW). Copernicus, program Európskej únie na pozorovanie Zeme, ponúka bezplatné informačné služby založené na satelitnom pozorovaní Zeme a in situ (nie vesmírnych) údajoch (pozri Kapitola 1.4).



Program RawMatCop demonštruje, šíri, vzdeláva a rozvíja nové zručnosti a aplikácie údajov z programu Copernicus a iných údajov z pozorovania Zeme prostredníctvom nasledujúcich aktivít:

- Inžinierske a doktorandské programy,
- Post-doktorandské štúdiá,
- Celoživotné vzdelávanie,
- Aplikačné projekty,
- Mladí inovátori,
- RawMatCop akadémia,
- Používateľské fóra.

Program RawMatCop organizuje aj **RawMatCop Academy – Copernicus for RawMaterials** (Obr. 9.19). Ide o odborný kurz, ktorý ponúka praktický prístup a ukazuje, ako využiť silu programu Copernicus spoločnostiam, organizáciám a výskumným inštitúciám počas celého životného cyklu surovín. Počas kurzu majú účastníci možnosť priamo pracovať s údajmi zo satelitov Sentinel programu Copernicus a softvérom s otvoreným zdrojovým kódom, aby sa naučili, ako ho možno použiť na:

- zabezpečenie primárnych a sekundárnych nerastných a materiálnych zdrojov potrebných na prechod na udržateľné a obehové hospodárstvo,
- monitorovanie vplyvu na životné prostredie a zvyšovanie bezpečnosti.



Obr. 9.19 RawMatCop Academy 2020 – odborný kurz spoluorganizovaný FBERG TUKE v roku 2020. **Fig. 9.19** RawMatCop Academy 2020 - professional course co-organized by FBERG TUKE in 2020. Source: own processing

Kurz kombinuje odborné prednášky z priemyselných a výskumných komunít s praktickou prácou s použitím prípadových štúdií na demonštráciu aplikácií programu Copernicus. Účastníci sa dozvedia, ako môže program Copernicus urobiť využívanie primárnych a druhotných surovín nákladovo efektívnejším a bezpečnejším a ako môže pomôcť pri dodržiavaní právnych predpisov v oblasti životného prostredia. Medzi základné témy kurzu patria:

- Prieskum nerastov a mapovanie ložísk
- Monitoring banskej činnosti vrátane odpadového hospodárstva
- Monitorovanie vplyvov na životné prostredie
- Detekcia vody

Tento kurz je schválený a certifikovaný aj Európskou Federáciou Geológov (European Federation of Geologists).

9.5.4. Geological Remote Sensing Group (GRSG)

Skupina pre geologický diaľkový prieskum Zeme (*GRSG*) je záujmová skupina vytvorená z Geologickej spoločnosti v Londýne (GeolSoc) a Spoločnosti pre diaľkový prieskum Zeme a fotogrametriu v Spojenom kráľovstve (RSPSoc).

GRSG (Obr. 9.20) je združenie nadšencov, ktorí sa zaujímajú o geologické aspekty diaľkového prieskumu Zeme.

Súčasnými členmi sú geológovia a odborníci na diaľkový prieskum Zeme zamestnaní v priemysle, na akademickej pôde a vo vládnych agentúrach, ako aj postgraduálni študenti. Hoci oba materské orgány sídlia v Spojenom kráľovstve, *GRSG* je medzinárodná organizácia s členmi po celom svete.

GRSG je fórum na prezentáciu, diskusiu a výmenu nápadov a informácií týkajúcich sa geologického využitia diaľkového prieskumu Zeme. To znamená, že poskytuje širokú škálu činností a služieb pre členov a v ich mene.

Niektoré z týchto činností zahŕňajú:

- usporadúvanie každoročnej konferencie, ktorá je venovaná prezentácii geologických príspevkov o diaľkovom prieskume Zeme, propagácii komerčných produktov a zabezpečeniu toho, aby sa členovia mali možnosť stretnúť a nadviazať vzájomné kontakty,
- zabezpečenie komunikačných kanálov vrátane webovej stránky, bulletinov a emailov - potrebných na to, aby členovia boli informovaní o najnovších informáciách z odvetvia a skupiny,
- poskytovanie finančných prostriedkov na výskumné projekty prostredníctvom programu *GRSG* Student Awards.



Obr. 9.20 Geological Remote Sensing Group. **Fig. 9.20** Geological Remote Sensing Group. Source: www.grsg.org.uk

9.6. Monitoring mining activities

9.6.1. Activities within the EO4RM project

V rámci projektu Pozorovanie Zeme pre ťažbu nerastných surovín (EO4RM) existuje viacero produktov a služieb monitorujúcich banskú činnosť, resp. jej dopady na životné prostredie a infraštruktúru.

9.6.1.1. Surface subsidence

Tento produkt poskytuje informácie o poklesoch povrchu vplyvom banskej činnosti na základe InSAR. Poskytuje merania s presnosťou na mm na veľkých plochách na týždennej a mesačnej báze a môže slúžiť ako nástroj na monitorovanie celého dobývacieho priestoru aj s jeho priamym okolím.

Typickými aplikáciami tohto produktu je monitorovanie poklesu pôdy v podpovrchovej časti podzemnej bane, a účinkov banskej činnosti na životné prostredie a okolitú infraštruktúru (Obr. 9.21). Výhody spočívajú v tom, že veľké oblasti môžu byť monitorované pravidelne, plne automatizovaným spôsobom a bez ľudského zásahu.

V rámci tohto produktu sa využívajú satelitné dáta z misií Sentinel-1, TerraSAR-X, RadarSat-2 a COSMO-SkyMed. Merania môžu byť realizované na sub-pixelovej úrovni, typicky v rozsahu 1–5 m. Deformácie/pohyby monitorovaných objektov a povrchov môžu byť určené s presnosťou cca 1 mm / rok. Časová dostupnosť spracovaných dát závisí od typu družice, poskytovateľa a typu aplikácie, väčšinou sa pohybuje v rozsahu 1–5 dní.



Obr. 9.21 Hore – mapa povrchových poklesov, dole – profil poklesov. **Fig. 9.21** Top – map of surface subsidence, down – profile of subsidence. Source: https://earsc-portal.eu

9.6.1.2. Infrastructure stability monitoring

Tento produkt poskytuje informácie o stabilite/deformáciách infraštruktúry, objektov a majetku na základe InSAR. Poskytuje merania s presnosťou na mm na veľkých plochách na týždennej a mesačnej báze a môže slúžiť ako nástroj na monitorovanie celého dobývacieho priestoru aj s jeho priamym okolím.

Medzi typické banské aplikácie tohto produktu patrí monitorovanie stability hlušiny, skládok, odkalisiek, svahy ťažobných priestorov, dopravných ciest, budov a prostredia bane počas prevádzky, aj po nej (Obr. 9.22). Výhodou je, že kritickú infraštruktúru možno monitorovať pravidelne, plne automatizovane a bez ľudského zásahu, a že možno získať úplný prehľad o deformáciách v banskej oblasti a jej bezprostrednom okolí. Okrem toho sa pomocou satelitov dá získať jednotný formát a kvalita údajov pre všetky bane pre ktoré sa monitoring vykonáva.



Obr. 9.22 Pretrhnutá hrádza odkaliska hlinikárne v roku 2010 – Kolontár, Ajka, Maďarsko. **Fig. 9.22** The damaged reservoir near an alumina plant in 2010 – Kolontár, Ajka, Hunary. Source: ©Reuters/Laszlo Balogh, www.theatlantic.com

Tento produkt je založený na radarových snímkach z rôznych satelitov (Obr. 9.23). Ich produkty sa môžu líšiť počtom meraní na km2, frekvenciou meraní, cenou (bezplatné a platené snímky) a dostupnosťou. Vo väčšine lokalít na celom svete sú k dispozícii snímky z roku 2015 a v prípade niektorých lokalít až z roku 1992. Je teda možné získať dáta o banskej činnosti a jej vplyvoch nie len v súčasnosti, ale aj z historického hľadiska.

V rámci tohto produktu sa využívajú satelitné dáta z misií Sentinel-1, TerraSAR-X, RadarSat-2 a COSMO-SkyMed. V závislosti od typu satelitu sa doba opakovanej observácie pohybuje od 4 dní po 24 dní. Doba doručenia výsledného produktu sa opäť v závislosti od použitého satelitu, poskytovateľa služby, a typu aplikácie, pohybuje v rozmedzí 1 - 5 dní.



Obr. 9.23 Mapa posunov zaznamenaných počas 1 mesiaca pre odkalisko bane Cadia (Austrália). **Fig. 9.23** Displacement map recorded over 1 month for the tailing dam in Cadia Mine (Australia). Source: Thomas et al., 2019; ©CNES/Airbus (Alphabet Inc. 2018), contains modified Copernicus Sentinel data (2018), ©CGG 2018

9.6.1.3. Land disrupted by mining activities

Pri banskej činnosti je nevyhnutné monitorovať plochu narušenú prevádzkovateľmi ťažby počas fázy výstavby a následnej prevádzky banského závodu. Porovnaním dvoch alebo viacerých satelitných snímok získaných v rôznom čase môžu mapovacie aj banské orgány kontrolovať, aké banské činnosti sú vykonávané. Kombináciou manuálnej alebo automatickej kontroly týchto snímok a použitím nástrojov GIS možno vytvoriť vektorové vrstvy na vymedzenie územia narušeného banskou činnosťou a skúmať vývoj pôdneho krytu počas fáz výstavby a prevádzky. Okrem toho sa môžu využiť aj produkty vegetačných indexov s cieľom kvantifikovať, ako bola narušená vegetácia v rámci ťažobného priestoru a v jeho okolí.

V prípade potreby monitorovania vývoja krajinnej pokrývky vo vysokom rozlíšení v čase môže byť obmedzením oblačnosť na snímkach. Miera tohto obmedzenia závisí od geografickej polohy a klimatických podmienok v oblasti banskej činnosti, ako aj od ročného obdobia.

V rámci tohto produktu sa využívajú satelitné dáta z misií Sentinel-2, Landsat-8, GeoEye-1, Worldview-1, 2 a 3, SPOT 6 a 7, Pleiades. Priestorová presnosť produktov závisí od priestorového rozlíšenia vstupných dát, typicky sa pohybuje v rozmedzí 0,5 – 1 pixel. Digitalizácia krajiny narušenej banskou činnosťou z podkladových snímok do mapových výstupov je vyhotovená v priebehu niekoľkých dní, v závislosti od veľkosti monitorovanej oblasti. Mapové výstupy typicky znázorňujú prehľadové mapy banských činností a ich vývoj v čase; prehľadové mapy krajiny narušenej banskou činnosťou a jej vývoj v čase (Obr. 9.24).

9 Applications of RS – Geologic and Mining Activities



Obr. 9.24 Posúdenie vplyvu najväčšieho ropného a plynového terminálu v Európe na životné prostredie - Sullom Voen, Shetlandy. **Fig. 9.24** Assessment of the largest oil and gas terminal in Europe on the environment – Sullom Voen, Shetland Islands.

Source: www.geoville.com

9.6.1.4. Reclamation / revegetation

Počas zatvárania baní a následnej starostlivosti musia zodpovední aktéri z banského priemyslu preukázať, že oblasť banského diela bola zrekultivovaná a vrátila sa do dohodnutého konečného stavu. Konečný stav vychádza z východiskových údajov zhromaždených počas obdobia procesu povoľovania ťažby, pričom vegetácia a rozmanitosť vegetačného krytu sú kľúčovými ukazovateľmi. Na vykonanie takejto analýzy možno využiť niekoľko produktov pozorovania Zeme:

- Optické snímky umožňujú priebežne monitorovať kroky rekultivácie a následný vývoj revegetácie v okolí a na mieste ťažby. Tieto zmeny vo využívaní pôdy možno manuálne digitalizovať pomocou nástrojov GIS. Takéto pozorovania dávajú banským aj mapovacím orgánom možnosť preskúmať stav jednotlivých krokov pri zatváraní bane a následnej starostlivosti o ňu a overiť, či sa tieto kroky vykonávajú podľa dohodnutého plánu.
- Spojenie produktov snímok v infračervenom a viditeľnom spektre sa môže použiť na vytvorenie mapových produktov vegetačného indexu, ktoré umožňujú identifikáciu vegetáciou pokrytých oblastí a ich stavu.
- Digitálne modely terénu a povrchu s vysokým rozlíšením (DTM a DSM) odvodené z optických snímok (stereoskopia) a/alebo lidarových dát sa môžu použiť na určenie výšky stromov. Takáto analýza je užitočná na zisťovanie porastených plôch a odhad ich objemu - biomasy.

Rýchlosť rastu vegetačného krytu sa líši v závislosti od geografickej polohy a klímy. Ak je rýchlosť rastu relatívne pomalá, môže byť potrebné dlhšie obdobie monitorovania (roky až desaťročia), aby sa v danej oblasti preukázala úplná obnova biotopu po ťažbe.

Rast a obnova vegetácie závisí aj od rôznych faktorov a ich vývoja v čase - odstránenie ťažobnej infraštruktúry, kvalita ovzdušia a vody, hospodárenie s vodou a rozmiestnenie zásob. Preto je nevyhnutné nepretržité monitorovanie každého z týchto parametrov, spolu s reakciou vegetačnej pokrývky na ich zmeny, počas dlhého časového obdobia.

V období intenzívnej rekultivácie môže byť potrebné častejšie monitorovanie, kedy môže byť obmedzujúcim faktorom oblačnosť.

V rámci tohto produktu sa využívajú satelitné dáta Sentinel-2, Landsat-8, GeoEye-1, Worldview-1, 2 a 3, SPOT 6 a 7, Pleiades. Priestorová presnosť produktov závisí od priestorového rozlíšenia vstupných dát, typicky sa pohybuje v rozmedzí 0,5 – 1 pixel. Digitalizácia prebiehajúcej rekultivácie a revegetácie z podkladových snímok do mapových výstupov je vyhotovená v priebehu niekoľkých dní, v závislosti od veľkosti monitorovanej oblasti. Mapové výstupy znázorňujú realizované a plánované kroky rekultivácie; krajinnú pokrývku a jej vývoj v čase; vegetáciu, jej stav, a vývoj (Obr. 9.25).



Obr. 9.25 Multitemporálna klasifikácia krajinnej pokrývky zo satelitných snímok znázorňujúca zmeny v oblasti banskej činnosti a jej okolí v rokoch 2011 – 2015, Carajás region, Brazília. **Fig. 9.25** Multitemporal classification of the land cover from satellite images showing changes in mining area and its surroundings during 2011 – 2015, Carajás region, Brasil. Source: Nascimento et al., 2020

Postupná rekultivácia pôdy

Moderný prístup k udržateľnému rozvoju spočíva v prijatí stratégie postupnej rekultivácie, pri ktorej prevádzkovateľ bane priebežne rekultivuje pôdu. Inými slovami, pôda narušená banskou činnosťou sa postupne vracia do pôvodného stavu alebo do dohodnutého konečného stavu.

Údaje DPZ pomáhajú pri posudzovaní vývoja (v čase) pôdneho krytu a vykonaných rekultivačných krokov prevádzkovateľa bane. Manuálna interpretácia produktov snímkovania umožňuje digitalizovať charakter prebiehajúcich sanačných krokov a čas ich vykonávania. Tento produkt poskytuje kľúčové informácie na preukázanie rekultivácie/obnovy vegetácie banskej lokality do pôvodného stavu.

9.6.1.5. Protected areas

Tento produkt poskytuje prehľad chránených území v záujmovom regióne. Ich zmapovanie a umiestnenie vo vzťahu k potenciálnej ťažobnej lokalite je dôležité v etapách prieskumu, posudzovania a schvaľovania ťažobného cyklu. Produkty ako Natura2000 (chránené územia v Európskej únii), lokalizácia národných parkov, chránených území a kultúrneho dedičstva (t. j. typy chránených území) sú často k dispozícii priamo od národných orgánov. V prípade, že takýto produkt nie je k dispozícii alebo nemá dostatočnú presnosť, umiestnenie chránených oblastí možno získať priamo z produktov optických snímok (za predpokladu spolupráce s odborníkom z oblasti životného prostredia s lokálnymi znalosťami).

Keďže priestorové rozlíšenie hraníc chránených území získaných zo satelitných snímok je relatívne nízke, môže si vyžadovať dodatočné spresnenie v závislosti od potenciálnej oblasti ťažby.

V rámci tohto produktu sa využívajú satelitné dáta z misií Sentinel-2, Landsat-8, GeoEye-1, Worldview-1, 2 a 3, SPOT 6 a 7, Pleiades. Minimálna veľkosť mapovacej jednotky závisí od veľkosti pixela satelitnej snímky vstupujúcej do spracovania – spravidla sa pohybuje medzi 1 – 3 pixelmi. Priestorová presnosť produktov závisí od priestorového rozlíšenia vstupných dát, typicky sa pohybuje v rozmedzí 0,5 – 1 pixel.

Digitalizácia chránených oblastí z podkladových snímok do mapových výstupov je vyhotovená v priebehu niekoľkých dní, v závislosti od rozsahu potenciálnej oblasti ťažby a prítomnosti iných chránených oblastí v blízkosti. Mapové výstupy typicky znázorňujú chránené oblasti v záujmovej oblasti, najčastejšie vo vektorovom formáte (Obr. 9.26).



Obr. 9.26 Mapovanie krajinnej pokrývky v oblasti mokradí so stredným rozlíšením a podrobné mapovanie s vysokým rozlíšením pre posúdenie životného prostredia – region Chaudière-Appalaches, Québec, Kanada.

Fig. 9.26 Land cover mapping in the area of wetlands in medium resolution and detailed mapping in high resolution for environmental assessment – Chaudière-Appalaches region, Québec, Canada.

Source: www.space4ecosystems.com, 2014

9.6.1.6. Stockpile measurement

Z hľadiska riadenia ťažby je nevyhnutné priebežne získavať informácie o zásobách surovín, vyťaženého materiálu, a pod. Tento produkt poskytuje monitorovanie, ktoré pomáha sledovať akékoľvek zmeny v rámci zásob, ako aj určovanie objemov.

Pre tento účel sa najčastejšie používajú satelitné snímky s vysokým rozlíšením, ako napríklad Pléiades. Nové metódy so stereoskopickými a tristereoskopickými snímkami, ktoré sa používajú najmä na výškové modelovanie, teraz uľahčujú vytváranie 3D modelu, ktorý sa používa ako základ pre ďalšie spracovanie. Na základe týchto vstupných údajov sa následne generujú 2 základné modely:

- Digitálny Model Povrchu (DSM)
- Digitálny Model Reliéfu (DEM)

Objem zásob sa potom vypočíta spojením týchto dvoch vstupných modelov a výpočtom rozdielov medzi nimi. Pri porovnávaní modelov z rôznych časových horizontov možno merať aj zmeny objemu. Popri satelitných snímkach sa pre zisťovanie a meranie objemu zásob využívajú aj snímky získané pomocou UAV, nakoľko poskytujú vyššie rozlíšenie a môžu sa získavať s vyššou frekvenciou.

Pre odhadovanie objemu zásob a monitorovanie zmien objemov sa využívajú aj radarové snímky. Monitorovanie objemov zásob sa dá realizovať aj pomocou optických snímok s nízkym rozlíšením využitím metódy "Shape-from-Shading" (Obr. 9.27).

9 Applications of RS – Geologic and Mining Activities



Obr. 9.27 Meranie zásob na základe satelitných snímok s nízkym rozlíšením pomocou metódy "Shape-from-Shading".

Fig. 9.27 Stockpile measurement based on low resolution satellite images using the "Shape-from-Shading" method.

Source: d'Autume et al., 2020

Kvalita poskytovaných produktov a informácií závisí od kvality a rozlíšenia vstupných satelitných snímok. Pri použití voľne dostupných dát je možné získať snímky s rozlíšením 10m/pixel, čo však v niektorých prípadoch môže byť príliš nízke rozlíšenie (v závislosti od rozmerov skladovaných zásob). Navyše, ak je potrebné detailnejšie rozlíšenie viacerých typov materiálov, je nevyhnutné použiť hyperspektrálne dáta.

V rámci tohto produktu sa využívajú satelitné dáta z misií Sentinel-2, Worldview-1, 2 a 3, Pleiades, Pleiades Neo a ICEYE-X2. Priestorová presnosť produktov závisí od priestorového rozlíšenia vstupných dát, typicky sa dosahuje sub-pixelová presnosť. Výstupy sú k dispozícii spravidla do 5 dní od dňa vyhotovenia snímky.

9.6.1.7. Monitoring of tailings ponds and their dams

Tento produkt poskytuje informácie o monitorovaných odkaliskách a ich hrádzach počas ťažby na základe technológie InSAR. Poskytuje merania s presnosťou na mm na veľkých plochách na týždennej a mesačnej báze a môže slúžiť ako nástroj na monitorovanie celej ťažobnej oblasti a jej priameho okolia. V závislosti od použitého satelitu možno získať až 100 000 meraní na km².

Typickými aplikáciami tohto produktu je monitorovanie pohybu pôdy a svahov a vplyvov banskej činnosti na životné prostredie. Výhody spočívajú v tom, že veľké oblasti možno monitorovať pravidelne, plne automatizovane a bez ľudského zásahu (Obr. 9.28).



Obr. 9.28 Metóda inverznej rýchlosti implementovaná pomocou časových radov InSAR umožňuje predpovedať kolaps takmer mesiac pred jeho výskytom. **Fig. 9.28** The method of inverse of velocity implemented by InSAR time series can predict the failure of tailings dam almost one month before the collapse itself. Source: site.tre-altamira.com/showcase/tailing-storage-facilities-tailings-dam-failure/

Pre prevádzkovateľov baní sa zavádzajú výstražné systémy, ktoré sa spustia v prípade, ak pohyb hrádze dosahuje vopred definované prahové hodnoty, resp. keď je ohrozená nadzemná infraštruktúra. To umožňuje zasiahnuť skôr, ako dôjde k potenciálnej nehode (Obr. 9.29).

V rámci tohto produktu sa využívajú satelitné dáta z misií Sentinel-2, TerraSAR-X, RadarSat-2, COSMO-SkyMed a ICEYE-X2. Priestorová presnosť závisí na rozlíšení použitého satelitu. Meranie môže byť lokalizované na sub-pixelovej úrovni, s pravidla v rozsahu 1 – 5 metrov. Deformácie, resp. pohyb hrádze môže byť stanovený s presnosťou približne 1 mm / rok. V závislosti od typu satelitu sa doba opakovanej observácie pohybuje od 1 dňa po 24 dní. Doba doručenia výsledného produktu sa opäť v závislosti od použitého satelitu, poskytovateľa služby, a typu aplikácie, pohybuje v rozmedzí 1 - 5 dní.

Produkty sa poskytujú vo forme dát v GIS formátoch, resp. cez webový prehliadač, automatických upozornení z výstražných systémov cez API, resp. e-mail, a vo forme automatizovaných správ v PDF.



Maps Data: Google, ©2020 Maxar Technologies

Obr. 9.29 Satelitné snímky z Google Earth pred (vľavo hore) a po (vpravo dole) kolapse hrádze odkaliska v Brumadinho, Brazília. Priestorová analýza pohybov hrádze z obdobia pred kolapsom odhalila, že pomocou kontinuálneho monitoringu sa tento kolaps dal predpokladať.

Fig. 9.29 Google Earth satellite images before (top left) and after (bottom right) the collapse of a tailings dam in Brumadinho, Brazil. The spatial analysis of the dam's movement from before the collapse revealed that, using continuous monitoring, this collapse could have been predicted. Source: ©Maxar Technologies, www.eurekalert.org

9.6.1.8. Stability of slopes in opencast mining

Poskytuje informácie o stabilite svahov počas povrchovej ťažby na základe technológie InSAR. Poskytuje merania s presnosťou na mm na veľkých plochách na týždennej a mesačnej báze a môže slúžiť ako nástroj na monitorovanie celej ťažobnej oblasti a jej priameho okolia. V závislosti od použitého satelitu možno získať 100 000 meraní na km².

Medzi typické banské aplikácie tohto produktu patrí monitorovanie pohybu pôdy a svahov. Výhody spočívajú v tom, že veľké oblasti možno monitorovať pravidelne, plne automatizovane a bez ľudského zásahu. Pre prevádzkovateľov baní sa zavádzajú výstražné systémy, ktoré sa spustia v prípade, ak pohyb pôdy, resp. svahov, dosahuje vopred definované prahové hodnoty, resp. keď je ohrozená nadzemná infraštruktúra. To umožňuje zasiahnuť skôr ako dôjde k prípadnej nehode (Obr. 9.30), a zároveň lepšie plánovať podporné a ochranné opatrenia.

V rámci tohto produktu sa využívajú satelitné dáta z misií Sentinel-2, TerraSAR-X, RadarSat-2, COSMO-SkyMed a ICEYE-X2. Priestorová presnosť závisí na rozlíšení použitého satelitu. Meranie môže byť lokalizované na sub-pixelovej úrovni, spravidla v rozsahu 1 – 5 metrov. Svahové pohyby môžu byť stanovené s presnosťou približne 1 mm / rok. V závislosti od typu satelitu sa doba opakovanej observácie pohybuje od 1 dňa po 24 dní. Doba doručenia výsledného produktu sa opäť v závislosti od použitého satelitu, poskytovateľa služby, a typu aplikácie, pohybuje v rozmedzí 1 - 5 dní.

Produkty sa poskytujú vo forme dát v GIS formátoch, resp. cez webový prehliadač, automatických upozornení z výstražných systémov cez API, resp. e-mail, a vo forme automatizovaných správ v PDF.



Obr. 9.30 Údaje z InSAR monitoringu zobrazujúce deformácie svahu predchádzajúce jeho kolapsu v povrchovej bani. Fialový polygón vymedzuje oblasť zasiahnutú zrýchľujúcim sa trendom svahových posunov.

Fig. 9.30 InSAR monitoring showing slope deformation before its collapse in an open pit mine. The purple polygon indicates the area affected by the accelerating trend of slope movement. Source: Carlà et al., 2019

9.6.2. Other examples of using RS data for monitoring mining

activities

9.6.2.1. Detection, monitoring and mapping of illegal surface mining

Ťažba takzvaných "konfliktných minerálov" často súvisí s nelegálnou ťažbou na malom území. Táto činnosť sa najčastejšie vyskytuje v husto zalesnených oblastiach Afriky a Južnej Ameriky, ktoré sú často odľahlé, ťažko prístupné a nebezpečné pre priamu kontrolu v teréne. S cieľom zlepšiť zisťovanie a monitorovanie týchto ťažobných činností sa využívajú údaje z DPZ. To si však vyžaduje vysokú frekvenciu získavania snímok kvôli premiestňovaniu ťažobných lokalít a na kompenzáciu celoročnej vysokej oblačnosti, najmä pri vyhodnocovaní optických snímok.

Na zisťovanie malých ťažobných oblastí s minimálnou rozlohou približne 0,5 km² sa používajú voľne dostupné optické snímky so stredným rozlíšením Sentinel-2 a Landsat-8, ako aj údaje SAR Sentinel-1. Metódy DPZ umožňujú robustnú multi-temporálnu detekciu ťažobných objektov, monitorovanie priestorových a časových presunov ťažobných objektov, a zmeny prostredia (Obr. 9.31 a Obr. 9.32). Keďže sa generujú kvalitatívne a kvantitatívne porovnateľné výsledky, sledovaný prístup zisťovania zmien je objektívny a transparentný a môže posunúť proces monitorovania a prípadného legalizovania tejto činnosti dopredu. Osobitný dôraz sa kladie na využitie senzorov z európskeho programu pozorovania Zeme Copernicus.



Obr. 9.31 Mapovanie nelegálnej banskej činnosti medzi rokmi 2015 až 2017 – Ghana, Afrika. (a) – (c) satelitné snímky z Google Earth a príslušné zmeny v dôsledku banskej činnosti na základe vizuálnej interpretácie; (d) – (i) spracovanie radarových snímok Sentinel-1 vo VV polarizácii a z nich detegované zmeny v dôsledku banskej činnosti.

Fig. 9.31 Mapping illegal mining activities between 2015 and 2017 - Ghana, Africa. (a) - (c) Google Earth satellite imagery and relevant changes due to mining activity based on visual interpretation; (d) - (i) processing of Sentinel-1 radar images in VV polarization and corresponding changes due to mining activity.

Source: Forkuor, Ullmann and Griesbeck, 2020



Obr. 9.32 Mapovanie nelegálnej banskej činnosti – región Kivu, Demokratická Republika Kongo, Afrika. Zľava – NDVI snímka Sentinel-2, RGB snímka Sentinel-2, CIR snímka SPOT 7, SWIR-NIR-RED snímka Landsat-8, radarová snímka vo VV polarizácia Sentinel-1.

Fig. 9.32 Mapping illegal mining activities – Kivu region, Democratic Republic of Kongo, Africa. From the left – NDVI image Sentinel-2, RGB image Sentinel-2, CIR image SPOT 7, SWIR-NIR-RED image Landsat-8, radar image in VV polarisation Sentinel-1.

Source: bgr.bund.de/EN/Themen/GG_Fernerkundung/Projekte/abgeschlossen/

9 Applications of RS – Geologic and Mining Activities

9.6.2.2. Delineation of the surface mining areas based on multispectral imagery

V posledných desaťročiach sa monitorovanie priestorových zmien banských oblastí a ich rastu stalo bežným postupom v snahe pochopiť vplyv banskej činnosti na priľahlé typy využitia pôdy/krajinnej pokrývky. V súčasnosti existujú rôzne prípadové štúdie zamerané na mapovanie pôdnej pokrývky v krajinách známych pre banskú činnosť. Zdôrazňuje sa v nich, že rozhodujúci je rýchly, ako aj presný prístup.

Účinný spôsob dosiahnutia primeraného environmentálneho riadenia banských oblastí si vyžaduje integráciu metód DPZ a geografických informačných systémov. Diaľkový prieskum poskytuje základy analýzy obrazu, zatiaľ čo geografický informačný systém ponúka nástroje na analýzu priestorových údajov a geovizualizáciu. Ak sa tieto prvky využívajú vhodným spôsobom, potom môže priebežné monitorovanie banskej činnosti a zmien hraníc ťažobnej oblasti viesť k účinnej rekultivácii po ukončení ťažby. Navyše, voľne dostupné údaje a softvér s otvoreným zdrojovým kódom to výrazne uľahčujú. Cieľom je vždy vyvinúť komplexnú a zároveň rýchlu metodiku na identifikáciu ťažobných oblastí a presné vymedzenie ich hraníc (Obr. 9.33).





Fig. 9.33 Delineation of the boundaries of the active part of an open-pit lignite mine based on Sentinel-2 satellite imagery - Amyntaio, Greece. Source: Kotaridis and Lazaridou, 2021

9.6.2.3. Mapping of surface sources of acid mine drainage

Kyslé banské vody (*Acid Mine Drainage - AMD*) vznikajú, keď sulfidické minerály (pyrit a markazit) pochádzajúce z ťažby uhlia alebo rudných ložísk sú oxidované vodou v prítomnosti kyslíka za vzniku kyslého roztoku. Vzniknuté AMD sa vyznačujú nízkymi hodnotami pH, vysokými koncentráciami síranov a celkového množstva rozpustených pevných látok a zvýšenými koncentráciami ťažkých kovov, ako sú železo, hliník a mangán. Zvýšené koncentrácie týchto látok vo vodných zdrojoch spôsobujú zhoršenie kvality vody, nepriaznivo ovplyvňujú vodné organizmy a predstavujú vážne zdravotné problémy pre ľudí a zvieratá. Zdroje AMD siahajú od povrchovo odkrytých zdrojov (banské odvaly, odkaliská, nakladacie priestory uhlia) až po zdroje uložené v podpovrchových vrstvách (uhoľné rudy). Potenciálne zdroje AMD v podpovrchových vrstvách sú zvyčajne zbavené kyslíka (kľúčovej zložky pri tvorbe AMD), a preto predstavujú malé riziko ako zdroje AMD.

Opustené bane a banské odkaliská môžu spôsobovať dlhodobé environmentálne problémy, ako napríklad AMD a uvoľňovanie ťažkých kovov do životného prostredia. AMD sa uvoľňuje z (podzemných) baní a banských odkalisiek, keď sú sulfidické minerály vystavené pôsobeniu vody a kyslíka a oxidujú sa. Pri tomto oxidačnom procese vzniká kyselina sírová, ktorá rozpúšťa ťažké kovy, ako sú Cu, Zn a As, v hornine a spôsobuje, že banská voda je toxická a kyslá. Výsledná AMD môže mať celý rad negatívnych účinkov najmä na vodnú flóru a faunu. Keď sa pH kyslej drenážnej vody zvýši, napr. zriedením s nekyslou povrchovou alebo podzemnou vodou, vedie to k vyzrážaniu minerálov železa, ako sú sírany železa, hydroxidy železa a oxidy železa. Hromadenie týchto zrazenín spôsobuje výrazné červené sfarbenie pôdy a hornín v okolí odvodnenia AMD (Obr. 9.34).





Fig. 9.34 Typical colouring of soil and rocks in the vicinity of mine drainage due to AMD - Malý Šobov, Banská Štiavnica, Slovakia.

Source: Michalková, Máša and Svitok, 2009

Keďže niektoré z najbežnejších vyzrážaných minerálov spojených s AMD majú charakteristické vlastnosti odrazivosti v jednotlivých spektrálnych pásmach, tak DPZ môže byť účinnou metódou na identifikáciu, mapovanie a monitorovanie lokalít opustených baní a banských odkalisiek a s tým spojenými kyslými vodami. DPZ takto môže dopĺňať konvenčné metódy (prostredníctvom chemickej analýzy vzoriek pôdy/vody), pretože získané výsledky môže aplikovať do regionálnejšieho kontextu a poskytnúť lepší prehľad o množstvách, zdrojoch a smeroch týchto vôd.

Ako už bolo uvedené (pozri Kapitola 9.1 a 9.2), na diaľkový prieskum minerálov sa najčastejšie používajú multispektrálne snímky, napríklad z družice ASTER, a hyperspektrálne snímky, napríklad Hyperion, keďže tieto družice obsahujú pásma v krátkovlnnej infračervenej časti spektra (SWIR). Pásma SWIR sú obzvlášť užitočné na rozlišovanie alterovaných minerálov, ako sú minerály spojené s AMD, ktoré majú len malé spektrálne rozdiely v oblasti od viditeľného po blízke infračervené žiarenie (VNIR). Priestorové rozlíšenie údajov ASTER a Hyperion je 30 m (15 m pre pásma ASTER VNIR), čo môže spôsobiť, že je náročné zistiť rôzne prvky v menšom rozsahu. Na získanie vyššieho priestorového rozlíšenia sa zvyčajne používa letecký diaľkový prieskum z pilotovaných lietadiel a UAV. Od Augusta 2014 sú však k dispozícii snímky aj z družice WorldView-3, ktorá obsahuje 8 pásiem VNIR s priestorovým rozlíšením 2 m a 8 pásiem SWIR s priestorovým rozlíšením 7,5 m, čo predstavuje výrazné zlepšenie priestorového aj spektrálneho rozlíšenia v porovnaní s údajmi ASTER, a preto je vhodná na rozlišovanie rôznych minerálov aj v menšej mierke.

Na získanie spektrálnych vlastností z multispektrálnych údajov existuje viacero analytických techník. Ak chýbajú in situ údaje (napr. z terénnych meraní), tak na zvýraznenie určitých spektrálnych vlastností je možné použiť základné minerálne indexy alebo jednoduché pomery spektrálnych pásiem. Okrem toho sa na zvýraznenie spektrálnych rozdielov môžu použiť techniky ako napr. analýza hlavných komponentov (principal component analysis - PCA). Ak sú však k dispozícii údaje in situ a sú známe spektrálne krivky sledovaných minerálov, na zistenie a zmapovanie pravdepodobnosti prítomnosti určitých minerálov sa môžu použiť techniky ako napr. Spectral Angle Mapping (SAM), Spectral Feature Fitting (SFF) alebo Spectral Mixture Analysis (SMA).

Jedným z používaných minerálnych indexov pre identifikáciu hydroxidov železa zo so snímok WordView-3 je napr.:

$$\mathbf{Index}_{iron\ hydroxides} = \left(\frac{SWIR3}{SWIR7}\right) \left(\frac{SWIR3}{SWIR1}\right)$$
(9.1)

Ďalej sa tiež využívajú jednoduché pomery VNIR a SWIR pásiem, napríklad VNIR8/VNIR6, alebo SWIR1/SWIR3. Aj takéto jednoduché pomery môžu v kombinácii s dobre zvolenými prahovými hodnotami poskytnúť dobrý prehľad o lokalitách s pravdepodobným obsahom železitých minerálov spojených s AMD (Obr. 9.35 a Obr. 9.36).



Obr. 9.35 VNIR snímka zo satelitu WorldView-3, červenou farbou znázornený výsledok VNIR8/VNIR6 s prahovou hodnotou 0.9.

Fig. 9.35 VNIR image from WorldView-3, VNIR8/VNIR6 result in red colour with a 0.9 threshold. *Source: Davids, 2018*



Obr. 9.36 SWIR snímka zo satelitu WorldView-3, červenou farbou znázornený výsledok SWIRI/SWIR3 s prahovou hodnotou 0.75. **Fig. 9.36** SWIR image from WorldView-3, with SWIRI/SWIR3 result in red colour with a threshold of 0.75.

Source: Davids, 2018

Pre väčšie monitorované oblasti, kde sa dajú využiť aj satelitné snímky s nižším priestorovým rozlíšením, je možné využiť aj voľne dostupné snímky Sentinel-2. Práve Red Edge (B6) pásmo Sentinelu-2 má veľmi podobný spektrálny rozsah ako VNIR6 pásmo WordView-3, v ktorom majú železité minerály jednoznačne identifikovateľný charakteristický priebeh (Obr. 9.37).

Najvhodnejšou metódou pre detekciu a mapovanie AMD je však kombinácia údajov z VNIR a SWIR pásiem, s použitím pokročilých metód spracovania dát ako SAM, resp. SMA.

395000 393000 394000 3307000 3306000 3305000 B C ★ Rock Sample \star Water Sample 6<pH<8 (Goethite-Hematite) 3<pH<6 (Jarosite-Goethite) **2**<pH<5 (Jarosite-Clay)

Obr. 9.37 Klasifikačná mapa pre potenciálne kyslé banské vody na základe obsahu sekundárnych minerálov železa pomocou Spectral Angle Mapper a na základe Seninel-2.

Fig. 9.37 Classification map for potentially acidic mine drainage based on secondary iron mineral content using Spectral Angle Mapper and based on Seninel-2. Source: Seifi et al., 2019

References

Books

Paolo Tarolli and Simon Marius Mudd (2020). Remote sensing of geomorphology. Amsterdam, Netherlands: Elsevier. 398p. ISBN 978-0-444-64177-9

Feranec, J. a kolektív, 2010. Slovensko očami satelitov. 1st ed. Bratislava: VEDA, vydavateľstvo Slovenskej akadémie vied. 263p. ISBN 978-80-224-1105-9

Gupta, R.P. (2018). Remote sensing geology. Berlin, Germany: Springer-Verlag. 438p. ISBN 978-3-662-55876-8

Lillesand, T.M., Kiefer, R.W. and Chipman, J.W. (2015). Remote sensing and image interpretation. Hoboken, N.J.: John Wiley & Sons, Inc. 770p. ISBN 978-1-118-34328-9

Pu, R. (2017). Hyperspectral remote sensing: fundamentals and practices. Boca Raton Etc.: Crc Press/Taylor & Francis Group, Cop. 491p. ISBN 978-1-4987-3159-1

Papers, manuals, reports

Smith, K.S., Phillips, J.D., McCafferty, A.E., and Clark, R.N., eds., 2016, Developing integrated methods to address complex resource and environmental issues: U.S. Geological Survey Circular 1413, 160 p., http://dx.doi.org/10.3133/cir1413

Núñez, J., Farmer, J., Sellar, R., Swayze, G. and Blaney, D., 2014. Science Applications of a Multispectral Microscopic Imager for the Astrobiological Exploration of Mars. Astrobiology, 14(2), pp.132-169. DOI: 10.1089/ast.2013.1079

Krupnik, D. and Khan, S. (2017). Hydrocarbon microseepage-related geobotanical analysis in and around oil fields. The Leading Edge, 36(1), pp.12–23. DOI: 10.1190/tle36010012.1

Shebl, A., Abdellatif, M., Elkhateeb, S.O. and Csámer, Á. (2021). Multisource Data Analysis for Gold Potentiality Mapping of Atalla Area and Its Environs, Central Eastern Desert, Egypt. Minerals, 11(6), p.641. DOI: 10.3390/min11060641

Wu, C., Li, X., Chen, W. and Li, X. (2019). A Review of Geological Applications of High-Spatial-Resolution Remote Sensing Data. Journal of Circuits, Systems and Computers, 29(06), p.2030006. DOI: 10.1142/s0218126620300068

Zoheir, B., Emam, A., Abdel-Wahed, M. and Soliman, N. (2019). Multispectral and Radar Data for the Setting of Gold Mineralization in the South Eastern Desert, Egypt. Remote Sensing, 11(12), p.1450. DOI: 10.3390/rs11121450

van der Meer, F.D., van der Werff, H.M.A. and van Ruitenbeek, F.J.A. (2014). Potential of ESA's Sentinel-2 for geological applications. Remote Sensing of Environment, 148, pp.124–133. DOI: 10.1016/j.rse.2014.03.022.

Nascimento, F.S., Gastauer, M., Souza-Filho, P.W.M., Nascimento, W.R., Santos, D.C. and Costa, M.F. (2020). Land Cover Changes in Open-Cast Mining Complexes Based on High-Resolution Remote Sensing Data. Remote Sensing, 12(4), p.611. DOI: 10.3390/rs12040611

www.space4ecosystems.com (2014). Geospatial Ecosystem Service Assessment and Valuation. Innsbruck, Austria: GeoVille Information Systems and Data Processing GmbH, p.16

Carlà, T., Intrieri, E., Raspini, F., Bardi, F., Farina, P., Ferretti, A., Colombo, D., Novali, F. and Casagli, N. (2019). Perspectives on the prediction of catastrophic slope failures from satellite InSAR. Scientific Reports, 9(1). DOI: 10.1038/s41598-019-50792-y

Forkuor, G., Ullmann, T. and Griesbeck, M. (2020). Mapping and Monitoring Small-Scale Mining Activities in Ghana using Sentinel-1 Time Series (2015–2019). Remote Sensing, 12(6), p.911. DOI: 10.3390/rs12060911

Kotaridis, I. and Lazaridou, M. (2021). Delineation of Open-Pit Mining Boundaries on Multispectral Imagery. In: Remote Sensing. London, United Kingdom: IntechOpen Limited, p.15. DOI: 10.5772/intechopen.87829

Michalková, E., Máša, B. and Svitok, M. (2009). Kyslé banské výtoky z haldy pyritizovaného kvarcitu na lokalite Banská Štiavnica - Malý Šobov. Acta Facultatis Ecologiae, 21, pp.15–24

Davids, C. (2018). Mapping of abandoned mine tailings and acid mine drainage using in situ hyperspectral measurements and WorldView-3 satellite imagery. Tromsø, Norway: Norut - Northern Research Institute, p.16. ISBN: 978-82-7492-418-5

Siler, D. L., Faulds, J. E., Hinz, N. H., Dering, G. M., Edwards, J. H., & Mayhew, B. (2019). Three-dimensional geologic mapping to assess geothermal potential: examples from Nevada and Oregon. Geothermal Energy, 7(1). DOI: 10.1186/s40517-018-0117-0

Thomas, A., Edwards, S., Engels, J., Mccormack, H., Hopkins, V., & Holley, R. (2019). Earth observation data and satellite InSAR for the remote monitoring of tailings storage facilities: a case study of Cadia Mine, Australia.

Proceedings of the 22nd International Conference on Paste, Thickened and Filtered Tailings. Australian Centre for Geomechanics, Perth, pp. 183-195. DOI: 10.36487/acg_rep/1910_11_thomas

d'Autume, M., Perry, A., Morel, J.-M. ., Meinhardt-Llopis, E., & Facciolo, G. (2020). STOCKPILE MONITORING USING LINEAR SHAPE-FROM-SHADING ON PLANETSCOPE IMAGERY. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, V-2-2020, 427–434. DOI: 10.5194/isprs-annals-v-2-2020-427-2020

Seifi, A., Hosseinjanizadeh, M., Ranjbar, H., & Honarmand, M. (2019). Identification of Acid Mine Drainage Potential Using Sentinel 2a Imagery and Field Data. Mine Water and the Environment, 38(4), 707–717. DOI: 10.1007/s10230-019-00632-2

Web sources

https://www.grsg.org.uk/

https://earsc-portal.eu/display/EO4RawMaterials

https://eitrawmaterials.eu/

https://www.usgs.gov/ - USGS High Resolution Spectral Library

https://www.esa.int/ESA_Multimedia

10

Applications of RS -Forestry

Forests contribute to ecosystem services differently depending on the economic and ecological environment. Boreal and peat forests regulate the climate ecologically through their large underground carbon stocks, while tropical forests contain almost all the carbon above ground. Socioeconomically, in dry tropical forests with relatively dense populations of poor people dependent on forests, forests contribute substantially to livelihood needs such as firewood and fodder for livestock. In temperate forests, the recreational value of forests for populations with disposable income for tourism or the need to protect watersheds of large urban centres becomes more important. This heterogeneity in services and pressures on forests creates different monitoring needs in different parts of the world.

Data from RS can play an important role in planning for and responding to wildfires on forest lands. Such data and derived products on tree cover, species, and volume/biomass estimates can be used to input spatially explicit fire load models. Once a wildfire becomes active, imagery acquired near real-time can be critical to fire management and control efforts.

Many of the applications of RS in agriculture are also relevant to forest. For example, multispectral or hyperspectral imagery can be used to detect stress in tree leaves associated with insect or pathogen populations, nutrient imbalances, impacts from herbivores and other wildlife, environmental degradation (due to ozone, acid deposition, smog, and other factors), and meteorological conditions (moisture stress, drought, and storms).

This chapter is devoted to general knowledge on forest management and EO data for forestry purposes. Areas with the most frequent use of EO include forest fires, pest infestation, drought, storm damage, deforestation, and phenological changes. A large part of the chapter is devoted to mapping forest fires and deforestation. It also includes information on current global projects to support forest management.

·eesa い

FBERG

10.1. Introduction

Lesy v rôznych častiach sveta prispievajú k ekosystémovým službám rozdielne v závislosti od ekonomického a ekologického prostredia. Napríklad z ekologického hľadiska regulujú boreálne a rašelinové lesy klímu prostredníctvom svojich veľkých zásob podzemného uhlíka, zatiaľ čo tropické lesy obsahujú takmer všetok uhlík nad zemou. Zo socioekonomického hľadiska napríklad v suchých tropických lesoch s relatívne hustou populáciou chudobných ľudí závislých od lesov lesy podstatne prispievajú k potrebám živobytia, ako je palivové drevo a krmivo pre dobytok. V lesoch mierneho pásma naberá na význame rekreačná hodnota lesov pre obyvateľstvo s disponibilným príjmom pre cestovný ruch alebo potreba ochrany povodí veľkých mestských centier. Táto heterogenita v službách a tlaky na lesy vytvárajú rôzne potreby monitorovania v rôznych častiach sveta.

Najstaršie aplikácie diaľkového prieskumu Zeme v lesnom hospodárstve sa zameriavali na vizuálnu interpretáciu obrazu, čo naďalej zohráva dôležitú úlohu v mnohých lesníckych činnostiach, najmä pri inventarizácii lesov, obhospodarovaní porastov a plánovaní lesných prác. V posledných rokoch však technologický pokrok viedol k výrazne zvýšenej úlohe analýzy digitálneho obrazu a počítačovej extrakcie informácií z údajov snímaných na diaľku.

Proces interpretácie vizuálneho obrazu pri identifikácii druhov stromov je vo všeobecnosti zložitejší ako pri identifikácii poľnohospodárskych plodín. Danú oblasť lesnej pôdy často zaberá komplexná zmes mnohých druhov stromov, na rozdiel od poľnohospodárskej pôdy, kde sa zvyčajne vyskytujú veľké, relatívne jednotné polia. Lesníkov môže zaujímať aj druhové zloženie "lesného podrastu", ktorý na leteckých a satelitných snímkach býva často zakrytý korunami veľkých stromov.

Druhy stromov možno identifikovať na leteckých a satelitných snímkach prostredníctvom procesu eliminácie. Prvým krokom je eliminovať tie druhy, ktorých prítomnosť v oblasti je nemožná alebo nepravdepodobná kvôli polohe, fyziografii alebo podnebiu. Druhým krokom je zistiť, ktoré skupiny druhov sa v danej oblasti vyskytujú, na základe znalosti spoločných druhových asociácií a ich požiadaviek. Záverečnou fázou je identifikácia jednotlivých drevín pomocou základných princípov interpretácie obrázkov.

Pri identifikácii druhov stromov sa používajú charakteristiky obrazu, ako je tvar, veľkosť, vzor, tieň, tón a textúra. Jednotlivé dreviny majú svoj charakteristický tvar a veľkosť koruny. Niektoré druhy majú zaoblené koruny, niektoré majú koruny v tvare kužeľa a niektoré v tvare hviezdy, pričom sa vyskytujú aj variácie týchto základných tvarov (Obr. 10.1). V hustých porastoch vytvára usporiadanie korún stromov vzor, ktorý je pre mnohé druhy odlišný. Keď sú stromy izolované, tiene často poskytujú profilový obraz stromov, ktorý je užitočný pri identifikácii druhov. Tón snímky závisí od mnohých faktorov a vo všeobecnosti nie je možné korelovať absolútne tónové hodnoty s jednotlivými druhmi stromov. Relatívne tóny na jednej snímky alebo skupine snímok môžu mať veľkú hodnotu pri vymedzovaní susedných porastov rôznych druhov. Zmeny v štruktúre koruny sú dôležité pri identifikácii druhov. Niektoré druhy majú chumáčovitý vzhľad, iné sa zdajú byť hladké a ďalšie sú nafúknuté. Textúra snímky je veľmi závislá od mierky, takže texturálne charakteristiky daného druhu sa budú líšiť pri pohľade na jednotlivé koruny alebo súvislú lesnú pokrývku.



Obr. 10.1 Rôzne typy a tvary koruny stromov. **Fig. 10.1** Different types and shapes of tree crowns. Source: after Cherrick, 2019

Proces identifikácie druhov stromov pomocou vizuálnej interpretácie obrazu nie je taký jednoduchý, ako by sa mohlo zdať. Tento proces je najjednoduchší pri práci s čistými, rovnomerne starými porastmi. Za iných podmienok môže byť identifikácia druhov rovnako umením ako vedou. Vizuálna identifikácia druhov stromov môže byť vysoko úspešná ak ju robí skúsený vyhodnocovateľ. Zároveň sú však v rámci procesu interpretácie a zostavovania mapového výstupu prakticky vždy nevyhnutné aj terénne dáta.

Vytvoriť jednotný kľúč pre vizuálnu interpretáciu pre identifikáciu druhov stromov je náročné, pretože vzhľad jednotlivých porastov sa značne líši v závislosti od veku, podmienok lokality, geografickej polohy, geomorfného prostredia a iných faktorov. V súčasnosti existuje viacero eliminačných kľúčov, ktoré sa ukázali ako vhodné interpretačné nástroje, ak ich používajú skúsení vyhodnocovatelia.

Zmeny vo vzhľade stromov v rôznych ročných obdobiach niekedy umožňujú rozlišovanie medzi druhmi, ktoré sú nerozoznateľné počas krátkeho obdobia, resp. v rámci jednej snímky. Typickým príkladom je segmentácia listnatých opadavých a vždyzelených stromov, ktorá sa dá ľahko realizovať na jarných snímkach získaných krátko po pučaní listov alebo na jesenných snímkach získaných po sfarbení listnatých stromov. Napríklad snímky z letného obdobia panchromatické, resp. v pravých farbách, vykazujú iba malý rozdiel v tóne medzi listnatými a vždyzelenými stromami (Obr. 10.2). Na letných farebných infračervených CIR snímkach sú však rozdiely v odtieňoch vo všeobecnosti výraznejšie (Obr. 10.2).



Obr. 10.2 Rozdiely v tónovom podaní listnatých a vždyzelených stromoch na RGB snímke (vľavo) a CIR snímke (vpravo) – Veľká Fatra, Slovensko.

Fig. 10.2 Differences in tonal rendition of deciduous and evergreen trees in RGB image (left) and CIR image (right) – Veľká Fatra, Slovakia.

Source: Copernicus Sentinel data [2021]. Retrieved from Copernicus SciHub [30/12/2021], processed by FBERG TUKE

Na jarných snímkach môžu zase rozdiely v čase kedy sa rôzne druhy stromov zazelenajú poskytnúť dobrý nástroj na rozpoznávanie individuálnych druhov. Napríklad osika a breza patria pravidelne medzi prvé stromy, ktoré sa zazelenajú, zatiaľ čo duby alebo jasene patria medzi posledné. Tieto dve skupiny je teda možné rozlíšiť na snímkach získaných krátko po zazelenaní sa osiky a brezy. Tónové rozdiely medzi listnatými stromami s tvrdým drevom, ktoré sú v lete malé, sú naopak výraznejšie na jeseň, keď lístie niektorých druhov zožltne a iné sa sfarbí do červena alebo hneda (Obr. 10.2).

Vizuálna interpretácia snímok sa vo veľkej miere využíva aj pri "inventarizácii porastu". Primárnym cieľom takejto inventarizácie je určiť objem dreva, ktorý by bolo možné vyťažiť z jednotlivého stromu alebo (častejšie) z porastu stromov. Aby bola inventarizácia založená na snímkach úspešná, vyžaduje si vysokokvalifikovaného vyhodnocovateľa, ktorý pracuje so satelitnými a pozemnými (terénnymi) údajmi. Obrazové merania na jednotlivých stromoch alebo porastoch štatisticky súvisia s terénnymi meraniami objemu stromov na vybraných plochách. Výsledky sa potom extrapolujú na veľké oblasti. Najčastejšie sa vizuálna interpretácia vykonáva pre:

- 1. výška stromu alebo výška porastu,
- 2. priemer koruny stromov,
- 3. hustota porastu,
- 4. plocha porastu.

Vývoj a využitie digitálneho spracovania obrazu v lesníctve v niektorých smeroch kopíruje historický vývoj metód vizuálnej interpretácie obrazu. Diaľkovo snímané multispektrálne (alebo hyperspektrálne) snímky možno klasifikovať do širokých skupín druhov pomocou spektrálnych alebo objektovo založených klasifikačných metód. Dodatočné informácie – napríklad použitie starostlivo zvolených multitemporálnych snímok na využitie fenologických zmien v spektrálnych vlastnostiach klenby korún – môžu umožniť spoľahlivejšiu identifikáciu jednotlivých druhov stromov. Kombinácia optických snímok s inými typmi údajov DPZ, ako sú radarové snímky alebo priestorové dáta z LIDAR-u, môže tiež zlepšiť presnosť a/alebo špecifickosť klasifikácie lesných typov.

Najmä LIDAR zohráva čoraz dôležitejšiu úlohu v aplikáciách od inventarizácie lesov až po riadenie lesníckych činností. Analýza mračna bodov a dát z LIDAR-u môže poskytnúť oveľa viac informácií o štruktúre jednotlivých stromov a porastov. Produkcia topografických údajov, či už z fotogrametrie, radarovej interferometrie alebo LIDAR-u prispieva k logistike lesného hospodárstva vrátane výstavby ciest, plánovania ťažby, modelovania rizika a reakcie na požiar, riadenia povodí a kontroly erózie, a rekreácie.

Údaje z DPZ môžu zohrávať významnú úlohu pri plánovaní a reakcii na lesné požiare na lesných pozemkoch. Takéto údaje a odvodené produkty o stromovej pokrývke, druhoch a odhadoch objemu/biomasy možno použiť ako vstupy do priestorovo explicitných modelov pre zaťaženie požiarom. Akonáhle sa lesný požiar stane aktívnym, snímky získané takmer v reálnom čase môžu byť rozhodujúce pre snahu o kontrolu požiaru.

Mnohé z aplikácií DPZ v poľnohospodárstve sú relevantné aj pre lesné zdroje. Napríklad multispektrálne alebo hyperspektrálne snímky možno použiť na detekciu stresu v listoch stromov spojeného s výskytom hmyzu alebo patogénov, nerovnováhou živín, vplyvmi bylinožravcov a iných voľne žijúcich živočíchov, degradáciou životného prostredia (v dôsledku ozónu, usadzovania kyselín, smogu a iných faktorov) a meteorologické podmienky (vlhkostný stres, sucho a búrky).

10.2. RS in forest management

Lesy pokrývajú približne 30 % zemského povrchu, zohrávajú významnú úlohu v klimatickom systéme a sú neoddeliteľnou súčasťou mnohých ekosystémových, kultúrnych a ekonomických služieb (Obr. 10.3). Preto existuje značný záujem o trvalo udržateľné hospodárenie s cieľom zachovať lesné zdroje a zároveň vyvážiť rôzne konkurenčné záujmy o ich využívanie.



Fig. 10.3 Forest functions for ecosystem, economy, and culture. Source: after Thenkabail et al., 2019

Obhospodarovanie lesov môže byť definované ako "aplikácia biologických, fyzikálnych, kvantitatívnych, manažérskych, ekonomických, sociálnych a politických princípov na obnovu, obhospodarovanie, využívanie a ochranu lesov s cieľom dosiahnuť stanovené ciele a zámery pri zachovaní produktivity lesa. V praxi to často znamená nejaký druh lesnej praxe, ochranárskej činnosti alebo lesnej regulácie.

Vzhľadom na veľkú a často odľahlú pôdu pokrytú lesmi sa technológie DPZ vo veľkej miere prijali ako súčasť portfólia operatívneho obhospodarovania lesov, najmä na monitorovanie polohy, typu a množstva lesov, ako aj ich zmien v priebehu času. V blízkej minulosti bolo používanie DPZ na obhospodarovanie lesov z veľkej časti riadené leteckým snímkovaním a multispektrálnymi satelitnými snímkami (ako napr. Landsat alebo SPOT) a (postupne aj) LIDAR-om. V súčasnosti nám technológia hyperspektrálneho snímkovania môže umožniť rozšíriť spôsoby charakterizácie pomocou DPZ, aby sme vedeli charakterizovať druhy a biodiverzitu, zdravie a stav lesa, štruktúru porastu, hrozby (napríklad stres alebo invázne druhy) a funkciu lesného ekosystému. Napriek mnohým potenciálnym výhodám tejto technológie je však použitie hyperspektrálnych snímok na prevádzkové aplikácie lesného hospodárstva extrémne práce bola V oblasti vedeckého obmedzené. Väčšina výskumu alebo pilotných/demonštračných štúdií, ukazujú ktoré potenciálnu hodnotu hyperspektrálnych údajov pri ochrane, monitorovaní a inventarizácii lesov. Neochota praktizujúcich lesných hospodárov prijať hyperspektrálne diaľkové snímanie vo veľkom meradle pramení z (1) veľkosti a zložitosti súborov hyperspektrálnych údajov a lesných ekosystémov a (2) nedostatku opakovaných hyperspektrálnych pozorovaní pre veľké regióny (inými slovami nedostatok dostupných satelitných údajov).

10.2.1. Complexity of forest ecosystems

Viacero faktorov ovplyvňuje odrazivosť vegetácie a sťažuje analýzu dát z DPZ. Patrí medzi nich napr. fenológia, slnečné žiarenie, geometria osvetlenia, vlastnosti pôdy, režim živín, hydrológia a spektrálne podobnosti medzi viacerými druhmi. Zároveň už bolo preukázané, že prirodzená variabilita odrazivosti v rámci druhov v kombinácii so spektrálnymi podobnosťami medzi druhmi spôsobila, že niektoré druhy sú pri analýze odrazivosti nerozoznateľné. Analýza lesných ekosystémov je tak isto sťažená vysoko variabilnými trojrozmernými štruktúrami, najmä v klenbe zmiešaného lesa (Obr. 10.4). Lesy majú často komplexné horizontálne a vertikálne kombinácie rôznych druhov (spôsobujúce vrstvenie v lesnej klenbe), komplexnú architektúru v korunách, premenlivú výšku a biomasu, a druhovú a medzidruhovú variabilitu v listovej ploche a v biochémii listov. Variabilita v morfológii listov a biochémii listov je tak isto charakteristická v rámci jednej lesnej klenby, najmä medzi listami ožiarenými slnkom v hornej časti a zatienenými listami pod klenbou. Zložitá architektúra klenby, najmä veľkosť a umiestnenie medzier, tiež ovplyvňuje svetelný režim a môže ovplyvniť rýchlosť fotosyntézy a absorpciu svetla.



Obr. 10.4 Komplexné zloženie koruny lesného porastu - premenlivé druhy, výška koruny a vrstvenie v zmiešanom lese.

Fig. 10.4 Complex composition of the forest canopy - variable species, canopy height and layering in the mixed forest.

Source: mapio.net

Pri analýze údajov z DPZ môže byť prirodzená heterogenita lesného ekosystému ďalej zväčšená pomocou rozlíšenia pixelov na senzore. Ak je veľkosť pixelu väčšia ako veľkosť koruny jedného stromu, signál z odrazu môže obsahovať zmiešané efekty z odrazu tieňa, z odrazu bez listov alebo kombinácie druhov. Z toho dôvodu bol výskum v minulosti orientovaný aj na modelovanie odrazivosti klenby, v snahe kvantifikovať alebo odstrániť časť z odrazeného signálu prislúchajúcu nelistovej ploche. Dôležitým bol aj výskum geometrického modelovania, ktorý predpokladá, že les pozostáva z viacerých objektov s kvantifikovateľnými rozmermi, tvarmi a usporiadaním. Najjednoduchší z týchto modelov, pôvodne vyvinutý pre klenbu plodín, je navrhnutý tak, aby simuloval vplyv tieňa na odrazivosť pokrývky, pričom sa vyčísľuje časť vegetácie, pôdy a ich zatienené časti.

Zložitejšie modely kombinujú štrukturálnu geometriu klenby a princípy radiačného prenosu v korunách, ako napríklad model geometrického opticko-žiarivého prenosu (geometric optical-radiative transfer model - GORT). Tieto modely, označované ako hybridné modely prenosu žiarenia, sa použili na charakterizáciu štruktúry pokrývky a biochémie listov v rôznych heterogénnych lesných prostrediach.

Ďalším prístupom k priamej charakterizácii/meraniu heterogenity klenby lesa je spojenie LIDAR-u s hyperspektrálnymi údajmi, čo preukázateľne poskytuje lepšie informácie o štruktúre klenby (lidar), biochémii (hyperspektrálne dáta), a funkcii (ich spojenie). Ukázalo sa, že LIDAR je ideálna technológia pre charakterizáciu štruktúry pokrývky, vrátane výšky, tvaru koruny, plochy listov, biomasy a základnej plochy. Na rozdiel od hyperspektrálnej technológie bol LIDAR vo viacerých krajinách akceptovaný ako technológia pri inventarizácii lesov. Spojenie LIDAR-u a hyperspektrálnych dát zlepšilo schopnosť charakterizovať štruktúru a biochemické premenné a poskytlo podstatné informácie o druhoch, biodiverzite a funkcii lesných ekosystémov.

10.3. Use of RS in Forestry

Lesné ekosystémy majú veľký sociálno-ekonomický a ekologický význam, ale sú čoraz viac ohrozené – biotickými aj abiotickými činiteľmi. Žiaľ, v dôsledku prebiehajúcej zmeny klímy sa predpokladá, že frekvencia a intenzita negatívnych zmien sa v blízkej budúcnosti ešte zvýši.

Vďaka zozbieraným informáciám bolo možné popísať výhody a obmedzenia rôznych techník diaľkového prieskumu Zeme a navrhnúť stratégie a odporúčania pre efektívne využitie údajov o pozorovaní Zeme na európskej úrovni pre šesť vysoko relevantných hrozieb:

- Lesné požiare
- Zamorenie škodcami
- Suchá
- Škody spôsobené búrkou
- Odlesňovanie / nelegálna ťažba dreva
- Fenologické zmeny

10.3.1. Forest fires

Lesné požiare patria medzi najčastejšie narušenia lesných ekosystémov (Obr. 10.5). S pokračujúcou zmenou klímy sa predpokladá, že požiare budú čoraz častejšie a intenzívnejšie a že obdobia požiarov sa predĺžia.

Aby sa predišlo vznieteniu a aby sa znížil dopad lesných požiarov, monitorovacie systémy založené na EO by mali riešiť tri fázy: pred požiarom (pred požiarom), počas požiaru (aktívny) a po požiari (po požiari). Vo všetkých fázach môže diaľkové snímanie podporovať manažment lesných požiarov. Obzvlášť vhodné sú optické snímače.


Obr. 10.5 RGB snímka v nepravých farbách z družice Sentinel-2 zachytávajúca lesný požiar v Kalifornii, USA, v Decembri 2017. Aktívne požiare sú zobrazené oranžovou a spálená plocha hnedou farbou.

Fig. 10.5 A false-colour RGB image from the Sentinel-2 satellite showing a forest fire in California, USA, in December 2017. Active fires are shown in orange and burned area in brown. Source: climate.nasa.gov/news/2892/through-smoke-and-fire-nasa-searches-for-answers

Na zníženie rizika vznietenia sú poznatky o typoch palív (t. j. o druhoch stromov) a ich podmienkach mimoriadne informatívne. Tieto informácie možno ľahko odvodiť z optických súborov údajov zo Sentinel-2 v kombinácii s vhodnými informáciami o počasí a informáciami o štruktúre lesa (napr. distribúcia veľkosti medzier a vertikálna štruktúra lesa). Štrukturálne informácie by sa mali aktualizovať v pravidelných intervaloch (napríklad každých 3 až 5 rokov) a prípadne by mali vychádzať z údajov LiDAR.

Počas aktívnej požiarnej fázy by mali byť lesníci v ideálnom prípade podporovaní termovíziou. V súčasnosti nie sú vhodné EO senzory pre túto úlohu dobre prispôsobené na menšie lesné požiare. Budúce satelity Copernicus by v ideálnom prípade mali mať aspoň jeden tepelný senzor s priestorovým rozlíšením 50 m s 5-dňovým časom opätovného navštívenia, aby sa táto medzera vyriešila. Medzitým by sa v súčasnosti dostupné tepelné senzory s hrubým rozlíšením (a geostacionárne) mali ďalej využívať na hodnotenie požiarov a sucha vo veľkom meradle.

Po požiaroch je v prvom kroku potrebné opísať, čo zostalo z lesa, pretože to ovplyvňuje fázu obnovy. Tieto informácie by potom mali byť doplnené informáciami o intenzite požiaru a nakoniec monitorovaním obnovy vegetácie.

10.3.2. Pest infestation

Lesy sú náchylné na škodcov a choroby. K veľkým stratám lesa dochádzalo v minulosti napadnutím podkôrnym hmyzom, ale aj hubovými patogénmi a ich hmyzími prenášačmi. Hoci je predácia stromov pôvodnými organizmami prirodzená, rovnováhu môžu narušiť nevhodné lesné lesné postupy a ešte viac ju umocniť zmena klímy. Oba faktory môžu výrazne zvýšiť predispozíciu lesov k zdravotným problémom. V skutočnosti väčšina väčších ohnísk podkôrneho hmyzu nasleduje po predošlých rušeniach spôsobených suchom alebo požiarmi a je ďalej podporovaná veľkými, rovnomerne starými a neprispôsobenými monokultúrami (Obr. 10.6).



Obr. 10.6 Pozemný (A a B) a letecký pohľad (C a D) na lesný porast vo Vysokých Tatrách, Slovensko, zasiahnutý podkôrnym hmyzom. Fig. 10.6 Ground (A and B) and aerial view (C and D) of a forest stand in the High Tatras, Slovakia, affected by bark beetles. Source: Nikolov et al., 2014

10.3.3. Droughts

Suchá možno ľahko monitorovať pomocou existujúcich vesmírnych prostriedkov (Obr. 10.7). Keďže suchá sú udalosti v mezo-rozsahu s pomalým nástupom a dlhým trvaním, požiadavky na údaje z hľadiska priestorového rozlíšenia sú relatívne skromné.

Na zobrazenie priestorového rozsahu a závažnosti sucha sú dostupné rôzne techniky – využívajúce celý rad rôznych senzorov a metód. Zo štyroch všeobecných typov sucha môžu satelitné senzory obzvlášť dobre riešiť meteorologické, hydrologické a poľnohospodárske suchá. Keďže lesy sú často hlboko zakorenené v pôde, len málokedy postačuje čistý popis meteorologických podmienok (napr. nedostatok zrážok). Vysoké neistoty sú zvyčajne spojené aj so získavaním pôdnej vlhkosti pomocou aktívnych a pasívnych mikrovĺn v dôsledku vysokého vegetačného pokrytia a nízkeho pomeru signálu k šumu. Z tohto dôvodu sú pozorovania vegetačných pomerov v optickej oblasti (napr. hodnotenie takzvaného ,poľnohospodárskeho sucha') zvyčajne najprínosnejšie. Pomerne vhodné sú aj metódy (často založené na geostacionárnych senzoroch), ktoré hodnotia vodnú bilanciu, napr. kombináciou strát evapotranspiráciou s údajmi o zrážkach. Takéto prístupy by profitovali z tepelných senzorov s vyšším rozlíšením, ktoré v súčasnosti nie sú k dispozícii. Odporúča sa uplatňovať takéto prístupy a kombinovať ich s informáciami o vlnách horúčav.



Obr. 10.7 Snímky družice Sentinel-2 zobrazujúce vplyv sucha na lesný porast a vodné plochy v Kalifornii, USA v Júni 2020 (vľavo) a 2021 (vpravo).

Fig. 10.7 Sentinel-2 images showing the impact of drought on forest cover and water bodies in California, USA in June 2020 (left) and 2021 (right).

Source: contains modified Copernicus Sentinel data (2020-2021), processed by ESA, CC BY-SA 3.0 IGO

10.3.4. Damage caused by storms

Búrky a vysokorýchlostné nárazy vetra spôsobujú vážne škody v lesných ekosystémoch. Škody sa pohybujú od vetrolamov (na jednom strome) až po veľké veterné vrhy zasahujúce stovky hektárov (Obr. 10.8). Keďže ponuka dreva sa môže po veľkých udalostiach výrazne zvýšiť, často je narušený celý hodnotový reťazec. Lesy, ktoré nie sú dobre prispôsobené miestnym podmienkam, sú obzvlášť zraniteľné. Keďže sa predpokladá, že podmienky na lokalite sa v dôsledku zmeny klímy zmenia, v niektorých regiónoch je potrebná konverzia lesov, aby sa budúce lesy lepšie prispôsobili tejto rastúcej hrozbe.

K dispozícii sú dobre zavedené techniky EO na mapovanie súčasného rozšírenia druhov stromov, ako aj oblastí zasiahnutých búrkou. Podrobné informácie o druhoch drevín s jemným rozlíšením sú povinné na modelovanie náchylnosti lesných porastov na klimatické riziká – súčasné aj predpokladané – a na posúdenie ekonomických škôd a potenciálnych vplyvov na hodnotový reťazec.

Detekcia vetrom vyžaduje údaje s vysokým priestorovým rozlíšením. Ak majú byť nárazy vetra detegované včas, sú potrebné senzory s vysokou frekvenciou opakovaných návštev. Sentinel-1 (mikrovlnná) aj Sentinel-2 (optická) sa na túto úlohu dobre hodia a odporúča sa integrovať oba systémy pre vyššiu mieru detekcie a schopnosť za každého počasia. Vždy, keď je to možné, by sa mali zahrnúť snímky s veľmi vysokým rozlíšením (VHR) od komerčných poskytovateľov snímok. Odporúča sa vytvoriť takýto európsky monitorovací systém.



Obr. 10.8 Mapy úrovní poškodenia lesného porastu spôsobeného hurikánom Katarína v USA v Auguste 2005. (a) úroveň poškodenia podľa USDA Forest Service, (b) celková mapa poškodenia, (c) úrovne poškodenia, (d) úroveň 1, (e) úroveň 2, (f) úroveň 3.

Fig. 10.8 Maps of forest damage levels caused by Hurricane Katrina in the USA in August 2005. (a) USDA Forest Service damage levels, (b) overall damage map, (c) damage levels, (d) level 1, (e) level 2, (f) level 3.

Source: Wang et al., 2010

10.3.5. Deforestation / illegal logging

Nelegálna ťažba dreva a postupné odlesňovanie krajiny sú najrozšírenejšia v tropických krajinách. Odlesňovanie je však aktuálnym problémom aj vo viacerých Európskych krajinách, vrátane Slovenska (Obr. 10.9).

Tak isto, kvôli regionálnym pomerom spojených s korupciou v krajinách ako Brazília sú dôležité lesné ekosystémy ako Amazónia po rokoch zlepšovania manažmentu a ochrany prírodných zdrojov opäť pod obrovským tlakom (Obr. 10.10).

Prax nezákonnej ťažby má za následok výrazné narušenie biodiverzity lesov a pôdy, môže poškodiť zvyšné stromy a znížiť ukladanie uhlíka. Nevyhnutná infraštruktúra (napr. cesty a paluby) otvára medzery v korunách a výsledné okraje lesov sú náchylnejšie na požiare, suchá a iné nepokoje, okrem využitia na poľnohospodárske aktivity.

Techniky EO využívajúce optické (Sentinel-2) aj mikrovlnné senzory (Sentinel-1) preukázali vynikajúcu schopnosť detegovať ťažbu lesa. Rozlíšenie medzi legálnou a nelegálnou ťažbou si však vyžaduje informácie o koncesii lesa a stave ochrany daného lesného porastu. Tieto informácie musia byť poskytnuté zo zdrojov iných ako EO. Na odhalenie nezákonnej ťažby sa odporúča zabezpečiť, aby sa záznamy o ťažbe v rámci Európy uchovávali presne a aktuálne. Týmto spôsobom je možné (post-hoc) rozlíšiť medzi legálnou a nelegálnou ťažbou.



Obr. 10.9 Zmeny stavu lesného porastu v Tichej Doline, Slovensko od roku 1949 do roku 2018. **Fig. 10.9** Changes in forest cover in Ticha Dolina, Slovakia from 1949 to 2018. Source: dennikn.sk/2507453/letecke-mapy-ukazuju-miznuce-tatry-aj-to-ako-clovek-opustilkrajinu



Obr. 10.10 Odlesňovanie prebiehajúce v Amazonskom pralese 1989/2019. **Fig. 10.10** Deforestation in the Amazon rainforest 1989/2019. Source: Source Imagery courtesy of The European Space Agency (ESA)

Vo všeobecnosti sa väčšie poruchy ľahšie detegujú v porovnaní s výrubom jednotlivých stromov – ten sa v súčasnosti najlepšie rieši pomocou komerčných súborov údajov VHR s priestorovým rozlíšením od metra k sub-metru. Na odhaľovanie nelegálnej ťažby je vhodná aj takzvaná spektrálna analýza zmesí (SMA), pretože každá ťažba vedie k zvýšeniu podielu tieňa v strešnej zóne porastu, čo je dobre detekovateľné pomocou SMA. K dispozícii je niekoľko ďalších alternatívnych techník, ako sú metódy detekcie zmien založené na prahových hodnotách (mikrovlnných aj optických).

Hlavnou technickou výzvou je požadovaná krátka latencia, ak má exekutíva použiť informácie na zabránenie ďalšiemu zaznamenávaniu. Odporúča sa zriadiť európsky monitorovací systém so zameraním na menšie poruchy a prípadne aplikovať súborné prístupy, ktoré kombinujú informácie niekoľkých slabých študentov do jedného robustného indikátora. Keďže monitorovanie veterných vývratov a odhaľovanie nelegálnej ťažby využíva mnoho podobných metód a súborov údajov, odporúča sa integrovať obe poruchy do jedného spoločného monitorovacieho systému, ktorý najskôr a vopred zisťuje zmeny lesnej pokrývky – ale nie nevyhnutne priamo pôvodcu vedúceho k strate. lesnej pokrývky.

10.3.6. Phenological changes

Posuny vo fenologickom vývoji lesov – a druhov, ktoré tvoria lesné ekosystémy – môžu potenciálne ohroziť druhy so synchronizovanými životnými cyklami a môžu vyvolať posuny v distribúcii druhov a vhodnosti určitých lokalít pre konkrétne druhy drevín. Monitorovanie lesnej fenológie navyše poskytuje cenné poznatky o vplyve klimatických zmien.

EO môže poskytnúť cenné informácie o fenológii lesa v akomkoľvek požadovanom priestorovom detaile prostredníctvom meraní napr. načasovanie začiatku vegetácie a starnutia (napr. začiatok jari/jesene) (Obr. 10.11). Diaľkovo odvodené informácie dopĺňajú pozorovania in-situ, ktoré sú podľa definície presnejšie a zaznamenávajú skutočné štádiá fenologického vývoja, ale sú obmedzené na niekoľko miest.

Preskúmanie zdôraznilo potenciál optických satelitov EO, ako je Sentinel-2 (a v menšej miere Sentinel-3) pre takýto monitorovací systém zemskej povrchovej fenológie (LSP). Keďže však tieto satelity boli vypustené len nedávno, odporúča sa spätná kalibrácia na produkty odvodené od MODIS/Landsat. Potrebné algoritmy extrakcie LSP sú dobre vyvinuté a možno ich ľahko nasadiť. Odporúča sa zriadiť európsky monitorovací systém LSP, ktorý bude stavať na bohatých informáciách poskytovaných existujúcimi sieťami insitu, čím sa využije doplnkový charakter oboch pozorovacích systémov. Hlavnou technickou výzvou je správne predbežné spracovanie veľkých údajov na odstránenie šumu zo súborov údajov EO a prepojenie ukazovateľov LSP s vývojovými štádiami fenológie rastlín.



Obr. 10.11 Fenologické zmeny v lesnom poraste na základe optických satelitných snímok. **Fig. 10.11** Phenological changes in forest vegetation based on optical satellite images. Source: Helman, 2018

10.4. Mapping forest fires

Zvyšujúce sa riziko požiarov v dôsledku zmeny klímy si vyžiadalo zvýšenie informovanosti na podporu činností v oblasti zmierňovania, reakcie a obnovy zo strany agentúr a organizácií zaoberajúcich sa lesnými požiarmi. Následne je potrebné neustále prehodnocovať dostupné a najaktuálnejšie informácie a technológie.

Požiare spôsobujú rozsiahle ničenie prirodzených ekosystémov lesa, čo vedie k ekologickej, ekonomickej a spoločenskej degradácii. Vo viacerých krajinách pochádza veľká väčšina lesných požiarov z ľudskej činnosti, ako je ťažba dreva, premena pôdy, poľnohospodárstvo a sociálno-ekonomické konflikty týkajúce sa využívania pôdy a vlastníckych práv (Obr. 10.12). V posledných rokoch však rozšírené podmienky sucha, nadmerného využívania na komerčné účely a konverzie na iné využitie pôdy viedli k značnému nárastu veľkosti, frekvencie a súvisiacich environmentálnych vplyvov. Vzhľadom na častú absenciu kvalitných štatistických údajov o veľkosti lesných požiarov a celkovej zasiahnutej ploche nie je možné presne odhadnúť rozsah ničenia spôsobeného lesnými požiarmi. Nedávne pokroky v technológiách DPZ umožnili prekonať tieto obmedzenia nákladovo efektívnym a včasným spôsobom poskytnutím hĺbkového prehľadu o dynamike odozvy v lesných ekosystémoch. Schopnosť odhaľovať, monitorovať, posudzovať a predpovedať požiare v globálnom, regionálnom a lokálnom meradle sa tak výrazne zlepšila.



Source: after Gitas, 2015

Lesné požiare majú dôležitý význam vo viacerých krajinách sveta, ktoré často čelia pretrvávajúcim environmentálnym problémom vrátane straty biodiverzity, rastúcej urbanizácie do prírodného prostredia a rastúceho rizika požiarov. Lesné požiare sú neoddeliteľnou súčasťou ekosystémových procesov týchto lesov a významným faktorom narušenia prírodného prostredia. Ovplyvňujú zmeny ekosystémov, druhovú diverzitu, môžu zvýšiť fragmentáciu biotopov a zmeniť fungovanie krajiny.

Údaje z DPZ môžu pomôcť pri riadení požiaru v troch fázach v súvislosti s výskytom požiaru vrátane (Obr. 10.13) (1) pred požiarom (opatrenia týkajúce sa nebezpečného / potenciálneho paliva, čas od posledného horenia) na pomoc pri prevencii alebo minimalizácii činností, (2) počas požiaru (detekcia a lokalizácia aktívnych oblastí požiaru takmer v reálnom čase) a (3) po požiari (mapovanie a hodnotenie spálených oblastí). ktoré môžu byť potenciálne monitorované termálnymi senzormi na satelitoch alebo palubách lietadiel.



Obr. 10.13 Využitie DPZ v rôznych fázach lesného požiaru. **Fig. 10.13** Use of remote sensing data in various stages of forest fire. Source: after Gitas, 2015

Ako je už známe z časti o EMŽ (pozri Kapitola 2), tak energia odrazená a rozptýlená objektami a povrchmi umiestnenými na zemskom povrchu má jedinečné vlastnosti. Tieto spektrálne znaky nám umožňujú skúmať širokú škálu objektov a procesov na zemskom povrchu. Pre štúdium lesných požiarov využívajú nástroje optického DPZ viditeľné a infračervené spektrálne pásma zo senzorov s vysokým rozlíšením. Blízke infračervené, stredné infračervené a termálne pásma sú citlivé na zmeny v zdravotnom stave vegetácie. Často sa používajú na presné vyhodnotenie požiarom zasiahnutých oblastí a závažnosti spálenia na podporu činností lesného hospodárstva. Zelená, zdravá vegetácia odráža žiarenie v blízkej infračervenej (NIR) oblasti; pohlcuje červené svetlo vo viditeľnej časti elektromagnetického spektra. Na rozdiel od toho, spálené oblasti postihnuté požiarom odrážajú viac energie vo krátkovlnnej infračervenej (SWIR) oblasti, zatiaľ čo pohlcujú energiu v NIR oblasti (Obr. 10.14).



Obr. 10.14 Spektrálne vlastnosti pôdy, zdravej vegetácie a spálenej pôdy. **Fig. 10.14** Spectral signatures of soil, healthy vegetation and burned areas. Source: modified from USDA Forest Service, RSAC

Pre posúdenie závažnosti a rozsahu lesných požiarov sa používa niekoľko indikátorov.

Normalizovaný Pomer Spálenia NBR (*Normalized Burn Ratio*) je index, ktorý sa používa na meranie závažnosti spálenia rozlišovaním oblastí, ktoré boli výrazne zmenené vo svojej spektrálnej odrazivosti po požiari. Počíta sa pomocou hodnôt odrazivosti z pásiem vlnových dĺžok NIR a SWIR. Vzorec pre NBR je podobný ako Normalizovaný Diferenčný Vegetačný Index (NDVI), pričom NBR využíva pomer medzi pásmami NIR a SWIR. Vysoké hodnoty NBR odrážajú oblasti pokryté zdravou vegetáciou, zatiaľ čo nízke hodnoty označujú holú zem a nedávno spálené oblasti.

Pre snímky Sentinel-2 sa NBR určí podľa:

$$\mathbf{NBR} = \frac{(NIR - SWIR)}{(NIR + SWIR)} = \frac{(B8 - B12)}{(B8 + B12)}$$
(10.1)

Závažnosť spálenia (*Burn Severity*) je termín používaný na vyjadrenie miery, do akej je ekosystém ovplyvnený požiarom. Odhaduje sa ako rozdiel medzi hodnotami NBR pred požiarom a po požiari, odvodenými zo satelitných snímok. Na identifikáciu nedávno spálených oblastí a ich odlíšenie od holej pôdy a iných oblastí bez vegetácie sa často používa rozdiel medzi NBR pred požiarom a po požiari, známy aj ako **delta Normalizovaný Pomer Spálenia** (**dNBR**). Oblasti s vysokou hodnotou dNBR zodpovedajú vyššiemu stupňu poškodenia alebo závažnosti spálenia. Na rozdiel od toho, nízke hodnoty dNBR predstavujú oblasti, ktoré nie sú ovplyvnené požiarom, alebo oblasti, ktoré sa prejavili opätovným rastom vegetácie po požiari:

$$dNBR = NBR_{before fire} - NBR_{after fire}$$
(10.2)

Na praktické monitorovanie požiarov sú v princípe potrebné dve satelitné snímky tej istej oblasti. Snímka získaná časovo najbližšie k požiaru sa označuje ako hlavná (master) snímka a tá druhá ako podriadená (slave) snímka. Výpočtom NBR pre hlavnú a podriadenú snímku potom možno analyzovať vplyv požiarov na dané územie. Na základe rozdielu medzi hlavnou snímkou NBR a podriadenou snímkou NBR (dNBR) možno určiť celkovú spálenú plochu požiaru a možno vymedziť oblasti silne zasiahnuté požiarmi. Každú nasledujúcu podriadenú snímku možno použiť na vytvorenie mapy po požiari v rôznych časových intervaloch od prvej mapy požiaru (hlavnej) a monitorovať postup obnovy skúmaním reakcie lesnej vegetácie po požiari.

10.4.1. Identification of the burned area

Po spracovaní dvoch satelitných snímok teda máme dve NBR pásma, z ktorých jedno zodpovedá dátumu pred požiarom a druhé po požiari. Na identifikáciu spálených oblastí je potom možné vypočítať dNBR ako rozdiel NBR pred požiarom a NBR po požiari. dNBR je však absolútnou mierou zmeny, ktorá môže viesť k problémom v oblastiach s nízkou vegetačnou pokrývkou pred požiarom, kde bude výsledný rozdiel zanedbateľný. Aby sme sa vyhli takýmto problémom, používa sa **Relativizovaný Pomer Spálenia RBR** (*Relativized Burn Ratio*):

$$\mathbf{RBR} = \frac{dNBR}{NBR_{pred\ po\check{z}iarom} + 1.001}$$
(10.3)

Po výpočte RBR je možné použiť ďalšie nástroje na identifikáciu nedávno spálených oblastí vytvorením nového pásma, ktoré bude obsahovať len pixely, ktoré majú hodnoty RBR nad určenou prahovou hodnotou. Zmena hodnôt RBR, ktorá je mierou používanou na hodnotenie spálenej plochy, potom môže byť vizualizovaná vykreslením pásma RBR napr. v prostredí GIS pomocou vhodnej farebnej škály a mierky.

10.4.2. Burn severity classification

Ďalším cieľom pri analýze lesných požiarov je klasifikovať oblasti, ktoré sú spálené, na základe veľkosti zmeny hodnôt RBR medzi obdobím pred požiarom a obdobím po požiari (Obr. 10.15). Klasifikácia závažnosti spálenia môže slúžiť ako základný nástroj pri pomoci v núdzových situáciách a pri hodnotení vývoja obnovy vegetácie po požiari. Organizácia United States Geological Survey (USGS) navrhla klasifikačnú tabuľku na interpretáciu závažnosti spálenia:

aroe, an option of g				
		Burn severity	dNBR	dNBR
		Zvýšený opätovný rast, vysoký (po požiari)	-500 až -251	-0.500 až -0.251
		Zvýšený opätovný rast, nízky (po požiari)	-250 až -101	-0.250 až -0.101
		nespálené	-100 až +99	-0.100 až +0.990
		Nízka závažnosť	+100 až +269	+0.100 až +0.269
		Nízka-stredná závažnosť	+270 až +439	+0.270 až +0.439
		Stredná-vysoká závažnosť	+440 až +659	+0.440 až +0.659
		Vysoká závažnosť	+660 až +1300	+0.660 až +1.300

Tab. 10.1 Klasifikačná tabuľka závažnosti spálenia krajiny podľa USGS. **Tab. 10.1** USGS Landscape Burn Severity Classification Table.

Source: un-spider.org





Fig. 10.15 Classified relativized burn ratio from Sentinel-2 images after a forest fire in Central Italy in 2017.

Source: De Simone et al., 2020

10.4.3. Estimation of the total area burned

Po klasifikácii je možné RBR ďalej spracovať tak, aby sa vytvorilo nové pásmo obsahujúce pixely zodpovedajúce spáleniu s nízkou závažnosťou a viac. Na základe toho možno vypočítať celkovú spálenú plochu ako plochu reprezentovanú všetkými pixelmi vynásobenú rozlíšením v horizontálnej (zemepisná dĺžka) a vertikálnej (zemepisná šírka) osi. Výpočet celkovej spálenej plochy bude teda vyjadrený ako:

burned area
$$(m^2) = pixels_{RBR>0.1} * X_{resolution} (m) * Y_{resolution} (m)$$
 (10.4)

Satelitné snímky poskytujú vhodný zdroj pre monitorovanie rozsiahlych požiarov. V posledných rokoch zvýšená dostupnosť údajov z optických satelitov so stredným až vysokým priestorovým rozlíšením z misií DPZ umožnila vykonávať podrobné vyhodnotenie rizika požiaru, mapovanie aktívnych požiarov a vyhodnotenie spáleného územia po požiari. Techniky DPZ a ich následná analýza v prostredí GIS môžu poskytnúť

zásadný pohľad na vplyv požiarov na lesné ekosystémy. To má významné dôsledky pre efektívne monitorovanie, plánovanie a potenciálny manažment prevencie rozsiahlych lesných požiarov na celom svete.

10.5. Global Wildfire Information System

Globálny informačný systém o lesných požiaroch GWIS (Global Wildfire Information System) je spoločnou iniciatívou Skupiny pre pozorovania Zeme (GEO), aplikovaného výskumu NASA a pracovných programov EÚ Copernicus. Pomocou pokročilých metód spracovania údajov na detekciu a monitorovanie lesných požiarov, numerických modelov predpovede počasia a diaľkového prieskumu Zeme umožňuje GWIS vylepšenú prevenciu lesných požiarov, pripravenosť a efektivitu v manažmente lesných požiarov. Podporuje ho vedecká komunita a vesmírne agentúry prostredníctvom implementačného tímu Global Observation of Forest Cover Fire, národných výskumných centier a univerzít. Okrem toho GWIS poskytuje prvú globálnu databázu udalostí súvisiacich s lesnými požiarmi na nepretržitý časový rámec (medzi rokmi 2001-2019), čo umožňuje analýzu režimov lesných požiarov na celom svete a poskytuje základ pre hodnotenie potenciálnych účinkov zmeny klímy.

Údaje a služby sú ľahko dostupné cez užívateľské webové rozhranie, ktoré umožňuje analýzu údajov, vizualizáciu a prístup na stiahnutie na portáli GWIS (<u>https://gwis.jrc.ec.europa.eu/</u>) (Obr. 10.16).



Obr. 10.16 Predpoveď požiarneho rizika pre lesné požiare na Slovensku z portálu GWIS pre 19. Augusta 2021. Snímka na základe dát Copernicus EU.

Fig. 10.16 Fire Danger Forecast for wildfires in Slovakia, from the Global Wildfire Information System (GWIS) on 19 August 2021. Image via Copernicus EU. Source: gwis.jrc.ec.europa.eu

GWIS analyzuje vplyv požiarov z hľadiska emisií z požiarov, poškodenia infraštruktúry a životného prostredia. Skladá sa z niekoľkých modulov pokrývajúcich rôzne fázy cyklu od pred-požiarnej až po po-požiarnu fázu. V štádiu pred požiarom poskytuje predpoveď nebezpečenstva požiaru až 10 dní pred aktuálnym dátumom, čím podporuje prevenciu a pripravenosť. Počas krízovej alebo havarijnej fázy podporuje hasičské operácie viacnásobnou dennou aktualizáciou informácií o aktívnych požiaroch, rozsahu a priebehu požiaru.

GWIS, jeho nástroje a aplikácie propaguje NASA Applied Remote Sensing Training (ARSET) a Organizácia Food and Agriculture Organization (FAO). Výsledky získané z

aplikácie GWIS a dopadov lesných požiarov sú nevyhnutné pre organizácie OSN, ako je Úrad OSN pre znižovanie rizika katastrof (UNDRR), ako aj pre podporu iných, ako je Program OSN pre životné prostredie (UNEP) a Úrad OSN pre koordináciu humanitárnych záležitostí (OCHA).

Na globálnej úrovni je GWIS nastavený ako jedinečný zdroj podporujúci rozvojové krajiny, ktoré nemusia mať prístup k informáciám o lesných požiaroch na národnej úrovni. Žiaľ, medzi tie, ktoré sú katastrofami najviac postihnuté, patria podľa Rozvojového programu OSN (2018) krajiny so strednými a nízkymi príjmami a rozvojové krajiny. Tento globálny portál s otvorenými údajmi poskytuje potrebné informácie tým krajinám, ktoré to najviac potrebujú.

V novom pracovnom programe GEO GWIS na roky 2020-2022 sa GWIS zameriava na spojenie existujúcich informačných zdrojov na regionálnej a národnej úrovni s cieľom poskytnúť komplexný pohľad a vyhodnotenie požiarnych režimov a účinkov požiarov na globálnej úrovni a poskytnúť nástroje na podporu operačného manažmentu lesných požiarov od národnej až po globálnu úroveň.

GWIS stavia na pokračujúcich aktivitách Európskeho informačného systému o lesných požiaroch (EFFIS), Globálneho pozorovacieho systému Zeme (GTOS), Globálneho pozorovania lesnej pokrývky - Globálneho pozorovania dynamiky krajiny (GOFC-GOLD), Požiarny Implementačný Tím (GOFC Fire IT), a súvisiace regionálne siete, ktoré dopĺňajú existujúce aktivity, ktoré prebiehajú po celom svete v súvislosti so zhromažďovaním informácií o lesných požiaroch. Vývoj GWIS podporujú partnerské organizácie a vesmírne agentúry. Podporu GWIS poskytuje NASA prostredníctvom svojich aktivít GEO-GWIS v programe ROSES.

V súčasnosti sa GWIS skladá z aplikácií:

1. Webový prehliadač aktuálnej situácie

Táto aplikácia poskytuje informácie takmer v reálnom čase o:

- a) predpoveď nebezpečenstva požiaru až 10 dní vopred na základe kanadského indexu požiarneho počasia FWI (Canadian Fire Weather Index),
- b) výskyt bleskov,
- c) aktívna detekcia požiarov zo senzorov NASA MODIS a VIIRS,
- d) plochy spálených oblastí v takmer reálnom čase odvodené z MODIS a VIIRS,
- e) emisie z požiarov zo služby Copernicus CAM Service.

Okrem toho je k dispozícii prístup k statickej globálnej mape požiarneho paliva.

2. Profil krajiny

Táto aplikácia poskytuje historický prehľad požiarnych režimov na úrovni krajiny a regiónov za obdobie rokov 2002-2019. Zahŕňa mapy ročných/mesačných spálených oblastí, frekvenciu spálených oblastí a sezónnosť spálených oblastí. Okrem toho poskytuje viacročné a jednoročné grafy:

- a) Počet požiarov odvodený z GlobFire,
- b) Spálené plochy odvodené z MODIS MCD64A1,
- c) Požiarne režimy (sezónnosť),
- d) Mesačné rozdelenie veľkosti požiaru za rok,

- e) Poškodenie krajinnej pokrývky,
- f) Ročné/mesačné emisie lesných požiarov.

Dáta sú voľne dostupné na stiahnutie vo webovej aplikácii.

3. Dlhodobá predpoveď počasia pri požiari

Mesačná a sezónna predpoveď teplotných a zrážkových anomálií, pri ktorých sa očakáva že budú prevládať vo svete.

4. Dáta a služby

Webová aplikácia poskytujúca prístup k údajom používaným v aplikáciách GWIS. Údaje z Prehliadača aktuálnej situácie sú poskytované vo forme webových mapových služieb (WMS) (Obr. 10.17).



Obr. 10.17 Portál GWIS. **Fig. 10.17** GWIS portal. Source: gwis.jrc.ec.europa.eu

V rámci programu Copernicus EU funguje aj program Európsky Informačný Systém o Lesných Požiaroch EFFIS (European Forest Fire Information System). Tento program podporuje služby zodpovedné za ochranu lesov pred požiarmi v EÚ a susedných krajinách a poskytuje útvarom Európskej komisie a Európskemu parlamentu aktualizované a spoľahlivé informácie o lesných požiaroch v Európe.

Od roku 1998 EFFIS podporuje sieť expertov z krajín v takzvanej Expertnej skupine pre lesné požiare, ktorá je registrovaná pod Generálnym sekretariátom Európskej komisie. V súčasnosti túto skupinu tvoria odborníci zo 43 krajín Európy, Stredného východu a Severnej Afriky. V roku 2015 sa EFFIS stal jednou zo súčastí služieb núdzového manažmentu v programe EU Copernicus. Aplikácia poskytuje prístup k údajom používaným v aplikáciách GWIS. Údaje z Prehliadača aktuálnej situácie sú poskytované vo forme webových mapových služieb (WMS).

10.6. Deforestation / illegal logging

Lesy zaberajú jednu tretinu zemskej masy planéty a pokrývajú takmer 4 miliardy hektárov. Najväčšie zalesnené plochy sa nachádzajú v boreálnych a rovníkových zónach (Obr. 10.18). Toto súčasné rozdelenie nie je fixné, ale v priebehu času sa neustále menilo vplyvom environmentálnych zmien a antropogénnych vplyvov. Jedna tretina súčasných zalesnených oblastí je tvorená lesom, ktorý sa považuje za primárny alebo nedotknutý. Zvyšné dve tretiny sú predmetom antropogénnej činnosti a v dôsledku toho majú neistú budúcnosť.



Obr. 10.18 Svetový lesný porast s hustotou vegetácie >30% v roku 2010. **Fig. 10.18** World tree cover with canopy density >30% in 2010. Source: www.globalforestwatch.org

Každý rok zmizne niekoľko miliónov hektárov lesa a rozsiahle oblasti podliehajú degradácii. Podľa dát z Globaforestwatch.org sa od roku 2001 do roku 2020 celkový svetový lesný porast zmenšil o 10%. Na Slovensku sa lesný porast od roku 2001 do 2020 zmenšil o 9,3% (Obr. 18). Tieto hodnoty nezahŕňajú novovzniknutý lesný porast. Zároveň, tieto úbytky v lesnej ploche nespadajú iba pod odlesňovanie, resp. nelegálnu ťažbu. Na druhej strane, od roku 2001 do 2012 na Slovensku pribudlo 2,2% nového lesa (Obr. 10.19).



Obr. 10.19 Zmeny lesnej plochy na Slovensku od roku 2001 do 2020 (purpurová farba – úbytok; fialová farba – nový les (do 2012)).

Fig. 10.19 Forest cover changes in Slovakia from 2001 to 2020 (magenta colour – loss; purple colour – gain (until 2012)).

Source: www.globalforestwatch.org

Odlesňovanie je v podstate úplné zničenie lesného porastu, pričom jednou z hlavných príčin odlesňovania je premena na poľnohospodársku alebo pastiersku pôdu. Po opustení určitých oblastí sa lesná pokrývka môže opäť rozvinúť, čo vedie k takzvaným sekundárnym lesom. Na rozdiel od odlesňovania je degradácia čiastočným zničením lesného porastu. Je definovaná ako strata schopnosti lesa poskytovať ekosystémové služby (ukladanie uhlíka, lesné produkty, atď.) po antropogénnej činnosti. Degradácia je charakterizovaná rozpadom zalesnených plôch po nezákonnom klčovaní pôdy, nadmernom vyťažení dreva, požiaroch atď. Degradované lesy zahŕňajú veľkú rozmanitosť lesných typov v závislosti od povahy, intenzity a frekvencie degradácie.

Lesy poskytujú rozmanitosť produktov a ekosystémových služieb. Živá biomasa lesov ukladá okolo 3x10¹⁴ kg uhlíka, čo znamená, že hrá dôležitú úlohu pri potenciálnom zmierňovaní klimatických zmien. Lesy tiež predstavujú rezervoár biodiverzity, najmä tropické lesy. Poznať rozsah zalesnených oblastí, stav lesov a to, ako sa menia v priebehu času, je preto obzvlášť dôležité vzhľadom na súčasné environmentálne obavy spojené so zmenou klímy (Obr. 10.20).

Diaľkový prieskum Zeme sa ukázal ako jediný nástroj schopný nepretržite poskytovať spoľahlivé údaje v regionálnom alebo kontinentálnom meradle. Na rozdiel od iných typov využívania pôdy sú lesy typom vegetácie, ktorý je na satelitných snímkach ľahko rozpoznateľný. Napriek nástupu diaľkového prieskumu Zeme v 70. rokoch 20. storočia sú odhady rozlohy lesov a ich zmeny v čase v planetárnom meradle dostupné len od začiatku 21. storočia.



Obr. 10.20 Služby lesných ekosystémov - vzťah komplementarity alebo konkurencie. **Fig. 10.20** Forest ecosystem services – complementarity or competitivity relationship. Source: Lambini et al., 2018

Degradácia lesov spolu s odlesňovaním (Obr. 10.21) sú na druhom mieste po spaľovaní fosílnych palív, pokiaľ ide o prispievanie k emisiám skleníkových plynov; kľúčovou hybnou silou globálnej zmeny klímy. Odlesňovanie, degradácia lesov a požiare rašelinísk predstavovali približne 15% celosvetových antropogénnych emisií oxidu uhličitého (CO₂) v rokoch 1997 až 2006. Hnacie sily a intenzita degradácie sa v jednotlivých regiónoch líšia, ale vplyv straty a degradácie lesov možno pociťovať na všetkých úrovniach, od globálnej zmeny klímy po klesajúcu ekonomickú hodnotu lesných zdrojov a biodiverzity a ohrozené miestne živobytie. Prvoradé je naliehavé a rozhodné opatrenie na obmedzenie rozsahu odlesňovania a degradácie lesov a na podporu zvýšenia zásob uhlíka prostredníctvom regenerácie a zalesňovania, a teda lepšie započítavanie zdrojov a záchytov CO₂.



Degradation 👁 Deforestation

Obr. 10.21 Degradácia lesa a odlesňovanie. **Fig. 10.21** Degradation vs. deforestation. Source: ©Winrock International / winrock.org

Na vyriešenie tohto problému Rámcový dohovor OSN o zmene klímy (UNFCCC) prijal mechanizmus na zníženie emisií z odlesňovania a degradácie lesov a úlohu ochrany, trvalo udržateľného hospodárenia s lesmi a zvyšovania zásob CO₂ v lesoch v rozvojových krajinách (REDD+), čo by poskytlo dodatočné financie na znižovanie emisií. Na implementáciu REDD+ sa od krajín vyžaduje, aby zaviedli národné systémy merania, podávania správ a overovania (Measurement, Reporting and Verification - MRV) v rámci existujúceho alebo novozriadeného národného systému monitorovania lesov, ktorý poskytuje ročné národné odhady zmien zásob a emisií CO $_2$ v lesoch a ktoré sú uvádzané každé dva roky. Odporúčanie Medzivládneho panelu pre zmenu klímy (Intergovernmental Panel on Climate Change - IPCC) je použiť kombináciu údajov z pozorovania Zeme (EO) a terénnych dát na odhad lesnej plochy, zásob CO_2 a ich zmien.

Doplnenie inventarizácie v teréne údajmi z EO umožňuje väčšie plošné pokrytie a znižuje zaťaženie pri terénnom prieskume. Satelitné snímky sa môžu použiť na odhad plôch rôznych tried lesa (vrátane degradovaných a neporušených stavov lesa), pre ktoré možno odhadnúť objem a hustotu biomasy pomocou terénnych meraní. Opakované pozorovania EO aj terénnych údajov umožňujú priebežné hodnotenie zmien v zásobách CO₂ v lesoch. Odhady štruktúry lesa a nadzemnej biomasy je možné realizovať aj pomocou SAR údajov a LiDAR-u. Vhodné satelitné snímky pokrývajúce časový interval aj niekoľkých desaťročí sú k dispozícii v strednom rozlíšení z optických, a v kratšom časovom intervale aj zo SAR senzorov. Tieto údaje umožňujú dlhodobejšie hodnotenie dynamiky lesov v reakcii na antropogénne aj prírodné narušenie lesa. Integrovaný prístup, ktorý kombinuje multi-senzorové údaje EO a údaje in situ, by mohol tvoriť súčasť systematického rámca na monitorovanie zmien lesného porastu a zásob CO₂.

Súčasné prístupy monitorovania pomocou DPZ možno rozdeliť do dvoch hlavných kategórií: (1) zisťovanie degradácie (alebo zástupných ukazovateľov), ktoré by mohli byť súčasťou systému včasného varovania, a (2) kvantifikácia úbytku (alebo prírastku) nadzemnej biomasy, ktorú musia krajiny zahrnúť do svojich správ o emisiách. Požiadavky na údaje DPZ sa môžu líšiť v závislosti od typu degradácie alebo zástupného ukazovateľa, ktorý sa má monitorovať.

10.6.1. What RS data to use for deforestation monitoring?

Satelitné údaje používané na monitorovanie odlesňovania môžu byť dvoch typov. Optické údaje získané vo viditeľnej a infračervenej (IR) vlnovej dĺžke sú citlivé na prevádzkové premenné vegetácie (aktivita chlorofylu, štruktúra a vnútorný obsah vody v listoch). Radarové údaje, získané v oblasti multifrekvencií s dlhšími vlnovými dĺžkami, sú citlivé na štruktúru vegetácie (bazálna plocha, štruktúra porastu a prítomnosť vody).

10.6.1.1. Low- and medium-resolution optical images

Monitorovanie odlesňovania vo svojich začiatkoch využívalo dáta zo série satelitov NOAA (Národný úrad pre oceány a atmosféru) s pokročilým rádiometrom s veľmi vysokým rozlíšením (AVHRR). Tieto snímky sa používali najmä v 80. a 90. rokoch minulého storočia. Rádiometer AVHRR zachytáva žiarenie vo viditeľnej, blízkej IR, strednej IR a tepelnej IR časti spektra s priestorovým rozlíšením 1,1 km a dennou časovou frekvenciou. Tieto dáta s nízkym priestorovým rozlíšením sa používali najmä na vypracovanie regionálnych hodnotení odlesňovania, najmä v brazílskej Amazónii a v strednej Afrike. Koncom 90. rokov 20. storočia sa snímky SPOT-Vegetation s priestorovým rozlíšením zhodným so snímkami NOAA-AVHRR použili na monitorovanie odlesňovania v juhovýchodnej Ázii.

Hlavným obmedzením týchto snímok je ich nízke priestorové rozlíšenie, pretože nemôžu monitorovať plochy menšie ako 1 km² (často je potrebné monitorovať aj výrazne

menšie územia). Preto sa častejšie začali využívať snímky s vyšším rozlíšením, ako napríklad snímky zo senzorov MODIS - TERRA a AQUA (Obr. 10.22). Tieto snímky s rozlíšením 250 m, 500 m alebo 1 km zachytávajúce viditeľnú časť spektra sú k dispozícii bezplatne a sumarizujú sa každých 16 dní. Pri ich spracovaní je navyše možné minimalizovať vplyv oblačnosti.



Obr. 10.22 Optická snímka so stredným rozlíšením zo senzora MODIS z oblasti Rondonia, Brazília. **Fig. 10.22** Medium-resolution optical image from the MODIS spectroradiometer in Rondonia, Brazil.

Source: https://earthobservatory.nasa.gov/world-of-change/deforestation.php

10.6.1.2. High and very high resolution optical images

Od polovice 80. rokov 20. storočia sa údaje Landsat s dvoma MSS (multispectral scanners) a TM (thematic mapper) stali hlavným zdrojom dát používaných na monitorovanie odlesňovania. Vďaka vysokému priestorovému rozlíšeniu (30 - 60 m), dlhej histórii (údaje sa zbierajú od roku 1972) a otvorenému prístupu k 2 miliónom snímok od roku 2009 ide o jedinečný súbor údajov. Napriek tomu majú tieto snímky pri monitorovaní odlesňovania niekoľko obmedzení: obmedzená dostupnosť v prvých desaťročiach (pred rokom 1990), oblačnosť na snímkach bežná v tropických oblastiach, a nízka frekvencia snímok (temporálne rozlíšenie Landsat 7, 8 je 16 dní). Na eliminovanie týchto nedostatkov je možné tieto snímky kombinovať so snímkami Sentinel-2.

Na národnej, regionálnej úrovni sa na monitorovanie odlesňovania a degradácie lesov používajú aj snímky s veľmi vysokým priestorovým rozlíšením (SPOT-6/7 (1,5 m), RapideEye (5 m), Pleiades (0,5 m), GeoEye-1 (0,41 m), a pod.). Tento typ snímok možno použiť napríklad na odhad vplyvu rýchleho nárastu počtu obyvateľov v dôsledku migrácie na vegetáciu. Všetky tieto údaje nie sú zadarmo a vo všeobecnosti platí, že čím jemnejšie rozlíšenie, tým vyššia cena.

Porovnanie rozlíšenia optických snímok s vysokým a veľmi vysokým rozlíšením pre snímky Sentinel-2 a Pleiades je znázornené na Obr. 10.23.



Obr. 10.23 Porovnanie priestorového rozlíšenia v RGB kompozícii pre snímky Sentinel-2. **Fig. 10.23** Comparison of spatial resolution in RGB composition for Sentinel-2 satellite images. Source: Copernicus Sentinel data [2020]. Retrieved from Copernicus SciHub [10/01/2022], processed by FBERG TUKE) and Pleiades (includes material © CNES (2014), Distribution Airbus DS"

10.6.1.3. Radar data

Monitoring odlesňovania pomocou optických satelitných údajov je často veľmi náročný a niekedy nemožný kvôli pretrvávajúcej oblačnosti vo vlhkých tropických oblastiach. Radarové SAR dáta majú vďaka svojej charakteristike "za každého počasia" veľký potenciál na monitorovanie v tropických oblastiach.

Na mapovanie a monitorovanie odlesňovania pomocou radarových snímok sa často používajú dva prístupy:

- 1. prístup založený na intenzite radarového spätného rozptylu;
- 2. prístup zohľadňujúci koherenciu radarových signálov a fázovej zložky.

V druhom prístupe spočíva základný princíp v porovnaní koherencie pred a po dopade signálu na vegetáciu, pričom koherencia je citlivá na stabilitu lesnej vegetácie. Tento prístup je však silne závislý od dostupnosti vhodných snímok.

Spravidla platí, že výkonnosť radarových senzorov pri charakterizovaní lesa sa zvyšuje s vlnovou dĺžkou. Súvisí to so schopnosťou signálu s dlhými vlnovými dĺžkami preniknúť cez koruny stromov a v dôsledku toho lepšie identifikovať stav lesa (hustý/otvorený, neporušený/degradovaný). Vlny v pásme C ($\lambda \sim 5,6$ cm - RADARSAT-2, Sentinel-1) a X ($\lambda \sim$

3,1 cm - TerraSAR-X, COSMO-SkyMed atď.) nemôžu preniknúť hlboko do vegetačného krytu, pretože interagujú s veľkým množstvom zložiek ako sú listy, vetvičky a malé konáre. Vlny v pásme L ($\lambda \sim 23,6$ cm - Advanced Land Observing Satellite (ALOS)/PALSAR) nie sú ovplyvnené jemnou štruktúrou povrchu a umožňujú ľahko rozlíšiť lesy od odlesnených oblastí. Pásmo P ($\lambda \sim 69$ cm) je rovnako prispôsobené na použitie v lesníctve. Porovnanie pásiem X, C a L je znázornené na Obr. 10.24. Budúca vesmírna misia BIOMASS s radarovým senzorom v pásme P umožní nielen rozlíšiť a odhadnúť lesný porast, ale aj odhadnúť biomasu tropických lesov.



Obr. 10.24 Porovnanie SAR pásiem X, C a L na radarovej snímke z oblasti Rondonia, Brazília. **Fig. 10.24** Comparison of X, C and L SAR bands in a radar image from Rondonia, Brazil. Source: Jensen, 2014

10.6.2. Using optical data for monitoring deforestation and forest degradation

Sprístupnenie archívu údajov Landsat US Geological Survey (USGS) v roku 2008 a spustenie nových satelitných misií s politikou otvorených údajov, ako napríklad Sentinel Missions ESA, vytvorili základ pre analýzu časových radov optických satelitných dáta vo vysokom priestorovom a vysokom časovom rozlíšení. Hoci spektrálne pásma Sentinel-2 Multi Spectral Instrument (MSI) a Landsat 8 Operational Land Imager (OLI) nie sú plne kompatibilné z hľadiska rádiometrie, viaceré vedecké výskumy rádiometrickej konzistencie medzi týmito dvoma senzormi odhalili vysokú koreláciu medzi zodpovedajúcimi pásmami. Optické časové rady s vysokým temporálnym rozlíšením umožňujú vývoj nových prístupov k mapovaniu využitia krajiny a krajinnej pokrývky (LULC) a nových metód na zisťovanie dynamických a postupných, ako aj dlhodobých procesov a zmien.

Satelitné systémy, ktoré poskytujú snímky s vysokým temporálnym rozlíšením (1 až niekoľko dní), ako je napr. MODIS, môžu dosiahnuť konzistentné časové pokrytie,

dokonca aj v tropických oblastiach. Avšak kvôli nižšiemu priestorovému rozlíšeniu (250– 500 m) nebudú menšie zmeny identifikovateľné. V súčasnosti však už existuje viacero rôznych algoritmov na detekciu zmien lesa pri použití časových radov optických satelitných snímok so stredným priestorovým rozlíšením. V poslednom desaťročí sa ročné mapovanie odlesňovania a určovanie miery odlesňovania stali funkčnými a pravidelne realizovanými na globálnej a aj národných úrovniach. V porovnaní s odlesňovaním, meranie degradácie lesa alebo opätovného rastu lesa a súvisiacich zmien zásob uhlíka v lesoch je náročnejšie ako samotné sledovanie odlesňovania, pretože monitorovanie degradácie vyžaduje častejšie a lepšie zobrazenie územia a následné spracovanie.

Faktorom výrazne ovplyvňujúcim presnosť detekcie narušenia lesov, najmä v tropických oblastiach, je oblačnosť (Obr. 10.25). Ak sa v časovom rade vyskytnú časové medzery spôsobené napríklad snímkami s výraznou oblačnosťou, tak rýchle zotavenie poškodenej vegetácie môže zakryť príznaky jej poškodenia. Viaceré výskumy využívajúce aj historické niekoľkoročné snímky z misie Landsat bez oblačnosti ukázali, že opätovný rast stromov relatívne rýchlo zamaskuje spektrálne vlastnosti dokonca aj v prípade lesných holorubov. Vyššiu mieru narušenia lesa je teda možné zistiť len pomocou hustého časového radu optických údajov. Husté časové rady sú nevyhnutné pre neustály vývoj monitorovacích systémov takmer v reálnom čase, ako je napríklad Global Forest Watch Humid Tropical Forest Alerts, a môžu poskytnúť veľmi potrebné výstražné informácie o mieste a presnom načasovaní nelegálnych ťažobných činností.



Obr. 10.25 Oblačnosť na optickej satelitnej snímke sťažujúca monitorovanie lesných porastov. **Fig. 10.25** Cloud cover in optical satellite imagery making it difficult to monitor forest stands. Source: Copernicus Sentinel data [2021]. Retrieved from Copernicus SciHub [13/01/2022], processed by FBERG TUKE

Metódy mapovania degradácie lesa a odlesňovania z optických obrazových údajov možno rozdeliť dvoma spôsobmi: po prvé, z hľadiska typu a počtu použitých snímok a po druhé, z hľadiska mapovaných prvkov. Tieto prvky možno mapovať priamo z digitálnych čísel alebo hodnôt povrchovej odrazivosti v jednotlivých pásmach alebo nepriamo prostredníctvom indexov. Bežne používané indexy sú napríklad Normalizovaný Diferenčný Vegetačný Index (NDVI), Normalizovaný Pomer Spálenia (NBR), Vylepšený Vegetačný Index (EVI) a Vegetačný Index Upravený podľa Pôdy (SAVI).

Jednou zo základných metód mapovania je klasifikácia len jednej snímky a jej porovnanie s existujúcou mapou alebo s predpokladom úplného neporušeného lesa. Táto metóda nevykonáva detekciu zmien v striktnom zmysle slova, keďže ide len o jednu snímku DPZ. Dva hlavné prístupy detekcie zmien lesov sú:

klasická detekcia zmien "snímka vs. snímka" - vyžaduje sa aspoň jedna snímka získaná pred a jedna po udalosti odlesnenia/poškodenia, z ktorých prvá musí byť zo začiatku monitorovacieho obdobia a druhá z konca. Tento prístup sa často označuje aj ako "bi-temporálna detekcia zmien" alebo len "detekcia zmien". Takýto prístup sa môže použiť aj dvakrát alebo viackrát, pričom zakaždým sa porovnávajú dve snímky, resp. klasifikácie z nich.

Detekcia zmien založená na analýze časových radov - vyžaduje sériu snímok nasnímaných nepretržite počas určitého časového obdobia. Preto je potrebné podstatne viac, a pravidelných akvizícií snímok oblasti záujmu. Tento prístup sa často označuje jednoducho ako "analýza časových radov".

10.6.2.1. Image vs. Image

Detekcia zmien medzi jednotlivými snímkami je v súčasnosti najčastejšie používanou metódou mapovania degradácie lesov a odlesňovania. Využíva zmenu v odrazivosti v spektrálnych pásmach zemského povrchu medzi snímkami zhotovenými v dvoch rôznych časových obdobiach s cieľom posúdiť zmeny, ktoré nastali medzi týmito dvoma dátumami. Na zisťovanie zmien medzi jednotlivými snímkami je potrebná "maska" definujúca lesnú plochu, aby sa dalo zamerať len na zmeny v týchto oblastiach, pretože ostatné hlavné kategórie pôdneho krytu, najmä poľnohospodárske oblasti, sa môžu v priebehu jedného vegetačného obdobia výrazne zmeniť a viedli by k falošným výsledkom. Takéto masky lesa musia byť čo najaktuálnejšie a môžu byť odvodené buď z údajov EO použitých na detekciu zmien, alebo z iných zdrojov. Zo štandardných krokov predspracovania je veľmi dôležitá geometrická a rádiometrická kalibrácia. V porovnaní s absolútnou kalibráciou poskytuje relatívna kalibrácia výhodu, že sezónne zmeny sa dajú lepšie oddeliť od skutočných zmien, ak sú použité snímky z rôznych fáz sezónneho vývoja. Zmeny sa potom klasifikujú na základe zmeny ukazovateľov medzi dvoma dátumami pomocou ukazovateľov ako je NDVI alebo NBR.

Doteraz bolo vyvinutých a testovaných množstvo prístupov na identifikáciu optimálneho indikátora na detekciu degradácie a odlesňovania. Patria sem prístupy, ktoré využívajú hodnoty odrazivosti z dostupných spektrálnych pásiem oboch snímok na odvodenie veľkosti zmien. Tieto indikátory možno použiť ako prahové hodnoty (threshold) alebo v štandardnom klasifikačnom postupe, ako aj v kombinácii s klasifikačnými prístupmi, ktoré zahŕňajú aj segmentáciu obrazu (Obr. 10.26).



Obr. 10.26 Postup pri bi-temporálnej detekcii zmien pre monitorovanie odlesňovania. **Fig. 10.26** Bi-temporal change detection workflow for monitoring deforestation. Source: ©2021 Humboldt-Universität zu Berlin, Department of Geography; pages.cms.hu-berlin.de

10.6.2.2. Time series analysis

Typický časový rad snímok DPZ pozostáva z troch komponentov: zložka dlhodobého smerového trendu, sezónna zložka a reziduálna zložka (Obr. 10.27). V závislosti od zamerania výskumu je sledovaná jedna alebo všetky tieto zložky.



Obr. 10.27 Komponenty časových radov – trendový, sezónny a reziduálny, dohromady tvoriace časový rad (niekedy sa zvyknú označovať aj ako dlhodobý, sezónny a krátkodobý). **Fig. 10.27** Time series components - trend, seasonal and residual, together forming a time series (sometimes also as long-term, seasonal, and short-term). Source: Kuenzer et al., 2015

Pre monitorovanie degradácie lesov je podstatná najmä reziduálna zložka a treba ju odlíšiť od zvyškového šumu. V závislosti od regiónu kde sa monitorovaný lesný ekosystém nachádza, významnú úlohu pri charakterizácii poškodenia lesa zohráva aj sezónna zložka. Spracovanie časových radov môže byť založené na sériách nespracovaných digitálnych čísel (digital numbers - DN), hodnotách odrazivosti (%) alebo rôznych premenných. Týmito premennými môžu byť geofyzikálne premenné, napr. vrchol atmosféry (TOA), fotosyntetické aktívne žiarenie (PAR), podiel absorbovaného fotosyntetického aktívneho žiarenia (FPAR), premenné rôznych indexov ako NDVI, EVI, SAVI, tematické premenné, topografické premenné (napr. sklon, pomer strán, výška) alebo texturálne premenné (napr. homogenita, veľkosť a tvar objektu, konektivita) (Obr. 10.28). Predpokladom pre aplikovanie časových radov je presné predspracovanie obrazových dát, a to geometricky aj rádiometricky. Geometrické predspracovanie sa zvyčajne vykonáva plne automatizovanou koregistráciou snímok pomocou algoritmov na porovnávanie subpixelových obrazov. Pre rádiometrické predspracovanie údajov časových radov existujú dve možnosti: absolútna a relatívna kalibrácia.



Obr. 10.28Príklad časového radu optických snímok pre monitorovanie odlesňovania.Fig. 10.28Example of a time series of optical images for deforestation monitoring.Source:earthobservatory.nasa.gov/images/145888/making-sense-of-amazon-deforestation-patterns

Pre absolútnu atmosférickú kalibráciu je myšlienkou prejsť od digitálnych čísel k hodnotám fyzikálnej povrchovej odrazivosti (hodnoty spodnej časti atmosféry). Na vykonanie tejto kalibrácie sú potrebné parametre pre atmosférické podmienky v rôznych častiach snímky. Na rozdiel od toho, relatívna rádiometrická kalibrácia nepotrebuje dodatočné vstupné údaje, pretože snímky sú relatívne prispôsobené sebe navzájom alebo hlavnej scéne. Pre klasickú detekciu zmien sa často používala relatívna rádiometrická kalibrácia.

V prípade časových radov je štandardným postupom aplikácia absolútnej atmosférickej korekcie, aby sa do časových radov pridali nové súbory údajov ihneď po ich dostupnosti.

Nástroje na atmosférickú korekciu optických údajov neustále zdokonaľujú organizácie ako ESA (Sen2Cor for Sentinel2 imagery) alebo USGS (LEDAPS). Okrem toho sú k dispozícii aj ďalšie nástroje pre relatívnu rádiometrickú kalibráciu. Ďalším krokom v predspracovaní býva topografická korekcia a generovanie masky oblačnosti.

Z hľadiska metodológie môžeme rozdeliť metódy analýzy časových radov, ktoré sa používajú na zisťovanie zmeny lesa, do štyroch kategórií (Obr. 10.29):

- detekcia zmeny na základe prahovej hodnoty (threshold-based change detection);
- 2. prispôsobenie krivky (curve fitting);
- 3. prispôsobenie trajektórie (trajectory fitting);
- 4. segmentácia trajektórie (trajectory segmentation).



Obr. 10.29 Schematické znázornenie základných metód analýzy časových radov. **Fig. 10.29** Schematic representation of time series analysis methods. Source: Hirschmugl et al., 2017

Počas niekoľkých posledných desaťročí boli vyvinuté rôzne metódy analýzy časových radov na dlhodobé monitorovanie vegetácie založené na satelitných snímkach s nízkym až stredným rozlíšením, ako sú AVHRR a MODIS. Všetky aplikácie na údajoch so stredným rozlíšením majú jedno dôležité obmedzenie: zatiaľ čo časové rozlíšenie údajov MODIS je vysoké, priestorové rozlíšenie 250 m na pixel umožňuje iba monitorovanie vážnej degradácie vo veľkej mierke, ako sú napríklad veľké lesné požiare alebo rozsiahle biotické škody. Typická veľkosť zasiahnutých oblastí je však často oveľa menšia ako rozlíšenie pixelov MODIS, a preto sú tieto dáta nepoužiteľné.

Dáta časových radov pre Sentinel-2 alebo Landsat 8 majú nižšie temporálne rozlíšenie ako napríklad dáta MODIS a dostupnosť dát z časových radov zo satelitov s vysokým rozlíšením silne závisí od regionálnej oblačnosti a geografickej šírky.

1. Threshold-based change detection

Tieto metódy využívajú prahové hodnoty - "thresholding", na oddelenie lesnej plochy od nelesnej, resp. neporušeného lesa od degradovaného a poškodeného lesa, v časovom rade optických snímok. Do tejto skupiny prístupov patrí viacero existujúcich algoritmov, napr. ForWarn System (monitoring zmien vegetácie na území USA takmer v reálnom čase), automatizovaný algoritmus mapovania zmien lesa (Vegetation Change Tracker -VCT) - vyvinutý na základe pravdepodobnosti zalesnenia pixelu, kde pre zalesnené a nezalesnené oblasti sa na identifikáciu zalesnených oblastí používa prah takzvaného integrovaného lesného Z-skóre (index založený na prahovej hodnote, s cieľom zamerať sa na náhle zmeny lesného porastu na úrovni pixelov. Je to inverzná miera pravdepodobnosti, že pixel je zalesnený).

Hlavná nevýhoda analýzy časových radov založenej na prahových hodnotách je rovnaká ako pri akejkoľvek inej technike založenej na tomto princípe: prahové hodnoty sú určené empiricky, a preto ich nemožno priamo preniesť na iné záujmové oblasti, ktoré sa vyznačujú rôznymi typmi vegetácie, hustotou vegetácie alebo modelmi degradácie.

Pre analýzy Global Forest Watch sa použila aj špecifická metóda kombinujúca prístup snímka vs. snímka s časovými radmi. Používa algoritmus klasifikačného stromu na porovnanie nových snímok s hodnotami z časových radov pre oblasti tropického vždyzeleného lesa. Podobné prístupy sa však uplatnili aj v iných oblastiach sveta vrátane Európy.

2. Curve fitting

Užitočnosť tejto metódy pre monitorovanie dynamiky lesa je v súčasnosti preukázaná viacerými štúdiami. Pri spracovaní sa sezónne vplyvy na vegetáciu potláčajú výberom snímok s dátumom blízkym špecifickému obdobiu rastu (napr. v období vrcholu rastu vegetácie). Medzi spektrálne premenné (Spectral Variables SV) (ktorými môžu byť odrazivosť v jednom pásme alebo odvodené indexy) a čas, sa priradí funkcia trendu v jednotlivých pixeloch založená na regresných modeloch. Sklon, ktorý sa výrazne líši od nuly, určuje prítomnosť alebo neprítomnosť trendu. Trend je vyjadrený ako sklon regresnej krivky a poskytuje informácie o veľkosti zmeny v čase. Znamienko sklonu možno použiť na oddelenie rôznych procesov zmeny, ako napr. nárast alebo pokles koruny lesného porastu.

Okrem sklonu aj koeficienty kvadratického zakrivenia sú dôležité pre pochopenie degradácie a obnovy lesného porastu, čo sa uplatňuje pri mapovaní degradácie tropických lesov v Brazílii, kde sa skúmal vzťah lesnej fenológie a selektívnej ťažby na základe časového radu s použitím údajov MODIS. Okrem použitia indexov, ako napríklad EVI, sa používa aj analýza kombinácie spektrálnych pásiem. Nedostatkom tejto metódy je, že štandardné základné štatistické predpoklady, ako je normalita a rozptyl, sa vo všeobecnosti ťažšie plnia a ich porušenie vedie k neadekvátnej reprezentácii údajov. Okrem odvodenia trendovej zložky zachytáva táto metóda aj základnú dynamiku sezónnosti.

3. Trajectory fitting

Mnohé modely degradácie lesov majú odlišné časové správanie pred a po udalosti kedy došlo k degradácii, čo vedie k charakteristickému spektrálno-časovému priebehu. Zatiaľ čo les, ktorý prechádza postupnými zmenami, môže byť reprezentovaný lineárnym trendom, stabilný les (tj. žiadna degradácia) môže byť reprezentovaný vodorovnou čiarou. Podobne môžu náhle zmeny viesť k náhlej zmene trajektórie, po ktorej budú nasledovať stabilné, rastúce alebo klesajúce trendy v závislosti od konkrétnych procesov degradácie a obnovy lesa. Zmeny sú teda analyzované prispôsobením idealizovaných trajektórií, ktoré sú charakteristické pre špecifické typy degradácie. Na to je potrebné definovať predpokladané trajektórie zmien, ktoré sú založené na očakávanom spektrálno-časovom správaní sa vybraných premenných. Tieto predpokladané trajektórie musia byť definované pre každý typ degradácie samostatne. Prispôsobovanie trajektórie možno preto interpretovať ako kontrolovanú metódu detekcie zmien s idealizovanými trajektóriami predstavujúcimi vzorový priebeh špecifický pre rôzne typy degradácie. Pri aplikovaní tejto metódy na monitorovanie degradácie v tropických lesoch sú hlavnými problémami atmosférické podmienky v trópoch, rýchly opätovný rast vegetácie po selektívnej ťažbe dreva a malé štruktúrované vzory ťažby dreva. Hlavným obmedzením tejto metódy je, že tvar typickej degradačnej krivky (kriviek) musí byť známy z niektorých referenčných údajov a metóda bude správne fungovať len vtedy, ak sa pozorovaná spektrálna trajektória zhoduje s jednou z vopred definovaných typických degradačných kriviek.

4. Trajectory segmentation

Takzvaný LandTrendR prístup rozkladá trajektóriu na sériu priamych segmentov, aby zachytil širšie rysy trajektórie, rovnako ako aj podtrendy. Prvou fázou segmentácie je určenie vrcholových rokov, ktoré definujú koncové body segmentov. V druhej fáze je najlepšia priamočiara trajektória preložená cez tieto vrcholy pomocou bod-bod alebo regresných čiar. Výsledkom tejto segmentácie je spektrálna trajektória, ktorá sa skladá z priamočiarych segmentov. Časová poloha a spektrálna hodnota vrcholov segmentov poskytuje základné informácie, ktoré sú potrebné na vytvorenie máp zmien lesa, alebo slúžia ako prognostické premenné na porovnanie budúceho vývoja. Výhodou tohto prístupu je to, že priame segmenty umožňujú detekciu náhlych udalostí, ako sú poruchy, ako aj dlhšie trvajúce procesy, ako je opätovný rast. Ďalšou výhodou je, že nie je potrebná typická krivka degradácie ako pri predchádzajúcej metóde, pretože samotné dáta určujú tvar trajektórie. Algoritmus LandTrendR zachytáva náhle poruchy (ako sú holiny) rovnako dobre, alebo dokonca lepšie, ako metódy detekcie zmien zo snímok z dvoch dátumov a deteguje jemné zmeny, ako je degradácia súvisiaca s podkôrnym hmyzom, resp. rast vegetácie. Hlavnou nevýhodou metódy je, že sa neberú do úvahy sezónne vplyvy spôsobené fenologickými zmenami.

10.6.3. Using radar data for monitoring deforestation and

forest degradation

Monitorovania lesa založené na SAR dátach patrí medzi metódy DPZ s najväčším potenciálom pre mapovanie narušenia lesov v trópoch v "reálnom čase" vďaka schopnosti SAR fungovať za všetkých meteorologických podmienok, kedykoľvek počas dňa alebo noci. Uvoľnenie globálnych mozaík z misií JERS, PALSAR a PALSAR-2 s rozlíšením 25 m podporilo výskum v oblasti monitorovania odlesňovania pomocou SAR. Mozaiky z misií ALOS PALSAR boli použité na vytvorenie prvých ročných (2007 – 2010)

globálnych máp lesného a nelesného pokryvu na báze SAR dát, z ktorých boli vytvorené mapy úbytkov a prírastkov lesa využitím "threshold" hodnôt.

Monitorovanie zmeny lesa zo SAR dát sa zvyčajne vykonáva meraním zmien intenzity spätného rozptylu v priebehu času. Poruchy lesných porastov a opätovný rast v subkontinentálnom meradle bývajú monitorované na základe zmien intenzity signálu. Nepriame prístupy zasa spájajú signál spätného rozptylu s lesnou biomasou pomocou regionálnych empirických regresných modelov a potom vypočítavajú zmeny biomasy v priebehu času. Lesná nadzemná biomasa sa odhaduje zo spätného rozptylu v dvoch časových obdobiach, a potom sa zmeny v biomase určia odčítaním týchto dvoch odhadov. Aplikácie, ktoré sú založené na údajoch ALOS PALSAR, sú obmedzené malým počtom dostupných snímok: v prípade globálnej mozaiky ide o l súbor za kalendárny rok, v prípade individuálnych snímok je maximálne temporálne rozlíšenie približne 42 dní. Väčšina aplikácií je teda obmedzená na bi-temporálne analýzy.

Iné prístupy pre monitorovanie narušenia lesa založené na SAR dátach využívajú trojrozmerné (3D) informácie z radargrametrie a InSAR na detekciu medzier v korunách lesného porastu. Dáta z misií Sentinel-1 a TerraSAR-X a ich SAR senzorov s rôznou frekvenciou sú dokonca komplementárne pre monitorovanie narušenia lesov.

SAR dáta v C-pásme sú menej vhodné na hodnotenie narušenia lesov a odhadu nadzemnej biomasy ako SAR dáta v L-pásme kvôli kratšej vlnovej dĺžke, ktorá obmedzuje penetráciu do porastu. C-pásmo sa preto pri monitorovaní lesov využíva v menšej miere ako údaje v L-pásme. Husté časové rady misie Sentinel-1 však ponúkajú jedinečnú príležitosť systematicky monitorovať lesy v opakovanom cykle 6 až 12 dní v závislosti od typu údajov a polohy. Okrem toho je zaručená dlhodobá kontinuita údajov Sentinel, čo umožní vývoj dlhodobých systémov monitorovania životného prostredia.

Dáta Sentinel-1 na mapovanie narušenia lesov boli použité už vo viacerých výskumoch a projektoch. Väčšina prístupov meria zmeny intenzity spätného rozptylu SAR v čase, a to buď priamo medzi snímkami, alebo výpočtom variačného koeficientu z uložených dát za vopred definované časové obdobie. Empirické prahové hodnoty sa potom použijú na odvodenie poškodenia lesa. Takéto prístupy boli testované pri mapovaní poškodenia lesov vo viacerých krajinách (napr. Konžská demokratická republika, Indonézia).Výskumná štúdia na lokalite tropického pralesa v Bolívii ukázala, že údaje z časovej rady Sentinel-1 môžu poskytnúť oveľa včasnejšiu detekciu ako údaje optické snímky Landsat alebo radarové ALOS PALSAR-2.

Väčšina prác venovaných zisťovaniu poškodenia lesa z údajov Sentinel-1 predpokladá, že takéto poškodenie je nevyhnutne charakterizované znížením spätného rozptylu v C-pásme v rámci poškodenej oblasti, čo nemusí byť vždy pravdou. Preto bola navrhnutá nová metóda, ktorá využíva geometrické efekty SAR vyplývajúce z efektu "shadowing" na detekciu oblastí zmeny lesa z údajov Sentinel-1. V závislosti od geometrie zobrazenia sa na okrajoch lesov vyskytuje efekt "shadowing" a nové okraje lesov tak vedú k novým oblastiam tohto efektu, ktoré možno ľahko identifikovať v časovom rade. Na detekciu nových tieňov na oboch stranách oblasti poškodenia lesa sú potrebné údaje o vzostupnej aj zostupnej dráhe.

10.6.3.1. SAR characteristics for forest monitoring

Hodnoty spätného rozptylu SAR signálu sú určené dvoma hlavnými skupinami charakteristík: charakteristikami senzora a cieľa. Do prvej skupiny patrí frekvencia/vlnová dĺžka SAR signálu, polarizácia vysielaného a prijímaného signálu SAR, uhol dopadu radarového lúča na zem a smer pohľadu senzora. Pri interpretácii a analýze snímok SAR je potrebné zohľadniť kombináciu týchto charakteristík. Často nie je vhodné kombinovať snímky SAR zo súboru senzorov rôznych parametrov, ak sa údaje spätného rozptylu

starostlivo nekalibrujú. Najmä pri analýze časových radov sa odporúča analyzovať údaje rovnakých charakteristík, inak sa môžu zmeny signálu nesprávne interpretovať ako skutočná zmena, hoci v skutočnosti k žiadnej nedošlo.

Ďalšia skupina charakteristík určujúcich spätný rozptyl SAR lesov a iných prírodných a človekom vytvorených cieľov súvisí s charakteristikami cieľa. Vo všeobecnosti, za predpokladu konštantných charakteristík zobrazovacieho snímača, je spätný rozptyl SAR funkciou obsahu vlhkosti a štrukturálnych charakteristík cieľa. V prípade lesov to znamená, že objem lesa (biomasa) a štrukturálna zložitosť (lesné kmene, konáre a listy) môžu indikovať prítomné druhy (napr. borovice vs. listnaté stromy). Na rozdiel od optických snímok, ak sú parametre snímača stabilné - ako je to v prípade väčšiny opakovane prechádzajúcich snímačov SAR na obežnej dráhe - odchýlky signálu v danom mieste pixelu sú len funkciou týchto cieľových charakteristík. Zmeny uhla dopadu slnečného žiarenia pozorované v optických údajoch nemajú vplyv na aktívny systém snímania SAR. Taktiež atmosférické zmeny (vrátane mrakov) nemajú (takmer) žiadny vplyv na signál SAR. Existujú však dôležité výnimky pri kratších vlnových dĺžkach, keď sa vyskytujú silné aktívne dažde, čo je možné vidieť pri snímkach v pásme C nad tropickým prostredím (Obr. 10.30). Pri analýze SAR signálov je preto dôležité uvedomiť si, že zmeny vlhkosti v pôde aj vo vegetácii výrazne určujú spätný rozptyl signálu.



Obr. 10.30 Efekt hustého dažďa na SAR dátach – snímka ENVISAT ASAR, Wide Swath Mode, vo VV polarizácii, z 18 Augusta 2011.

Fig. 10.30 Rain effect on SAR data - ENVISAT ASAR image, Wide Swath Mode, in VV polarization, from 18 August 2011.

Source: Alpers et al., 2016

10.6.3.2. Signal frequency characteristics in forest mapping

Frekvencia SAR určuje vlnovú dĺžku elektromagnetickej vlny, ktorá interaguje s cieľmi, ako napr. lesné plochy. V princípe platí, čím dlhšia je vlnová dĺžka (t. j. čím menšia je frekvencia), tým viac vlna preniká do korún stromov a interaguje s väčšími časťami objemu lesa. Pri zjednodušenom pohľade možno pásmo X (približne 3 cm) pripísať najmä rozptylu korún a malých konárov a listov/ihličia. Pásmo C (5 cm) preniká o niečo hlbšie do korún a rozptyľuje sa na stredne veľkých konároch. Pásmo L (23 cm) a pásmo P (40 cm) majú najsilnejšiu penetračnú schopnosť a interagujú s väčšími časťami stromov, ako sú veľké konáre a kmene. Pásmo L a dlhšie vlnové dĺžky ako také sú často spojené so silnou zložkou rozptylu "dvojitého odrazu" (double-bounce), pri ktorej sa dopadajúca energia rozptyľuje dopredu smerom k zemi, kde sa odráža späť k snímaču. Tento efekt

dvojitého odrazu je neoceniteľný pri zisťovaní účinkov záplav pod korunami stromov, kde zaplavenie stojacou vodou pod stromom pôsobí ako silná odrazová plocha v smere naspäť k senzoru SAR. V prostredí tropických lesov sú potom zaplavené lesné plochy na SAR snímkach mimoriadne jasné (Obr. 10.31).



Obr. 10.31 Efekt dvojitého odrazu pri zaplavení lesných plôch v Peru na snímke ALOS PALSAR v HH polarizácii.

Fig. 10.31 Double-bounce effect from forest flooding in Peru, ALOS PALSAR image in HH polarization.

Source: Dataset: ©JAXA/METI ALOS PALSAR L1.5 2008. Accessed through ASF DAAC 17 January 2022

Pri porovnaní spätného rozptylu v pásmach L a C je viditeľná predovšetkým relatívna neprítomnosť veľmi tmavých povrchov pri dátach v C pásme, čo poukazuje na silný spätný rozptyl od drsných povrchov na kratších vlnových dĺžkach. V pásme L sa povrchy javia hladšie (teda tmavšie), v prítomnosti nízkej, resp. žiadnej vegetácie. Tento vplyv je dobre viditeľný na radarových snímkach v L (ALOS PALSAR) a C (Sentinel-1) pásme pre oblasti plantáží palmy olejovej v Ekvádore (Obr. 10.32).



Obr. 10.32 Plantáže palmy olejovej v Ekvádore - porovnanie snímok z L-pásma ALOS PALSAR a z C-pásma Sentinel-1.

Fig. 10.32 Oil palm plantations in Ecuador - comparison of ALOS PALSAR L-band and Sentinel-1 C-band images.

Source: Dataset: ©JAXA/METI ALOS PALSAR L1.5 2008. Accessed through ASF DAAC 17 January 2022; ASF DAAC 2022, contains modified Copernicus Sentinel data 2018, processed by TUKE FBERG

10.6.3.3. Polarization characteristics in forest mapping

Pri monitorovaní lesných plôch je dôležité zohľadniť polarizáciu radarových vĺn, pretože určuje, ako signál interaguje s kmeňmi a korunovými zložkami. Na Obr. 10.33 je znázornená zjednodušená schéma interakcie dlhých a krátkych vlnových dĺžok pri horizontálnej a vertikálnej polarizácii s lesmi. Najdôležitejšie je, že spätný rozptyl z polarizácie VV, HH (t. j. rovnaké polarizácia vyslanej a prijatej vlny) je zvyčajne silnejší pre zložky povrchového rozptylu, zatiaľ čo energia meraná z detekcie pri krížovej polarizácii (VH alebo HV) (t. j. meranie vlny vracajúcej sa s 90° rotáciou voči vysielanej vlne) je spojená s meraním objemového rozptylu.

Pre monitorovanie biomasy, sledovanie degradácie lesov a identifikáciu zmien sú teda nevyhnutné krížovo polarizované SAR dáta. Rozdiely medzi podobnými a krížovo polarizovanými snímkami z C- a L-pásov plantáže palmy olejnej sú viditeľné na Obr. 10.32. Na polarizácii L-HH aj C-VV je jasne vidieť, že medzi lesnými plochami a nelesnými oblasťami existujú veľké nejednoznačnosti sivej hodnoty. V krížovo polarizovaných obrazoch sú tieto rozdiely jednoznačnejšie.



Obr. 10.33 Schematické znázornenie efektu polarizácie SAR signálu na spätný rozptyl pre dlhé a krátke vlnové dĺžky od kmeňov a korún stromov.

Fig. 10.33 Schematic representation of the effect of SAR signal polarization on backscatter for long and short wavelengths from tree trunks and crowns. Source: Kellndorfer, 2019

10.6.3.4. Effect of incidence angle

Spätný rozptyl SAR signálu je silne ovplyvnený uhlom dopadu, pretože určuje rozptyl v korunovej vrstve, kmeňoch a interakciách so zemou. Ak sú svahy naklonené smerom k snímaču, možno očakávať silnejší spätný rozptyl. Ak sú svahy naklonené smerom od snímača, je potrebné očakávať slabší spätný rozptyl. Rádiometrická terénna korekcia bude do určitej miery zodpovedať za tieto účinky; rozptyl je však silne závislý od typu povrchovej pokrývky. Tento efekt je slabší v prostredí s hustými lesmi a silnejší v prostredí s riedkou vegetáciou alebo holou pôdou.

10.6.3.5. Effect of look direction (Ascending / Descending)

Smer pohľadu SAR družice sa vzťahuje na smer, ktorým je nasmerovaná radarová anténa pri vysielaní a prijímaní radarového signálu. Smer pohľadu je určený vzhľadom na smer letu snímača. Je to podobné, ako keď človek sedí na pravej alebo ľavej strane lietadla a pozerá sa von oknom. Senzory SAR sú zvyčajne nakonfigurované tak, aby vysielali signál vpravo alebo vľavo. Ak sa satelit otočí, tento smer sa môže zmeniť. Spôsob, akým je oblasť zachytená radarovým lúčom, sa mení predovšetkým počas vzostupnej, resp. zostupnej, dráhy nad oblasťou. Obr. 10.34 ilustruje vplyv smeru pohľadu zo vzostupných alebo zostupných údajov.

Na obrázku je znázornený prechod družice Sentinel-1 v severovýchodnom Ekvádore. L'avá časť zobrazuje prekrytie snímok zo zostupnej (hore) a vzostupnej (dole) dráhy družice nad územím. V pravej časti sú znázornené RGB kompozície (VV/VH/VV_VH_ratio) z oboch dráh. Je tu možné vidieť rozdiely v spätnom rozptyle, ako aj rozdiely v prekryte a tieni (červená farba). Aplikácie na monitorovanie lesa ťažia z kombinovania rôznych smerov pohľadu, nakoľko sa často mapujú rôzne regióny a možno tak získať doplnkové informácie o spätnom rozptyle. Smer pohľadu väčšinou spôsobuje zmenu v štrukturálnom pohľade na zastavané územia a lesy. Ak je analýza časových radov na detekciu zmien zameraná na monitorovanie lesa, odporúča sa analyzovať časové rady opakovanými obežnými dráhami a nemiešať snímky zo vzostupných a zostupných dráh satelitov.



Obr. 10.34 Zobrazenie efektov smeru pohľadu na spätný rozptyl, prekryt a tieň na radarovej snímke VV/VH/ratio RGB Sentinel-1. **Fig. 10.34** Look direction effects on backscatter, layover and shadow on the VV/VH/ratio RGB Sentinel-1 radar image. Source: Kellndorfer, 2019

10.6.3.6. Effect of moisture

SAR signál je veľmi citlivý na vlhkosť pôdy a vegetácie, ako aj na stojaté otvorené vody a stojaté vody pod korunami stromov. Zvýšený obsah vlhkosti v pôde a vegetácii má tendenciu zvyšovať spätný rozptyl signálu. Stojatá otvorená voda má na snímkach veľmi tmavé podanie, pretože väčšina jej energie je rozptýlená v smere od snímača; keď však vietor, prúdy alebo lodné motory rozvlnia vodnú hladinu, tak na takýchto otvorených vodných plochách môže dochádzať k silnému spätnému rozptylu. Najmä kratšie vlnové dĺžky, t.j. v pásmach C a X, majú výraznejší spätný rozptyl pokojných vodných plôch od nepokojných vodných plôch. Pri dlhších vlnových dĺžkach môže mať spomínaný efekt dvojitého odrazu pod korunami stromov silný spätný rozptyl signálu (Obr. 10.31).

Obr. 10.35 zobrazuje vplyv vlhkosti v zalesnených oblastiach na dáta C-pásma Sentinel-1 v Ekvádore. Efekt stmavenia je spojený s aktívnym dažďom a silnými tropickými konvekčnými systémami, ktoré spôsobujú oslabenie signálu. Zosvetľujúce účinky pochádzajú z mokrej vegetácie a pôdy z dažďových udalostí spojených s tropickým frontálnym systémom.





Fig. 10.35 Influence of moisture on the backscatter for Sentinel-1 image in VV polarization. Source: Dataset: ASF DAAC 2022, contains modified Copernicus Sentinel data 2016, 2017, 2018, processed by TUKE FBERG

Obr. 10.36 znázorňuje účinky pôdnej vlhkosti v lesnej vegetácii na zosvetlenie signálu v L-pásme HH polarizácie zo satelitu ALOS v lokalite Ekvádor. Zatiaľ čo snímka z roku 2008 preukazuje len slabý vplyv na výraznejší spätný rozptyl súvisiaci s vlhkosťou, rok 2009 ukazuje mierne výraznejší rozptyl vo východnej časti snímky. V roku 2010 je viditeľné silnejšie zosvetlenie súvisiace s vlhkosťou. Výsledkom je, že multitemporálny farebný kompozit vykazuje veľké farebné variácie, ktoré súvisia s vlhkosťou. Pri vykonávaní multitemporálnej detekcie zmien pre monitorovanie degradácie lesa je potrebné dávať pozor, aby sa stmavnutie oblastí v časovom rade neinterpretovalo ako degradácia lesa, nakoľko príčinou zníženia alebo zvýšenia spätného rozptylu môžu byť aj zmeny vlhkosti. Analýza časových radov môže pomôcť rozlíšiť tieto dve rôzne príčiny, pretože zmeny vlhkosti sú kratšie v čase a priestore a vykazujú náhodnejší vzor v porovnaní so skutočnými signálmi poškodenia lesa alebo odlesňovania.


Obr. 10.36 Znázornenie vplyvu vlhkosti na spätný rozptyl signálu pre snímky ALOS PALSAR v HH polarizácii.

Fig. 10.36 Influence of moisture on the backscatter for ALOS PALSAR image in HH polarization. Source: Dataset: ©JAXA/METI ALOS PALSAR L1.5 2008, 2009, 2010, Accessed through ASF DAAC 17 January 2022

10.6.3.7. Effect of structure

Okrem vlhkosti ovplyvňujú spätný rozptyl SAR signálu z lesov aj štrukturálne charakteristiky vegetácie. To zahŕňa horizontálnu štruktúru (t. j. hustotu koruny, radové plantáže, textúru) aj vertikálnu štruktúru (t. j. hĺbku koruny, biomasu koruny a kmeňa, štruktúru listov a vetvenia, životné formy stromov).

Obr. 10.37 znázorňuje veľkosť spätného rozptylu pre údaje z C-pásma Sentinel-1 v polarizácii VV a VH pre palmové plantáže a jej rôzne štádiá rastu, narušenia a opätovného rastu (vrátane spätného rozptylu z nenarušeného primárneho lesa).



Google Earth 09-2018



Obr. 10.37 Rozdielny spätný rozptyl na snímke Sentinel-1 vo VH a VV polarizácii v porovnaní s optickými dátami z Google Earth pre palmové plantáže v rôznych štádiách rastu.

Fig. 10.37 Different backscatter in Sentinel-1 image in VH and VV polarization compared to optical data from Google Earth for palm plantations at different growth stages.

Source: Dataset: Dataset: ASF DAAC 2022, contains modified Copernicus Sentinel data 2018, processed by TUKE FBERG

Pre L-pásmo SAR satelitu ALOS PALSAR je na Obr. 10.38 uvedený príklad z oblasti hospodárenia s drevom v Louisiane, USA. Oblasť je intenzívne obhospodarovaná a možno vidieť rôzne štádiá ťažby, selektívnej ťažby (prerieďovanie) a opätovného rastu. Krížovo polarizované údaje jasne ukazujú zvýšený jas tam, kde sú zrelšie lesy s vyššou biomasou.



Google Earth 10-2007



Obr. 10.38 Rozdielny spätný rozptyl na snímke ALOS PALSAR v HH a HV polarizácii v porovnaní s optickými dátami z Google Earth pre oblasť hospodárskej ťažby dreva v rôznych fázach ťažby v štáte Luisiana (U.S.).

Fig. 10.38 Different backscatter on ALOS PALSAR image in HH and HV polarization compared to optical data from Google Earth for an area of timber management at different stages of logging in the state of Louisiana (U.S.).

Source: Dataset: Dataset: ©JAXA/METI ALOS PALSAR L1.5 2007, Accessed through ASF DAAC 17 January 2022

10.6.4. Deforestation and forest degradation from a SAR data

perspective

Vo všeobecnosti môžeme charakteristiku spätného rozptylu SAR signálu zhrnúť nasledovne:

Odlesňovanie – ide najmä o zmenu z objemového na povrchový rozptyl. To znamená, že spätný rozptyl pre krížovo polarizované dáta (VH, HV) výrazne klesá. Ak má však odlesňovanie za následok zdrsnenie terénnych podmienok (napr. rúbanie) alebo ak príprava miesta zdrsňuje terén, tak sa spätný rozptyl môže výrazne zvýšiť až do bodu,

kedy sa začne zvyšovať samotný výrub (napr. kým sa neodstránia polená). Pri časových radoch však trendy smerujú k znižovaniu spätného rozptylu. Zvýšená vlhkosť pôdy v danom čase môže výrazne zvýšiť spätný rozptyl v C-pásme a môže spôsobiť nejednoznačnosti pri následnej analýze dát. Analýza časových radov však môže tieto prechody odhaliť.

Degradácia – Degradácia lesov zvyčajne znižuje objemový rozptyl a (v závislosti od miery degradácie), koľko pôdy prispieva k signálu spätného rozptylu pri pozorovanej vlnovej dĺžke. V C-pásme je ťažké zistiť degradáciu, pokiaľ sa neodstránia väčšie plochy lesa. Pri prerieďovaní lesa je možné detegovať zníženie spätného rozptylu v L-pásme. Typ degradácie však určuje aj mechanizmy spätného rozptylu. Napríklad poškodenie víchricou môže byť také, že objem celej vegetácie a mechanizmy rozptylu zosilnia spätný rozptyl z vyvrátených kmeňov, čo je náročné oddeliť od veľkosti spätného rozptylu pred poškodením lesa. Lesné požiare majú vplyv na vysoký nárast v L-pásme, kde vplyv pôdy zosilňuje dvojitý odraz a tým zvyšuje/rozjasňuje signál zo spätného rozptylu. Postupom času, keď objem začne výrazne klesať, tak signál kopíruje trend poklesu spätného rozptylu v degradovaných lesoch.

Tabuľka 10.2 poskytuje prehľad charakteristík spätného rozptylu pre rôzne druhy vegetácie v rôznych polarizáciách a vlnových dĺžkach.

Tab. 10.2 Vlastnosti spätného rozptylu rôznych typov lesného porastu v C-pásme a L-pásme pre rôzne polarizácie. **Tab. 10.2** Backscatter characteristics of different forest cover types in C-band and L-band for different polarizations. Source: Kellndorfer, 2019

	ácia	Odozva podľa typu lesa					
Polariza		Riedky les (suchý)	Riedky les (zaplavený)	Poškodený les (suchý)	Poškodený les (zaplavený)	Hustý les (suchý)	Hustý les (zaplavený)
C-pásmo	vv	Stredná až vysoká; V závislosti od drsnosti povrchu v lesnom poraste a vlhkosti je v tejto kategórii veľká variácia.	Nízka až stredná; V závislosti od hustoty lesa – silnejší spätný rozptyl.	Stredná až vysoká; Najviac signálu z koruny stromov.	Stredná až vysoká; Najviac signálu z koruny stromov.	Stredná až vysoká; Najviac signálu z koruny stromov (môže byť slabší v prípade výraznejšej absorpcie čo znižuje spätný rozptyl).	Stredná až vysoká; Najviac signálu z koruny stromov (môže byť slabší v prípade výraznejšej absorpcie čo znižuje spätný rozptyl).
	νн	Stredná až vysoká; V závislosti od drsnosti povrchu v lesnom poraste a vlhkosti je v tejto kategórii veľká variácia.	Nízka až stredná; V závislosti od hustoty lesa – silnejší spätný rozptyl.	Stredná až vysoká; Najviac signálu z koruny stromov.	Stredná až vysoká; Najviac signálu z koruny stromov.	Stredná až vysoká; Najviac signálu z koruny stromov (slabší v prípade výraznejšej absorpcie čo znižuje spätný rozptyl).	Stredná až vysoká; Najviac signálu z koruny stromov (slabší v prípade výraznejšej absorpcie čo znižuje spätný rozptyl).
	∨∨/∨н	Stredná až vysoká	Stredná až vysoká	Stredná	Stredná	Stredná	Stredná
L-pásmo	нн	Nízka až stredná; Nižšia ako pri hustom lese a zaplavenom riedkom lese. Pri strmších uhloch dopadu môže byť spätný rozptyl stredný až vysoký.	Stredná až vysoká; V závislosti od toho, koľko dvojitého odrazu prispieva k celkovému signálu.	Stredná až vysoká	Vysoká až veľmi vysoká; Dvojitý odraz prispieva k vysokému spätnému rozptylu.	Vysoká až veľmi vysoká; Vyššia ako pri poškodenom lese, pri veľkých objemoch biomasy je viditeľná iba saturáciu a žiaden rozdiel od poškodeného lesa.	Vysoká až veľmi vysoká; Dvojitý odraz prispieva k vysokému spätnému rozptylu.
	HV	Nízka až veľmi nízka; V závislosti od toho, ako suchá je pôda.	Nízka až veľmi nízka; Väčší spätný rozptyl v dôsledku zrkadlového odrazu.	Stredná až vysoká	Stredná až vysoká; Žiadne sezónne výkyvy v súvislosti so zaplaveným lesným porastom.	Vysoká až veľmi vysoká; Dominantný je objemový rozptyl – najlepšia citlivosť na biomasu.	Stredná až vysoká; Žiadne sezónne výkyvy v súvislosti so zaplaveným lesným porastom.
	нн/н∨	Stredná	Vysoká	Stredná	Vysoká	Stredná	Vysoká

10.6.5. SAR data processing for forestry applications

Rádiometrická terénna korekcia

Správna rádiometrická terénna korekcia SAR dát je kľúčovým krokom pre akúkoľvek analýzu detekcie zmien, či už bi-temporálnej, v časových radoch, alebo v kombinácii s optickými snímkami. Dôležitá je tiež kvalita DEM - ako podklad akéhokoľvek ortorektifikačného procesu. DEM odvodené od SRTM sú často dostatočne kvalitné na spracovanie SAR s rozlíšením ~20 až 30 m. Zlepšenie sa dá dosiahnuť pomocou DEM s vyšším rozlíšením, ktoré však často nie sú voľne dostupné.

Multitemporálna redukcia Speckle Noise

Ak sú k dispozícii správne usporiadané SAR údaje, odporúča sa najprv spracovať dátové sady časových radov pomocou multitemporálneho speckle filtra. Multitemporálny speckle filter zachováva priestorové detaily a zároveň výrazne znižuje speckle noise v každom časovom kroku. Multitemporálne filtre odhadujú charakteristiky tohto šumu v čase a nie v priestore. Výsledné štatistiky možno použiť na odhad stredného spätného rozptylu pixelu so zníženým šumom, pričom sa zachová odhad spätného rozptylu v akomkoľvek časovom kroku, ale pri zníženom šume. Priestorové detaily tak zostávajú zachované.

Obr. 10.39 znázorňuje príklad dát z L-pásma ALOS PALSAR. Pre redukciu šumu bolo použitých 16 multitemporálnych scén. Po aplikovaní filtra sú oveľa zreteľnejšie rôzne stavy lesa počas ťažby ako pred jeho aplikovaním. Vzhľadom na zmeny objemového spätného rozptylu v L-pásme HV polarizácie, multitemporálny obraz možno ľahko interpretovať podľa toho, v ktorých oblastiach bola vykonaná holorubná alebo selektívna ťažba (červená a žltá farba), v akých oblastiach prebieha opätovný rast (modrá farba), resp. ktoré oblasti nezmenili svoj stav (biela a čierna farba). Dokonalé zarovnanie pixelov v čase je predpokladom úspešného multitemporálneho filtrovania šumu.



Obr. 10.39 Použitie multitemporálneho speckle filtra na co-registrované snímky z časového radu ALOS PALSAR v HV polarizácii.

Fig. 10.39 Application of a multitemporal speckle filter to co-registered ALOS PALSAR time series images in HV polarization.

Source: Kellndorfer, 2019

10.6.6. Change detection using SAR data

Bi-temporálne metódy

Klasické metódy detekcie zmien pre porovnanie bi-temporálnych snímok je možné použiť na SAR snímky po správne vykonanej rádiometrickej terénnej korekcii. Medzi tieto metódy patrí napríklad metóda logaritmického pomeru (log-ratio – LR), alebo algoritmus Iteratívne Re-vážená Multivariačná Detekcia Zmien iMAD (Iteratively reweighted Multivariate Alteration Detection). Vždy je však dôležité pochopiť možné vplyvy na zmenu spätného rozptylu, ktoré nesúvisia so skutočnými zmenami, ako je odlesňovanie. Zatiaľ čo zmeny lesa sa ľahšie detegujú v bi-temporálnych analýzach v L-pásme, tak analýzu dát v C-pásme často sťažuje drsnosť povrchu, a zároveň zložky vlhkosti môžu viesť k významným nejednoznačnostiam SAR signálu.

Analýza časových radov

V minulosti bola dostupnosť údajov SAR v priestore a čase slabá, až misia Sentinel-1 zásadným spôsobom zmenila situáciu v aplikačnom používaní SAR dát. Nadchádzajúca misia NASA-ISRO SAR (NISAR) – s jej politikou otvorených údajov a údajmi v L- a S-pásme v 12-dňových opakovaných intervaloch pri strednom rozlíšení – bude ďalším veľkým prínosom pre dostupnosť SAR dát. Vďaka takmer nepretržitej dostupnosti pozorovaní SAR je tak možné dosiahnuť monitorovanie lesa v reálnom čase. Techniky analýzy časových radov vyvinuté pre optické snímky sú do istej miery použiteľné, avšak charakteristiky citlivosti spätného rozptylu SAR signálu na štruktúru a vlhkosť prinášajú nové metódy. Zaužívanou metódou analýzy časových radov je detekcia bodových zmien pomocou kumulatívnych súčtov (Change point detection with cumulative sums). Vzhľadom na to, že trend spätného rozptylu SAR signálu sa znižuje so stratou biomasy v dôsledku odlesňovania alebo degradácie lesov, aplikácia analýzy kumulatívnych súčtov na údaje časových radov SAR dát sa zdá byť potenciálne jednoduchá, ale zároveň je efektívna.

Súhrnne sa dá povedať, že údaje o časových radoch SAR dát, ako sú tie, ktoré sú teraz dostupné zo Sentinel-1, sú neoceniteľným zdrojom pre podrobné mapovanie zmien lesa. Viaceré oblasti planéty môžu byť častejšie pokryté vzostupnými alebo zostupnými údajmi, súbormi údajov s jednou polarizáciou VV alebo s duálnou polarizáciou VV+VH. Nadchádzajúca misia NISAR prinesie dátové súbory s dostatočnou časovou frekvenciou v L-pásme, čo zvýši schopnosť detekcie zmeny lesa.

Závislosť vlhkosti a štruktúry rôzne hustých lesov je znázornená na príklade polosuchého regiónu v Burkine Faso na základe analýzy zmien v časovom rade pre dáta z Cpásma Sentinel-1 (Obr. 10.40). Spätný rozptyl sa mení podľa ročného obdobia v dôsledku nárastu vlhkosti a poľnohospodárskej činnosti. Zdá sa, že v apríli 2016 bola zaznamenaná silná dažďová udalosť, ktorá viedla k prudkému nárastu takmer všetkých kriviek okrem tých pre mestské oblasti a bahnité roviny. Profil bahennej roviny vykazuje v jednom dátume silný pokles (ktorý pravdepodobne súvisí s prívalovou povodňou zo silného dažďa), čo vedie k detekcii otvorenej vodnej plochy v časovom rade. Amplitúda v signáli časového radu sa zvyšuje s klesajúcim pokrytím korunami stromov, čo možno pripísať zvýšeniu signálu v dôsledku pôdnej vlhkosti počas obdobia dažďov. Je vidieť, že s klesajúcou hustotou prispievajú sezónne zmeny vlhkosti k nárastu a poklesu spätného rozptylu. Preto je dôležité brať do úvahy, že signály spätného rozptylu sa v čase menia, čo je nevyhnutné pre starostlivý výber ročných období na analýzu časových radov.



Obr. 10.40 Analýza a profily časových radov snímok Sentinel-1 pre lesné a iné plochy krajinnej pokrývky. Červený profil zodpovedá VV polarizácii a modrý profil VH polarizácii.
Fig. 10.40 Time series profiles and analysis of Sentinel-1 imagery for forest and other land cover areas. The red profile corresponds to VV polarization and the blue profile to VH polarization.
Source: Kellndorfer, 2019

10.6.7. Combining radar and optical data for monitoring

deforestation and forest degradation

Existuje množstvo štúdií a projektov, ktoré podporujú kombinované použitie SAR a optických údajov na monitorovanie tropických pralesov, odlesňovania, poškodenia lesného porastu. V princípe platí, že kombinované použitie môže zlepšiť monitorovanie tropických lesov na detekciu spálených oblastí, na mapovanie lesných/nelesných oblastí, na hodnotenie biomasy, a na monitorovanie odlesňovania a degradácie. Integráciou optických údajov Landsat 7/8 s údajmi SAR v L-pásme z misie ALOS PALSAR-2 a SAR v C-pásme z misie Sentinel-1 boli oblasti odlesňovania v Bolívii detegované s priemerným časovým oneskorením 31 dní a detekcia vykazuje používateľskú presnosť 88 %. Je to však použiteľné iba na väčšie oblasti odlesňovania a neplatí na malé územia poškodenia lesov, čo je náročné identifikovať z údajov so stredným rozlíšením. Namiesto toho sú nevyhnutné snímky s vysokým rozlíšením.

Významné možnosti detekcie poškodenia lesov ponúka kombinácia údajov z misií Sentinel-2 a Sentinel-1 (Obr. 10.41). Tieto dve satelitné misie majú v súčasnosti najvyššie časové pokrytie voľne dostupných údajov a poskytujú snímky vo vysokom priestorovom rozlíšení. Veľkou výhodou je taktiež možnosť spracovávať takéto časové rady údajov v službe Google Earth Engine (<u>https://earthengine.google.com</u>/).



Obr. 10.41 Príklad postupu pre kombináciu Sentinel-1 a Sentinel-2. **Fig. 10.41** Workflow of fusion technique for Sentinel-1 and Sentinel-2. Source: Chang & Shoshany, 2016

Údaje SAR a optické údaje poskytujú doplnkové informácie pre monitorovanie lesa, keďže rôzne princípy zobrazovania sú základom meraní spätného rozptylu SAR a optickej multispektrálnej odrazivosti (Obr. 10.42). Ako už bolo uvedené, SAR meria zmeny vo vegetácii a obsahu pôdnej vlhkosti, ako aj štrukturálne zloženie vegetácie. Optický DPZ meria zmeny v chemickom zložení listov a ich odrazivosť pri osvetlení slnečným žiarením, vrátane stanovenia podielu zatienených oblastí v korunách lesných porastov. Indexy ako napr. NDVI normalizujú hodnoty optickej odrazivosti a poskytujú mieru hustoty vegetácie alebo listnatosti. Štúdie spätného rozptylu SAR a NDVI sa teda môžu použiť na porovnanie časových radov optických údajov a údajov SAR. Viacero prác už využilo tieto podobnosti a spojilo údaje SAR z časových radov Sentinel-1 a ALOS a optických snímok Landsat. Na spojenie údajov časových radov možno použiť rôzne prístupy. Boli urobené pokusy spojiť časové rady na úrovni signálu, kde sú optické signály a signály SAR normalizované na simuláciu podobných trendov v zlúčených časových radoch (napr. vyplnenie medzier NDVI simulovaným spätným rozptylom SAR za predpokladu podobného správania). To je však problematické vzhľadom na to, že signály majú rôzne základné princípy. Ďalším prístupom je spojenie na predikčnej úrovni, to znamená, že optické a časové rady SAR sa analyzujú oddelene a pravdepodobnosti udalostí odlesňovania a degradácie lesov sa vypočítavajú a porovnávajú v časovo ohraničenej oblasti. Ako také môže SAR vyplniť časové medzery v optických pozorovaniach a spoločné pravdepodobnosti môžu potvrdiť detekcie zo samostatných optických analýz alebo analýz SAR.



Sentinel-1Sentinel-2FusionObr. 10.42 Porovnanie dát zo Sentinel-1, Sentinel-2 a ich kombinácie pre monitorovanie biomasy.Fig. 10.42 Comparison of data from Sentinel-1, Sentinel-2 and their combination for biomassmonitoring.Faurage Change & Chashany 2010

Source: Chang & Shoshany, 2016

10.6.8. SAR vegetation index

Spätný rozptyl SAR signálu je ovplyvnený typom lesa a štrukturálnymi formami (typ a orientácia), podmienkami prostredia (napr. vlhkosťou a fenológiou) a vlastnosťami radarového zobrazovania. Zohľadnenie týchto skutočností môže pomôcť pri využívaní SAR na monitorovanie lesov. Údaje SAR možno použiť na výpočet indexov, ktoré pomáhajú rýchlo interpretovať podmienky na zemi. Medzi najznámejšie indexy patrí **Radarový Vegetačný Index RVI** (*Radar Vegetation Index*) (pozri aj Kapitola 8) (Obr. 10.43):

$$\mathbf{RVI} = \frac{8\sigma_{HV}^{0}}{(\sigma_{HH}^{0} + \sigma_{VV}^{0} + 2\sigma_{HV}^{0})}$$
(10.5)

kde σ^0 predstavuje rádiometricky a geometricky korigovaný koeficient spätného rozptylu SAR pre každú kombináciu polarizácie v lineárnych jednotkách (m²/m²). RVI je pomer krížovej polarizácie k celkovej energii zo všetkých pásiem polarizácie. Vo všeobecnosti sa pohybuje medzi 0 a 1 a je mierou náhodnosti rozptylu. Ako pomer má RVI menšiu citlivosť na geometriu a topografiu radarového merania a zostáva necitlivý na absolútnu chybu kalibrácie v radarových údajoch.



Obr. 10.43 RVI je takmer nulový pre hladký holý povrch a zvyšuje sa s rastom vegetácie. Má zvýšenú citlivosť na vegetačný kryt a biomasu.

Fig. 10.43 RVI is almost zero for a smooth bare surface and increases with vegetation growth. It has an increased sensitivity to vegetation cover and biomass.

Source: after Saatchi, 2019

Radarový Index Degradácie Lesa RFDI (*Radar Forest Degradation Index*) (Obr. 10.44):

$$\mathbf{RFDI} = \frac{\sigma_{HH}^{0} - \sigma_{HV}^{0}}{\sigma_{HH}^{0} + \sigma_{HV}^{0}}$$
(10.6)

Všetky hodnoty predstavujú rádiometricky opravené snímky. Hodnota RFDI sa pohybuje medzi 0 a 1. Vo všeobecnosti možno RFDI použiť na zistenie straty lesnej pokrývky a jej obnovenie po narušení.



Obr. 10.44 Hodnoty RFDI sa pohybujú od menej ako 0,3 pre husté zdravé lesy, od 0,4 do 0,6 pre degradované lesy a viac ako 0,6 pre odlesnené krajiny.

Fig. 10.44 RFDI values range from less than 0.3 for dense healthy forests, from 0.4 to 0.6 for degraded forests, and more than 0.6 for deforested landscapes. Source: after Saatchi, 2019

10.7. Global Forest Watch

Global Forest Watch (GFW) je online platforma, ktorá poskytuje údaje a nástroje na monitorovanie lesov. Využitím najmodernejšej technológie umožňuje každému prístup k informáciám v takmer reálnom čase o tom, kde a ako sa lesy na celom svete menia. GFW platforma obsahuje dva základné typy aplikácií pre užívateľov:

- 1. Mapový klient
- 2. Informačný panel

Mapový klient (Obr. 10.45) pomáha vyrozprávať vizuálny príbeh o tom, čo sa deje s lesmi na konkrétnom mieste. Užívateľ si môže priblížiť ľubovoľné miesto na svete a preskúmať, ako sa lesy menia, ako sa v nich hospodári a aké hodnoty poskytujú. Údaje je možné vrstviť - napríklad ročný úbytok stromovej pokrývky, údaje o využívaní pôdy a satelitné snímky – čím sa dajú lepšie pochopiť základné príčiny a vplyvy zmien lesov. Zobrazenie mapy je možné vložiť na inú webovú stránku, zdieľať prostredníctvom sociálnych médií alebo e-mailu, prípadne si urobiť snímku obrazovky a použiť ju v publikácii.



Obr. 10.45 Mapový klient online platformy Global Forest Watch. **Fig. 10.45** Global Forest Watch online map client. Source: globalforestwatch.org/map

Informačné panely (Obr. 10.46) pomáhajú odpovedať na dôležité otázky týkajúce sa zmien lesov v akejkoľvek oblasti a umožňujú zobraziť stovky štatistických údajov prostredníctvom interaktívnych tabuliek a grafov, ktoré sú odvodené z analýzy priestorových údajov. Štatistiky je možné prispôsobiť tak, aby boli všeobecné alebo špecifické podľa užívateľových predstáv, a je možné ich jednoducho zdieľať a stiahnuť na použitie off-line.



Obr. 10.46 Informačný panel webovej služby Global Forest Watch. **Fig. 10.46** Global Forest Watch online dashboard. Source: globalforestwatch.org/dashboards

GFW bezplatne sprístupňuje najlepšie dostupné údaje o lesoch online, čím vytvára výnimočnú transparentnosť o tom, čo sa deje v lesoch na celom svete. Lepšie informácie podporujú inteligentnejšie rozhodnutia o tom, ako obhospodarovať a chrániť lesy pre súčasné a budúce generácie, a väčšia transparentnosť pomáha verejnosti brať na zodpovednosť vlády a spoločnosti za to, ako ich rozhodnutia ovplyvňujú lesy. K údajom GFW majú denne prístup vlády, spoločnosti, organizácie občianskej spoločnosti, novinári a bežní ľudia, ktorým záleží na ich miestnych lesoch. Tisíce ľudí na celom svete denne využívajú GFW na monitorovanie a správu lesov, zastavenie nezákonného odlesňovania a požiarov, upozorňovanie na neudržateľné činnosti, ochranu svojej pôdy a zdrojov, udržateľné získavanie tovaru a výskum v oblasti ochrany prírody.

GFW zároveň zapája používateľov, aby pomohli využívať tieto údaje a technológie na zlepšenie lesného hospodárstva na celom svete. Podporuje vlády, aby využívali opensource platformu na vytváranie prispôsobených online máp, ktoré podporujú plánovanie a implementáciu národnej politiky. Tím GFW pre súkromný sektor spolupracuje s najväčšími svetovými výrobcami potravín a pomáha im používať nástroje GFW na identifikáciu a elimináciu odlesňovania v ich dodávateľských reťazcoch. Fond malých grantov GFW poskytuje organizáciám občianskej spoločnosti technickú a finančnú podporu, ktorá im pomáha uplatňovať údaje GFW pri výskume, propagácii a práci v teréne.

10.7.1. Origin and evolution of GFW

Inštitút svetových zdrojov (WRI) založil Global Forest Watch v roku 1997 ako súčasť iniciatívy Forest Frontiers. Začala ako sieť mimovládnych organizácií, ktoré vypracúvali aktuálne správy o stave lesov v štyroch pilotných krajinách - Kamerune, Kanade, Gabone a Indonézii.

Do roku 2002 GFW rozšírila svoju činnosť do Čile, Ruska, Venezuely, Demokratickej republiky Kongo a Spojených štátov amerických, pričom uverejňovala správy o lesnom poraste a stave lesov, ako aj o činnostiach, ktoré majú vplyv na lesy, napríklad o

koncesiách a infraštruktúre. GFW plánovala do roku 2005 sprevádzkovať svoju sieť na monitorovanie lesov v 21 krajinách.

GFW začala spolupracovať s vládami v strednej Afrike na vytvorení interaktívnych online máp lesov a využívania pôdy s názvom Lesnícke atlasy v 2004. Prvá mapa bola vytvorená pre Kamerun v spolupráci s Ministerstvom životného prostredia a lesov Kamerunu (MINEF). Interaktívne mapy vytvorené na serveri ArcGIS spoločnosti ESRI sa čoskoro rozšírili na všetky krajiny pokryté GFW.

Počas nasledujúcich šiestich rokov GFW pokračovala vo vytváraní globálnych a regionálnych máp a analýz lesov a zároveň rozširovala národné mapovacie projekty s vládami. V roku 2006 GFW spolu s organizáciou Greenpeace vytvorili vôbec prvú globálnu mapu zostávajúcich neporušených lesných oblastí.

V roku 2014 WRI spustil GFW 2.0, ktorý nadviazal na takmer dve desaťročia práce a vytvoril plne interaktívnu online platformu s údajmi z monitorovania lesov na celom svete. Nová iterácia GFW bola možná vďaka pokroku v technológii monitorovania lesov a rozšírenej skupine partnerov.

S cieľom riešiť mnohé výzvy súvisiace s odlesňovaním sa GFW v 2015 začala rozširovať o niekoľko nových webových aplikácií - GFW Commodities na hodnotenie udržateľnosti v dodávateľských reťazcoch komodít a GFW Fires na monitorovanie lesných a pozemných požiarov a oparu zo smogu v JV Ázii.

S ďalším vývojom satelitnej technológie sa GFW rozšírila nad rámec ročných údajov o lesoch a začala poskytovať mesačné a týždenné upozornenia o odlesňovaní. Vďaka emailovému predplatnému sa tieto upozornenia dostali priamo do rúk používateľov, čím sa zvýšila ich schopnosť reagovať na nové aktivity takmer v reálnom čase.

V roku 2017 spoločnosť GFW spustila mobilnú aplikáciu Forest Watcher, ktorá umožňuje používateľom preniesť údaje a nástroje GFW do terénu aj off-line. Táto aplikácia predstavuje nový krok v priamom prepojení ľudí pracujúcich v lesoch s informáciami, ktoré potrebujú na ich ochranu.

V roku 2018 GFW zverejnila nové údaje, ktoré ukazujú dominantné faktory úbytku stromovej pokrývky vrátane tých, ktoré vedú k odlesňovaniu. GFW tiež vydala nové a vylepšené informačné panely, ktoré poskytujú prehľad o príčinách a vplyvoch zmien v lesoch.

Na základe spolupráce s poprednými finančnými a komoditnými spoločnosťami bola v roku 2019 spustená aplikácia GFW Pro, ktorá má pomôcť podnikom so zámerom riadiť riziko odlesňovania v ich dodávateľských reťazcoch. Medzitým pridanie podkladových máp s vysokým rozlíšením, údajov o plantážach pre 82 krajín a údajov o primárnych lesoch v pan-tropickom pásme poskytlo používateľom nový spôsob pochopenia zmien lesov na mapách GFW.

10.7.2. Destruction of primary rainforests to increase by 12% from

2019 to 2020

Podľa aktuálnych (2021) údajov z Marylandskej univerzity, ktoré sú k dispozícii na stránke Global Forest Watch, tropické oblasti stratili v roku 2020 12,2 milióna hektárov stromovej pokrývky.

Z toho 4,2 milióna hektárov, čo je plocha veľkosti Holandska, pripadá na vlhké tropické pralesy, ktoré sú mimoriadne dôležité pre ukladanie uhlíka a biodiverzitu. Výsledné emisie uhlíka z tohto úbytku primárnych lesov (2,64 Gt CO2) sa rovnajú ročným emisiám 570 miliónov áut, čo je viac ako dvojnásobok počtu áut na cestách v Spojených štátoch.

Úbytok primárnych lesov bol v roku 2020 o 12 % vyšší ako v predchádzajúcom roku a bol to druhý rok po sebe, keď sa úbytok primárnych lesov v tropických oblastiach zhoršil (Obr. 10.47) a (Obr. 10.48).







Top 10 Countries for 2020 Primary Forest Loss



Rok 2020 mal byť prelomovým rokom v boji proti odlesňovaniu - v tomto roku sa mnohé spoločnosti, krajiny a medzinárodné organizácie zaviazali znížiť úbytok lesov na polovicu alebo ho úplne zastaviť. Pokračujúci úbytok primárnych tropických lesov jasne ukazuje, že ľudstvo tieto ciele nesplnilo.

10.7.3. New radar alerts monitor forests through clouds (Senitel-1)

Dažďové pralesy sú často ovplyvnené dlhodobými zrážkami - čo znamená, že sú aj často ukryté pod oblačnosťou. Ako je zrejmé, to predstavuje problém pre monitorovanie lesov, pretože optické satelitné snímky nie sú schopné "vidieť" cez prekážky, ako sú mraky, dym a opar. Nový výstražný systém RADD (Radar for Detecting Deforestation) v službe Global Forest Watch však pomocou radarových údajov zo satelitov zisťuje narušenie lesov ako za dažďa tak za slnečného počasia.

Výstrahy RADD sú vytvorené na základe prvých globálnych, voľne dostupných radarových údajov zo satelitov Sentinel-I Európskej Vesmírnej Agentúry. Tieto radarové výstrahy slúžia ako ďalší nástroj na rýchle odhalenie nedávneho odlesňovania a prijatie zodpovedajúcich opatrení. Základné informácie o výstražnom systéme RADD GFW:

1. Dokáže odhaliť zmeny rýchlejšie ako kedykoľvek predtým:

Zatiaľ čo existujúce výstrahy GFW (založené na optických údajoch) hlásia zmeny hneď po ich zistení, niekedy môže trvať mesiace, kým sa získa snímka bez oblakov a identifikuje sa zmena. Oneskorenie výstrah sťažuje reakciu na prípady nezákonného odlesňovania - v niektorých prípadoch už ľudia, ktorí odlesňovali, mohli odísť.

Rádiové vlny vysielané radarovými satelitmi nie sú obmedzované oblačnosťou; ich dlhšie vlnové dĺžky im umožňujú preniknúť cez mraky až na zem. Vďaka satelitu Sentinel-1 má teraz verejnosť bezplatný prístup k radarovým údajom, ktoré pokrývajú tropické oblasti každých 6 až 12 dní. Vďaka tomu môžu výstrahy RADD založené na týchto údajoch spoľahlivo odhaliť odlesňovanie a iné narušenia lesa s minimálnym oneskorením. Pomocou výstrah RADD budú môcť užívatelia reagovať na odlesňovanie skôr ako kedykoľvek predtým, čo im poskytne výhodu pri predchádzaní ďalším stratám.

2. Zachytáva zmeny v lesoch s vysokým rozlíšením

Výstrahy RADD využívajú vysokú úroveň priestorového rozlíšenia Sentinel-1 pre zisťovanie zmien v rámci 10-metrových pixelov. To je deväťkrát podrobnejšie ako súčasné produkty založené na údajoch Landsat, ktoré merajú zmeny v 30metrovom rozlíšení. To znamená, že pomocou výstrah RADD je možné zistiť aj malé zmeny v rozsahu niekoľkých stromov.

Napríklad väčšina ťažby dreva z tropických lesov sa uskutočňuje prostredníctvom selektívnej ťažby jednotlivých cenných stromov, ako je teak alebo mahagón. Zvýšená podrobnosť výstrah RADD znamená, že teraz je možné jasnejšie vidieť vplyv tejto ťažby, čo je dôležitá informácia pre tých, ktorí bojujú proti nelegálnej ťažbe (Obr. 10.49).



Obr. 10.49 Výstrahy RADD identifikujúce miesta selektívnej ťažby okolo novej cesty v Stredoafrickej republike.

Fig. 10.49 RADD alerts detect patches of selective logging around a new road in the Central African Republic.

Source: globalforestwatch.org/blog/data-and-research/radd-radar-alerts

3. Upozornenia RADD sa vzťahujú na 44 krajín

Výstražný systém RADD sa nedávno rozšíril o povodie Amazonky. Pokrytie teraz zahŕňa tropické lesy v Južnej Amerike, ostrovnej juhovýchodnej Ázii a Afrike vrátane lesov v Indonézii, Malajzii, Konžskej demokratickej republike, Konžskej republike, Kamerune, na Madagaskare, v Brazílii, Kolumbii, Peru a ďalších krajinách (Obr. 10.50). Systém RADD v súčasnosti zisťuje zmeny len v primárnych tropických lesoch, v budúcnosti v budúcnosti sa plánuje zlepšiť zisťovanie aj v iných typoch lesov.

Systém je vhodný na to, aby sa v budúcnosti rozšíril aj na zvyšok tropického regiónu. Údaje Sentinel-1 sú ľahko dostupné pre celú zemeguľu a výstrahy RADD fungujú v rámci Google Earth Engine s dostatočným výpočtovým výkonom na vykonávanie globálnych analýz.

4. Využitie upozornení z RADD pre udržateľnosť dodávateľského reťazca

Vývoj výstrah RADD iniciovalo desať najväčších svetových výrobcov a nákupcov palmového oleja, ktorí chceli pokročiť v systéme monitorovania odlesňovania, ktorý by nebol obmedzovaný oblačnosťou, aby mohli spoľahlivejšie zisťovať a riešiť zmeny vo svojich dodávateľských reťazcoch.



Obr. 10.50 Pokrytie výstražného systému RADD. **Fig. 10.50** RADD radar alerts cover. Source: globalforestwatch.org/blog/data-and-research/radd-radar-alerts

10.8. Deforestation in Slovakia

Z analýzy satelitných snímok Inštitútu environmentálnej politiky (IEP), ktorý porovnával stratu lesa v rokoch 2017 až 2020 s rokmi 2001 až 2016, vyplýva, že za posledné 4 roky (2017-2020) narástol priemerný ročný úbytok lesa takmer o štvrtinu. Vysoké odlesnenie zaznamenal medzi rokmi 2017 až 2020 Národný park Veľká Fatra a Národný park Malá Fatra, kde sa priemerná ročná strata lesa zvýšila 3 resp. 4-násobne (Obr. 10.51).

Od začiatku 21. storočia ubudlo zo slovenských lesov každý rok v priemere 0,46 % rozlohy lesa. S výnimkou kalamitného roku 2004 zažilo Slovensko najväčšiu stratu lesa v roku 2018, pričom najviac postihnutým regiónom za ostatných 20 rokov bol región Kysúc. Tento stav sa nezmenil ani v uplynulých štyroch rokoch. V národných parkoch bola v rokoch 2017 až 2020 priemerná ročná strata lesa na úrovni 0,56 %. Podľa satelitných snímok boli regionálne na tom najlepšie lesy na východnom Slovensku a na Hornej Nitre. Naopak, najhoršie skončili oblasti na Kysuciach a podtatranské okresy Poprad a Kežmarok. Lepší stav vykazujú územia s 5. stupňom ochrany s bezzásahovým režimom.

Odlesňovanie je podľa satelitných snímok dlhodobým problémom Slovenska, a to aj napriek pomerne vysokej výmere lesov. Skutočnosť, že máme na Slovensku v evidencii lesný pozemok neznamená, že sa na ňom nachádza aj skutočný les. Podobne je to aj s výmerami lesov, kde by mal byť podľa mapových údajov les, ale v skutočnosti nám letecké snímky ukážu, že tam žiadny les nie je.

Rozdiel medzi inými hodnoteniami výmer lesov je, že IEP využíva medzinárodné satelitné snímky, ktoré poukazujú na reálnu skutočnosť lesných pozemkov a dokážu objektívne vyhodnotiť stav lesov. Analytici používali už spracované údaje satelitných snímok z portálu Global Forest Watch. Tie využívajú vegetačný index na identifikáciu lesa (nástroj identifikuje iba starší les s výškou cca 5 metrov) na ploche 30x30 metrov. Ak je na danej ploche aspoň 30 % pokryv stromov, tak sa plocha považuje za les.

V národných parkoch sa les v posledných 20-tich rokoch strácal rýchlejšie ako v iných územiach. Ide však o hrubú stratu bez prírastkov. Analytici zároveň poukázali na stav bezzásahových území, ktorý bol z pohľadu straty lesa a následného dopadu na záchyty uhlíka lepší ako stav iných území.



Obr. 10.51 Odlesňovanie v Demänovskej doline, Nízke Tatry, medzi rokmi 2006 - 2021. **Fig. 10.51** Deforestation in Demänovská dolina, Low Tatras, between 2006 and 2021. Source: Google Earth Pro, 2021

Ďalšie informácie o lesoch na Slovensku, odlesňovaní, a ochrane lesov je možné nájsť na portáli národného lesníckeho centra (NLC):

https://web.nlcsk.org/

a na portáli o lesoch Slovenska:

http://www.forestportal.sk/

References

Books

Helms, J.A. (1998). The Dictionary of Forestry. Wallingford: Cab International and Society of American Foresters, p.210. ISBN 9780851993089

Cherrick, J. (2019). TRees. Nature Study Hacking ed. Independently published, p.65. ISBN 978-1797822723.

Lillesand, T.M., Kiefer, R.W. and Chipman, J.W. (2015). Remote sensing and image interpretation. Hoboken, N.J.: John Wiley & Sons, Inc. 770p. ISBN 978-1-118-34328-9.

Blanc, L., Gond, V., & Minh, D. H. T. (2016). 2—Remote Sensing and Measuring Deforestation. In N. Baghdadi & M. Zribi (Eds.), Land Surface Remote Sensing (pp. 27–53). Elsevier. DOI: 10.1016/B978-1-78548-105-5.50002-5.

Achard, F. and Hansen, M.C. (2016). Global Forest Monitoring from Earth Observation. 1st ed. Boca Raton, FL, U.S.: CRC Press, Taylor & Francis Group, p. 346. ISBN 978-1-4665-5202-9.

Jensen, J. R. (2014). Remote sensing of the environment an earth resource perspective (2nd ed., p. 619). Pearson Education Limited. ISBN 978-1-292-02170-6.

Kuenzer, C., Dech, S., & Wagner, W. (Eds.). (2015). Remote sensing time series : revealing land surface dynamics (p. 458). Springer International Publishing AG. ISBN 978-3-319-15967-6.

Flores-Anderson, Africa Ixmucane, Kelsey E. Herndon, Emil Cherrington, Rajesh Thapa, Leah Kucera, Nguyen Hanh Guyen, Phoebe Odour, Anastasia Wahome, Karis Tenneson, Bako Mamane, David Saah, Farrukh Chishtie, and Ashutosh Limaye. "Introduction and Rationale" SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation. Eds. Flores, A., Herndon, K., Thapa, R., Cherrington, E. NASA. 2019. DOI: 10.25966/1rgr-q551.

Thenkabail, P. S., Lyon, J. G., & Huete, A. (2019). Hyperspectral remote sensing of vegetation. Volume IV, Advanced applications in remote sensing of agricultural crops and natural vegetation (p. 427). CRC Press Taylor & Francis Group. ISBN 978-1-138-36476-9.

Papers, manuals, reports

European Commission, Directorate-General for Environment, Atzberger, C., Zeug, G., Defourny, P., et al. (2020) Monitoring of forests through remote sensing: final report. Publications Office. 149p. https://data.europa.eu/doi/10.2779/175242

Jones S., Reinke K., Mitchell S., McConachie F. and Holland C., (2017) Remote sensing of active fires: a review – detection, mapping and monitoring v1.0. Melbourne: Bushfire and Natural Hazards CRC. 38p.

Gitas, I. (2015). Remote Sensing of forest fires (focus on Mediterranean ecosystems). Lecture, Laboratory of Forest Management and Remote Sensing School of Forestry & Natural Environment, Aristotle University of Thessaloniki Greece. 46p.

De Simone, W., Di Musciano, M., Di Cecco, V., Ferella, G., & Frattaroli, A. R. (2020). The potentiality of Sentinel-2 to assess the effect of fire events on Mediterranean mountain vegetation. Plant Sociology, 57(1), pp.11–22. DOI: 10.3897/pls2020571/02.

Nikolov, C., Konôpka, B., Kajba, M., Galko, J., Kunca, A., & Janský, L. (2014). Post-disaster Forest Management and Bark Beetle Outbreak in Tatra National Park, Slovakia. Mountain Research and Development, 34(4), pp.326–335. DOI: 10.1659/mrd-journal-d-13-00017.1.

Wang, W., Qu, J. J., Hao, X., Liu, Y., & Stanturf, J. A. (2010). Post-hurricane forest damage assessment using satellite remote sensing. Agricultural and Forest Meteorology, 150(1), pp.122–132. DOI: 10.1016/j.agrformet.2009.09.009.

Helman, D. (2018). Land surface phenology: What do we really "see" from space?. Science of the Total Environment, 618, pp.665–673. DOI: 10.1016/j.scitotenv.2017.07.237.

Mitchell, A. L., Rosenqvist, A., & Mora, B. (2017). Current remote sensing approaches to monitoring forest degradation in support of countries measurement, reporting and verification (MRV) systems for REDD+. Carbon Balance and Management, 12(1). DOI: 10.1186/s13021-017-0078-9.

Hirschmugl, M., Gallaun, H., Dees, M., Datta, P., Deutscher, J., Koutsias, N., & Schardt, M. (2017). Methods for Mapping Forest Disturbance and Degradation from Optical Earth Observation Data: a Review. Current Forestry Reports, 3(1), p.32–45. DOI: 10.1007/s40725-017-0047-2.

Hirschmugl, M., Deutscher, J., Sobe, C., Bouvet, A., Mermoz, S., & Schardt, M. (2020). Use of SAR and Optical Time Series for Tropical Forest Disturbance Mapping. Remote Sensing, 12(4), 727. DOI: 10.3390/rs12040727. Kellndorfer, J. (2019). "Using SAR Data for Mapping Deforestation and Forest Degradation." SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation. Eds. Flores, A., Herndon, K., Thapa, R., Cherrington, E. NASA. 16p. DOI: 10.25966/68c9-gw82.

Alpers, W., Zhang, B., Mouche, A., Zeng, K., & Chan, P. W. (2016). Rain footprints on C-band synthetic aperture radar images of the ocean - Revisited. Remote Sensing of Environment, 187, p.169–185. DOI: 10.1016/j.rse.2016.10.015.

Lambini, C. K., Nguyen, T. T., Abildtrup, J., Pham, V. D., Tenhunen, J., & Garcia, S. (2018). Are Ecosystem Services Complementary or Competitive? An Econometric Analysis of Cost Functions of Private Forests in Vietnam. Ecological Economics, 147, 343–352. DOI: 10.1016/j.ecolecon.2018.01.029.

Chang, J. & Shoshany, M. (2016). "Mediterranean shrublands biomass estimation using Sentinel-1 and Sentinel-2," IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2016, pp. 5300-5303. DOI: 10.1109/IGARSS.2016.7730380.

Minzp.sk. (2022). Satelitné snímky potvrdzujú úbytok lesov na Slovensku. [online] [Accessed 18 November 2021]. Sharma, A. (2020, June 17). Monitoring Wildfires using Earth Observation Satellites. Towards Data Science;

Medium. towardsdatascience.com/monitoring-wildfires-using-earth-observation-satellites-e3ee7113bae4.

Web sources

gwis.jrc.ec.europa.eu earthengine.google.com globalforestwatch.org web.nlcsk.org www.forestportal.sk www.lesy.sk

Applications of RS -Water, Ice, Snow

Water is an essential component of almost every human activity. Even at the beginning of the 21st century, scarce water resources were in high demand for agriculture, domestic consumption, hydropower, sanitation, industrial production, transport, recreational activities and ecosystem services. Water can also pose dangers - whether due to flooding, pollution or the spread of waterborne diseases. There are many, often very important, uses of RS in water resources management.

Given the limitations of ground-based observations, the availability of RS products serves as an important resource for researchers, water resource managers, and related stakeholders. RS is a cost-effective method for monitoring large water bodies with high temporal coverage and reasonable accuracy, which is not physically possible through in-situ measurements. Extensive coverage of areas with satellite data helps to understand the evolution of hazards, which is critical for resource management. This section considers three important areas, 1) quality assessment, 2) quantity, which includes streamflow, terrestrial water storage, and reservoir monitoring, and 3) extreme events, which include floods and droughts.

An important part of the chapter is a section on snow and ice monitoring. Much of the Earth's surface is covered by snow, ice or frozen ground for at least part of the year, particularly at high latitudes. Snow is usually highly reflective in the visible spectrum, with stronger absorption in parts of the mid-infrared bands. Its spectral response may vary depending on density, grain size, liquid water content and the presence of impurities such as dust, soot and algae. It is also the case that as global climate change continues and accelerates, cryosphere research has emerged as one of the key disciplines in climate change studies. In addition to measuring changes in the height or dynamics of the calving glacier during potential glacier retreat, SAR and optical RS data also allow monitoring of surface melt, pre-frontal sea ice and glacier conditions, or ice velocity.

· e esa

FBERG

11.1. Water

Voda je nevyhnutnou zložkou takmer každej ľudskej činnosti. Už na začiatku 21. storočia boli vzácne vodné zdroje veľmi žiadané pre poľnohospodárstvo, domácu spotrebu, vodnú energiu, hygienu, priemyselnú výrobu, dopravu, rekreačné aktivity a ekosystémové služby. Napriek tomu sa stále vyvíjajú nové potreby vody – najmä v oblasti ťažby a rozvoja prírodných zdrojov, kde sa v súčasnosti používa obrovské množstvo vody vo všetkom, od ťažby po spracovanie, čo v niektorých prípadoch umožňuje získavanie nerastných surovín, kde by sa inak nedali získať. Voda môže zároveň predstavovať nebezpečenstvo – či už v dôsledku záplav, znečistenia alebo šírenia chorôb prenášaných vodou. Existuje mnoho spôsobov, často veľmi dôležitých, využitia DPZ v manažmente vodných zdrojov.

Vo všeobecnosti platí, že väčšina slnečného žiarenia ktoré vstupuje do čistého vodného útvaru je absorbovaná do vzdialenosti asi 2 m od hladiny. Stupeň absorpcie samozrejme závisí od vlnovej dĺžky (Obr. 11.1). Blízke infračervené vlnové dĺžky sú absorbované len v niekoľkých desatinách metra vody, čo vedie k veľmi tmavým tónom obrazu dokonca aj plytkých vodných útvarov na snímkach v blízkej infračervenej oblasti. Absorpcia vo viditeľnej časti spektra sa značne líši v závislosti od charakteristík skúmaného vodného útvaru. Z hľadiska detekcie objektov v stĺpci čistej vody alebo na jeho dne sa najlepšie prenikanie svetla dosiahne pri relatívne krátkych vlnových dĺžkach (napr. 0,48 až 0,60 mm). V tomto pásme vlnových dĺžok bola hlásená penetrácia až do asi 20 m v čistej, pokojnej oceánskej vode. Hoci kratšie vlnové dĺžky na modrom konci spektra prenikajú dobre, sú značne rozptýlené a výsledkom je tzv. "podvodný opar". Červené vlnové dĺžky prenikajú vo vode len do niekoľkých metrov, ale môžu byť obzvlášť dôležité v mnohých aplikáciách kvality vody ako indikátor prítomnosti suspendovaných sedimentov alebo pigmentov rias, ako je chlorofyl. Krivka spektrálnej odrazivosti vody je znázornená na Obr. 11.2.



Obr. 11.1 Interakcia slnečného žiarenia a vody. **Fig. 11.1** Interaction of sunlight and water.

Source: ©FlyFishingScience; flyfishingscience.co.uk/2018/10/19/light-attenuation-in-water



Obr. 11.2 Spektrálna odrazivosť vody v porovnaní s pôdou a zelenou vegetáciou. **Fig. 11.2** Spectral reflectance of water compared to soil and green vegetation. Source: seos-project.eu/classification/classification-c01-p05.html

Metódy DPZ s rozsahom mimo viditeľného/blízkeho infračerveného pásma sú tak isto používané pri monitorovaní vodných zdrojov. Obzvlášť vhodné pre túto oblasť použitia sú termálne senzory, pretože vysoká a takmer rovnomerná tepelná vyžarovacia schopnosť vody umožňuje spoľahlivo vypočítať skutočnú kinetickú teplotu vodnej hladiny. V mikrovlnnom spektre sú radarové signály ovplyvnené drsnosťou vodnej hladiny a prítomnosťou vlhkosti v horných vrstvách nezarastených pôd, pričom pasívne mikrovlnné rádiometre sú citlivé aj na pôdnu vlhkosť.

11.1.1. Water quantity and distribution

Snímky DPZ – optické aj radarové – sú dobre použiteľné na mapovanie polohy a priestorového rozsahu vodných útvarov vrátane jazier, rybníkov, riek a zaplavených mokradí. Spolu s týmito dvojrozmernými informáciami je možné získať tretí rozmer (hladinu vody) pomocou radarových altimetrov alebo lidaru. V priebehu času môže monitorovanie povrchovej plochy alebo hladiny vody indikovať rozšírenie alebo zmenšenie vodných útvarov v dôsledku záplav alebo sucha a kombinácia týchto dvoch metód môže poskytnúť kvantitatívne merania zmien objemu vody.

Obr. 11.3 znázorňuje použitie satelitných snímok na monitorovanie záplav na regionálnej úrovni. Údaje Copernicus Sentinel-2 z 26. októbra 2019 a 10. novembra ukazujú zaplavenie mokradí v Benátskej zátoke a naznačujú tak stúpajúcu hladinu vody, ktorá zaplavila aj veľké časti samotných Benátok. Na ľavej strane je situácia znázornená ako CIR kompozit vo falošných farbách. Na pravej strane je zobrazený príslušný vodný index vypočítaný z pásiem Sentinel-2 zobrazujúci vodné plochy modrou farbou. Voda odráža najmä modré a zelené časti slnečného svetla, zatiaľ čo infračervené absorbuje. Výsledkom je, že voda sa v infračervených pásmach Sentinel-2 javí ako veľmi tmavá, zatiaľ čo vo viditeľných pásoch sa javí jasnejšia. Tento spektrálny rozdiel pre vodu je pomerne jedinečný a výpočet rozdielu medzi viditeľným a infračerveným pásmom na celej snímke tak umožňuje vygenerovať mapu oblastí zaplavených vodou.



Obr. 11.3 Záplavy v Benátskej zátoke v roku 2019 na snímke Sentinel-2. **Fig. 11.3** Floods in the Laguna of Venice in 2019 on Sentinel-2 image. Source: Contains modified Copernicus Sentinel data (2019)/processed by the Department of Geosciences, University of Oslo

Obr. 11.4 znázorňuje kombináciu radarových snímok Copernicus Sentinel-1B z 5. a 17. novembra 2019 v Benátkach. Táto kombinácia jasne ukazuje zaplavené mokrade červenou farbou. Keďže radarové satelity Copernicus Sentinel-1 snímajú Zem zo šikmého uhla, tak "neuvidia" do úzkych uličiek Benátok, aby tam rozpoznali zaplavené časti. Avšak zaplavenie mokradí v okolí Benátok je priamym indikátorom vysokej hladiny vody v celej zátoke. Keďže k záplavám často dochádza počas obdobia zrážok a teda aj veľkej oblačnosti, SAR dáta s ich schopnosťou snímať a poskytovať dáta za každého počasia môžu byť obzvlášť užitočným zdrojom údajov pre monitorovanie záplav.



Obr. 11.4 Záplavy v Benátskej zátoke v roku 2019 na kombinácii snímok Sentinel-1. **Fig. 11.4** Floods in the Laguna of Venice in 2019 on Sentinel-1 image combination. Source: Contains modified Copernicus Sentinel data (2019)/processed by the Department of Geosciences, University of Oslo

Pre zásobovanie vodou a analýzu kontroly znečistenia je dôležité aj monitorovanie podzemnej vody. Identifikácia topografických a vegetačných ukazovateľov podzemnej vody a určenie polohy oblastí vypúšťania podzemnej vody (prameňov a priesakov) môže pomôcť pri lokalizácii potenciálnych lokalít studní, vodných rezervoárov, podzemných vodných zdrojov. Je tiež dôležité vedieť identifikovať zóny kde dochádza k presakovaniu do podzemných vôd, aby sa tieto oblasti chránili pred činnosťami, ktoré by znečisťovali zásoby podzemných vôd. Vo väčších oblastiach – regionálne až kontinentálne – možno zmeny v podzemnej vode odvodiť z modelov zemského gravitačného poľa odvodených zo satelitov, ako napr. GRACE.

11.1.2. Water quality

Všetka prirodzene sa vyskytujúca voda obsahuje aj iné látky. Keď tieto látky ovplyvňujú optické vlastnosti vodného stĺpca, označujú sa ako činidlá vytvárajúce farbu. Medzi najdôležitejšie z týchto činidiel patrí suspendovaný sediment, chlorofyl a iné riasové pigmenty a farebné rozpustené organické látky alebo rozpustený organický uhlík (Obr. 11.5). Vo vodnom útvare môže byť prítomných množstvo ďalších látok a ich pôvod, význam a účinky sa môžu značne líšiť. Nečistoty môžu byť prirodzene sa vyskytujúce alebo môžu byť výsledkom antropogénneho znečistenia; môžu byť životu nebezpečné alebo úplne neškodné; a môžu mať silný vplyv na optické vlastnosti vody alebo vôbec žiadny zistiteľný účinok. Na hodnotenie kvality vody pomocou DPZ bola vyvinutá široká škála vizuálnych a automatizovaných metód. Voda sa považuje za znečistenú, ak je prítomnosť nečistôt dostatočná na to, aby obmedzila jej použitie na daný domáci a/alebo priemyselný účel. Nie všetky znečisťujúce látky sú výsledkom ľudskej činnosti. Medzi prirodzené zdroje znečistenia patria minerály vylúhované z pôdy a rozkladajúca sa vegetácia. Pri riešení znečistenia vôd je vhodné zvážiť dva typy zdrojov: bodové a bezbodové. Bodové zdroje sú vysoko lokalizované, ako napríklad priemyselné výstupy. Nebodové zdroje, ako sú hnojivá a sedimenty z poľnohospodárskych polí, majú veľké a rozptýlené zdrojové oblasti.



Obr. 11.5 Vizualizácia obsahu chlorofylu a suspendovaného sedimentu v jazere Balaton (Maďarsko) zo snímky Sentinel-2 pomocou skriptu Ulyssys Water Quality Viewer (UWQV). **Fig. 11.5** Visualisation of chlorophyll and suspended sediment content in Lake Balaton (Hungary) from Sentinel-2 imagery using the Ulyssys Water Quality Viewer (UWQV) script. Source: custom-scripts.sentinel-hub.com/custom-scripts/sentinel-2/ulyssys_water_quality_viewer

Každý z nasledujúcich materiálov môže prispieť k znečisteniu vody ak je prítomný v nadmerných množstvách:

- organické odpady pochádzajúce z odpadových vôd domácností a priemyselné odpady rastlinného a živočíšneho pôvodu, ktoré odstraňujú kyslík z vody prostredníctvom rozkladu;
- 2. infekčné látky pochádzajúce z odpadových vôd domácností a určitých druhov priemyselných odpadov, ktoré môžu prenášať choroby;
- 3. rastlinné živiny, ktoré podporujú nevhodný rast vodných rastlín, ako sú riasy a vodné trávy;
- synteticko-organické chemikálie, ako sú detergenty a pesticídy, ktoré sú výsledkom chemickej technológie a ktoré sú toxické pre vodné organizmy a potenciálne toxické pre ľudí;
- 5. anorganické chemické a minerálne látky pochádzajúce z ťažby, výrobných procesov, prevádzky v ropných závodoch a poľnohospodárskych postupov, ktoré narúšajú čistenie prírodných tokov, ničia ryby a vodný život, spôsobujú nadmernú tvrdosť vody, spôsobujú korozívne účinky a vo všeobecnosti zvyšujú náklady na úpravu vody;
- 6. sedimenty, ktoré zapĺňajú potoky, kanály, prístavy a nádrže, spôsobujú opotrebovanie zariadení vodných elektrární a čerpacích zariadení, ovplyvňujú populáciu rýb a mäkkýšov tým, že pokrývajú útočiská rýb, neresiská a zásoby potravy a zvyšujú náklady na úpravu vody;
- 7. rádioaktívne znečistenie vyplývajúce z ťažby a spracovania rádioaktívnych rúd, používania rafinovaných rádioaktívnych materiálov, a spád po jadrových testoch alebo jadrových haváriách;
- 8. zvýšenie teploty, ktoré je výsledkom používania vody na účely chladenia v parných elektrárňach a priemyselných odvetviach a zo zadržiavania vody v nádržiach, má škodlivé účinky na ryby a vodný život.

Veľký obsah sedimentov v riekach je väčšinou jasne znázornený na optických snímkach z DPZ. Obr. 11.6 zobrazuje rieku Tiber vytekajúcu do Tyrrhénskeho mora s vysokým obsahom bahna pochádzajúceho zo silných dažďov v regióne Lazio v Taliansku. Morská voda má nízku odrazivosť vo viditeľnej časti EMŽ. Odrazivosť nerozpustených látok z pôdy vo vode sa podobá odrazivosti pre klasickú krivku odrazivosti pôdy. Keďže vzor spektrálnej odrazivosti suspendovaných materiálov je odlišný od odrazivosti prírodnej morskej vody, tieto dva materiály je možné ľahko rozlíšiť na optických snímkach z DPZ.



Obr. 11.6 Suspendované sedimenty z rieky Tiber do Tyrrhénskeho mora po silných dažďoch v regióne Lazio (Taliansko) vo Februári 2019 na snímke Sentinel-2. **Fig. 11.6** Sediments from the Tiber River flows into the Tyrrhenian Sea after heavy rains in the Lazio region (Italy) in February 2019, visible on Sentinel-2 image. Source: contains modified Copernicus Sentinel data (2019), processed by ESA

Jedným z účinkov takto vyplavovaných sedimentov je, že často nesú živiny (z poľnohospodárskych oblastí, mestských oblastí a iných suchozemských zdrojov), ktoré môžu zmeniť trofický stav (stav živín) jazera alebo iného vodného útvaru. Jazero udusené vodnou burinou alebo jazero s mimoriadne výrazným obsahom rias sa nazýva eutrofné jazero (bohaté na živiny). Jazero s veľmi čistou vodou sa nazýva oligotrofné jazero (nízky obsah živín, vysoký obsah kyslíka). Všeobecný proces starnutia jazier sa označuje ako eutrofizácia. Eutrofizácia je prirodzený proces, ktorý sa odohráva v priebehu geologického času. Ak je však ovplyvnená ľudskou činnosťou, proces sa výrazne urýchli a môže viesť k "znečisteným" vodným podmienkam. Takéto procesy sa nazývajú kultúrna eutrofizácia a úzko súvisia s využívaním pôdy/krajinnej pokrývky.

Koncentrácie voľne plávajúcich rias sú dobrým ukazovateľom trofického stavu jazera. Nadmerné koncentrácie siníc sa vyskytujú najmä v eutrofných podmienkach. Sezónne kvitnutie siníc sa vyskytuje počas teplých vodných podmienok koncom leta, zatiaľ čo diatómy sú častejšie v studenej vode na jar a na jeseň. Zelené riasy sú zvyčajne prítomné v ktoromkoľvek bode sezónneho cyklu jazier. Keďže rôzne široké triedy rias majú trochu odlišné vlastnosti odrazivosti EMŽ, možno ich rozlíšiť pomocou leteckého a kozmického DPZ. Vlnové dĺžky zodpovedajúce maximálnej odrazivosti siníc a zelených rias sú však často blízko seba a najspoľahlivejšie výsledky možno získať použitím multispektrálnych alebo hyperspektrálnych senzorov s aspoň niekoľkými úzkymi pásmi v rozsahu vlnových dĺžok 0,45 až 0,60 mm. Kvitnúce riasy plávajúce na vodnej hladine alebo veľmi blízko nej majú tak isto vysokú odrazivosť v blízkom infračervenom pásme.

Na obrázku 11.7 je snímka Sentinel-2 v pravých farbách zobrazujúca kvitnúce zelené riasy v Baltskom mori.



Obr. 11.7 Kvitnúce zelené riasy v Baltskom mori na snímke Sentinel-2 v Júli 2019. **Fig. 11.7** Green algae blooms in the Baltic Sea as seen by Sentinel-2 in July 2019. Source: contains modified Copernicus Sentinel data (2019), processed by ESA

Vo väčšine Baltského mora sa každoročne vyskytujú dva druhy kvitnutia zelených rias – siníc, na jar a koncom leta. Baltské more čelí mnohým vážnym problémom vrátane toxických znečisťujúcich látok, nedostatku kyslíka v hlbokých vodách a toxického kvitnutia siníc, ktoré ovplyvňujú ekosystém, akvakultúru a cestovný ruch. Na tejto snímke z 20. júla 2019 sú jasne viditeľné pruhy a víry z neskorého letného kvitnutia siníc, ktoré pokrývajú more, keďže v týchto vodách rastie mnoho rôznych druhov rias. Najvyššia koncentrácia kvitnúcich rias sa vyskytuje v strednej časti Baltského mora a v okolí ostrova Gotland (na Obr. 11.7 vľavo). Hoci je kvitnutie rias prirodzenou a nevyhnutnou súčasťou života v mori, tak aj ľudská činnosť zvyšuje ich počet. Poľnohospodársky a priemyselný odpad vlieva do mora hnojivá, ktoré riasam dodávajú ďalšie živiny potrebné na ich tvorbu a rast. Baktérie, ktoré konzumujú rozkladajúce sa rastliny, vysávajú z vody kyslík a vytvárajú mŕtve zóny, v ktorých ryby nemôžu prežiť. Satelitné údaje môžu sledovať rast a šírenie škodlivých rias s cieľom upozorniť na nich a zmierniť ich škodlivý vplyv na cestovný ruch a rybársky priemysel.

Pomocou DPZ snímok je možné identifikovať aj materiály, ktoré vytvárajú na vodnej hladine vrstvy, ako napríklad ropné škvrny. Ropa sa do vodných útvarov dostáva z rôznych zdrojov vrátane prírodných priesakov, vypúšťania komunálneho a priemyselného odpadu, mestského splavovania a strát a nehôd v rafinériách a lodnej doprave. Husté ropné škvrny majú výraznú hnedú alebo čiernu farbu. Riedke ropné škvrny majú charakteristický strieborný lesk alebo opalizujúce farebné pásy, ale nemajú výraznú hnedú alebo čiernu farbu. Hlavné rozdiely v odrazivosti medzi vodnými plochami a olejovými vrstvami vo viditeľnom spektre sa vyskytujú medzi 0,30 a 0,45 mm. Najlepšie výsledky sa preto dosahujú, keď sú použité senzory citlivé na tieto vlnové dĺžky. Ropné

škvrny sa dajú identifikovať aj pomocou radarových dát vďaka tlmiacemu efekt ropných škvŕn na hladinu vody, čo sa prejaví na radarovej snímke. V dôsledku toho sa radarové snímky používajú aj ako súčasť procesu prieskumu ropy, pričom sa hľadajú malé prirodzené priesaky ropy v pobrežných oblastiach, ktoré môžu naznačovať väčšie ložiská v okolí.

Na Obr. 11.8 je snímka Sentinel-2 v pravých farbách z 11 Augusta 2020 zachycujúca tanker MV Wakashio, viditeľný v dolnej časti snímky, uviaznutý v blízkosti Pointe d'Esny (Maurícius), dôležitej mokraďovej oblasti. Ropnú škvrnu možno vidieť ako tenkú čiernu čiaru obklopenú jasnými tyrkysovými farbami Indického oceánu. Ropa je viditeľná v blízkosti lode, ako aj na iných miestach v okolí lagúny.





Fig. 11.8 A tanker crash and oil spill into the ocean off Mauritius as seen by Sentinel-2 in August 2020.

Source: contains modified Copernicus Sentinel data (2020), processed by ESA

Tanker MV Wakashio, ktorý údajne prevážal takmer 4 000 ton ropy, narazil 25. júla 2020 na koralový útes na juhovýchodnom pobreží Maurícia. Podľa správ médií z prasknutého plavidla uniklo do oceánu viac ako 1 000 ton paliva, ktoré znečistilo neďaleké koralové útesy, ako aj okolité pláže a lagúny. Ostrov Maurícius vyhlásil "stav ohrozenia životného prostredia" po tom, čo z odstaveného plavidla začali do Indického oceánu unikať tony ropy. Na monitorovanie prebiehajúceho úniku sa používajú práve snímky DPZ, ktoré ukazujú tmavú škvrnu šíriacu sa v blízkych vodách.

V reakcii na únik bola 8. augusta aktivovaná Medzinárodná Charta Vesmír a Veľké Katastrofy (International Charter Space and Major Disasters). Táto charta je medzinárodnou spoluprácou, ktorá poskytuje záchranárom a humanitárnym pracovníkom rýchly prístup k satelitným údajom v prípade katastrofy. Podľa správy o predbežnom hodnotení ropnej škvrny s využitím snímok z misie Copernicus Sentinel-2 bola zistená ropná škvrna s rozlohou približne 0,23 km² (Obr. 11.9).



Obr. 11.9 Mapový výstup zo správy o predbežnom hodnotení ropnej škvrny. **Fig. 11.9** Map output from the oil spill preliminary assessment report. Source: United Nations Institute for Training and Research, 2020

Na Obr. 11.10 je zase zachytená séria radarových snímok družice Sentinel-1 zachytávajúca prvé zábery úniku ropy zo zrážky dvoch lodí, ku ktorej došlo deň predtým v Stredozemnom mori severne od francúzskeho ostrova Korzika. Prvá snímka z rána 8 Októbra 2018 ukazuje, že ropná škvrna bola dlhá približne 20 km. Večer o 19:21 SELČ však snímky ukazujú, že škvrna sa predĺžila na približne 35 km. O 24 hodín neskôr, 9 Októbra o 19:14 SELČ, sa škvrna zväčšila na približne 60 km.

Na snímke z 9 Októbra je tiež vidieť veľkú čiernu škvrnu juhovýchodne od ropnej škvrny - je to dôsledok nízkej odrazivosti radarového signálu, čo zodpovedá pokojnej hladine vody.

Radarové snímky z DPZ sú teda obzvlášť užitočné na monitorovanie vývoja ropných škvŕn, pretože prítomnosť ropy na povrchu mora tlmí pohyb vĺn. Keďže radar v podstate meria štruktúru povrchu, ropné škvrny sú dobre viditeľné - ako čierne šmuhy na sivom pozadí.



Obr. 11.10 Rozširovanie ropnej škvrny po havárií dvoch lodí v Stredozemnom mori v roku 2018. **Fig. 11.10** Oil spill spreads after two ships collision in the Mediterranean Sea in 2018. Source: contains modified Copernicus Sentinel data (2018), processed by ESA

11.2. Importance of water

Z dostupných vodných zdrojov len asi 2,5 % z celkového množstva vody na Zemi tvorí sladká voda, z toho 1,5 % je využiteľných pre rôzne biofyzikálne procesy. Trvalo udržateľné hospodárenie s vodnými zdrojmi a zabezpečenie vodnej bezpečnosti sú životne dôležité pre vytváranie zodpovedných politík na zachovanie ekologického a ekonomického zdravia regiónu. Podľa OSN sa predpokladá, že svetová populácia sa do roku 2050 zvýši na 9,7 miliardy a do roku 2100 na 11 miliárd. Vzhľadom na rastúcu populáciu a ekonomiku je nárast dopytu po vode a globálny nedostatok vody nevyhnutný. Spotreba vody na obyvateľa sa podstatne zvýšila, čo spôsobilo zvýšenie získavania a využívania sladkovodných zdrojov z 500 km3/rok na 3800 km3/rok za posledných 100 rokov. Okrem toho, aby sa dosiahla potravinová bezpečnosť, došlo k rýchlemu rozšíreniu oblastí s ornou pôdou, čo spôsobuje nadmerné využívanie zdrojov podzemnej vody na zavlažovanie. Používanie hnojív na zvýšenie produktivity plodín ovplyvňuje kvalitu vody, poškodzuje morské a sladkovodné ekosystémy. Nárast spotreby priemyselnej vody bez vhodných politík na riadenie priemyselných odpadových vôd a recykláciu vody, najmä v rozvojových krajinách, vyvoláva obavy o udržanie kvality vody a minimalizáciu zdravotných problémov súvisiacich s vodou.

Nerovnováha medzi rozvojom a užitočnosťou zdrojov predstavuje veľkú výzvu pre hospodárenie s vodnými zdrojmi. Extenzívne využívanie vody negatívne ovplyvnilo ekosystém nadmerným využívaním zásob podzemnej vody a zmenšovaním odtokových oblastí jazier, riek a mokradí. Situácia sa pravdepodobne zhorší podľa scenára zmeny klímy, od ktorého sa očakáva, že ovplyvní sladkovodný systém zvýšením teploty, zvýšením hladiny morí, premenlivosťou zrážok a zvýšením extrémnych udalostí. Podľa Medzivládneho Panelu o Zmene Klímy - IPCC (Intergovernmental Panel on Climate Change) je pri zvýšení teploty o 1,5°C 178 miliónov ľudí z populácie suchých oblastí zraniteľných voči vodnému stresu. Odhaduje sa, že toto číslo sa zvýši na 220 a 270 miliónov ľudí so zvýšením teploty o 2°C a 3°C. Nárast globálnej priemernej povrchovej teploty vzduchu počas 20. storočia pravdepodobne premení časť snehových zrážok na zrážky že obdobie topenia snehu sa začne skôr, čo spôsobí zmeny v načasovaní a objeme odtoku vznikajúceho pri topení snehu. Zvýšenie teploty a súvisiace topenie polárneho ľadu "veľmi pravdepodobne" spôsobí zvýšenie hladiny morí, čo bude mať za následok prenikanie slanej vody do podzemných vôd, čím sa podzemná voda stane nepoužiteľnou a následne sa zníži dostupnosť zdrojov podzemnej vody.

Hoci existuje značná neistota spojená s vplyvom klimatických zmien na globálny vodný cyklus, väčšina štúdií naznačuje jeho zintenzívnenie v dôsledku zvýšenia vyparovania a následne aj zrážok. Zintenzívnený hydrologický cyklus môže viesť k častým výskytom extrémnych udalostí, ako sú suchá, povodne a cyklóny, ktoré pravdepodobne spôsobia katastrofické škody. To môže mať väčšie škodlivé účinky v rozvojových krajinách v dôsledku obmedzených zdrojov na zmierňovacie a adaptačné stratégie. Okrem očakávaných účinkov zmeny klímy na sektor vodného hospodárstva, zvýšenie dopytu po vode spolu s nedostatočným efektívnym riadením prispieva k výzve udržania kvality vody a efektívneho využívania vodných zdrojov.

11.3.Main tasks of RS in water monitoring

Organizácia Spojených národov uznala poskytovanie čistej vody a sanitácie za jeden z cieľov trvalo udržateľného rozvoja. Na dosiahnutie cieľov udržateľného rozvoja sa vedeckou paradigmou stal integrovaný manažment vodných zdrojov. Riadenie dostupnosti vodných zdrojov v rámci prebiehajúcich globálnych zmien si vyžaduje nepretržité monitorovanie dostupnosti vody a jej slabých miest v priestore a čase. Hydrometeorologické informácie (napr. zrážky, prietok a vlhkosť pôdy) zohrávajú zásadnú úlohu pri zlepšovaní hospodárenia s vodnými zdrojmi a pri kvantifikácii extrémnych udalostí. Presné meranie a monitorovanie hydrometeorologických premenných prostredníctvom pozorovaní in situ je niekedy náročné z dôvodu zastaraných alebo neexistujúcich socioekonomických údajov a zhoršujúcej sa pozorovacej siete. In-situ monitorovacie stanice sú často nerovnomerne rozmiestnené, prípadne v niektorých krajinách fungujú prerušovane z dôvodu nedostatočných investícií do infraštruktúry, nedostatočného inštitucionálneho rámca, nezáujmu vlády a neschopnosti pochopiť potrebu dlhodobých záznamov, čo vedie k nedostatku súvislých časových radov pre rôzne hydrometeorologické premenné. Hydroklimatické údaje získané in situ z meracích prístrojov poskytujú cenné informácie pre riadenie vodných zdrojov; tieto údaje však majú kľúčové obmedzenia, napríklad nedostatočné priestorové pokrytie a chýbajúce súbory údajov vo väčšine častí sveta (okrem niekoľkých rozvinutých krajín).

Vzhľadom na obmedzenia pozemných pozorovaní slúži dostupnosť produktov DPZ ako dôležitý zdroj pre výskumníkov, manažérov vodných zdrojov a súvisiace zainteresované strany. DPZ je ekonomicky efektívna metóda na sledovanie veľkých vodných útvarov s vysokým časovým pokrytím a primeranou presnosťou, čo nie je fyzicky možné prostredníctvom meraní in-situ. Rozsiahle pokrytie oblastí satelitnými údajmi pomáha pochopiť vývoj nebezpečenstiev, čo je rozhodujúce pre riadenie zdrojov. V tejto časti budeme brať do úvahy tri dôležité oblasti, 1) hodnotenie kvality vody, 2) množstvo vody, ktoré zahŕňa prietoky, skladovanie suchozemskej vody a monitorovanie nádrží, a 3) extrémne udalosti, ktoré zahŕňajú povodne a suchá. Obr. 11.11 zobrazuje schematický diagram týchto oblastí.



Obr. 11.11 Schematické znázornenie aplikácie DPZ v oblasti vodných zdrojov. **Fig. 11.11** Schematic representation of the application of remote sensing in the field of water resources. Source: after Chawla et al., 2020

11.3.1. Monitoring water quality

Rýchly a nepretržitý rast obyvateľstva a priemyslu viedol k nárastu bodových a plošných zdrojov znečistenia vodných útvarov. Zatiaľ čo bodové zdroje možno vysledovať k jedinému zdroju, bezbodové zdroje sú svojou povahou rozptýlené a je ťažké ich sledovať. Tieto znečisťujúce zdroje zhoršujú kvalitu vody a ovplyvňujú jedinečné ekosystémy vnútrozemských vôd (ako sú rieky, jazerá a nádrže), ako aj pobrežných vôd, čo podporuje širokú škálu vodných flór a fauny. Monitorovanie kvality vody je preto kľúčové pre zistenie udržateľnosti a využiteľnosti vodných zdrojov.

Fyzikálne, chemické a biologické vlastnosti vody určujú kvalitu vody. Tradične sa tieto vlastnosti kvantifikovali pomocou terénnej a laboratórnej analýzy, čo môže byť časovo náročné a prácne. Časopriestorové charakteristiky vlastností vody sú tiež ovplyvnené niekoľkými faktormi, ako je miesto odberu vzoriek, urbanizácia, zmeny využívania pôdy, odlesňovanie a klimatické zmeny (najmä zmeny teploty). Prieskumy insitu vo veľkých demografických oblastiach s dlhým trvaním sa teda môžu ukázať ako neuskutočniteľné. V tejto súvislosti môžu satelitné senzory poskytnúť informácie, ktoré možno použiť na efektívne monitorovanie určitých parametrov kvality vody, ako je chlorofyl, suspendované sedimenty, zakalenosť, obsah fosforu, obsah rozpustených organických látok, teplota, hĺbka podľa Secchiho disku (Secchi Disk Depth – SDD), znečistenie ťažkými kovmi a iné, okrem iného aj vo veľkých mierkach. Od nástupu misií Landsat v 70. rokoch 20. storočia sa informácie z DPZ čoraz viac využívajú na hodnotenie parametrov kvality vody.

Spektrálne charakteristiky čistej vodnej hladiny sa výrazne líšia od vody zmiešanej s nečistotami alebo znečisťujúcimi látkami. Čistý vodný útvar absorbuje približne 97 – 99 % dopadajúcej energie a odráža len 1 – 3 % dopadajúceho žiarenia. Tento podiel sa mení so zmenou kvality vody, pričom znečistená voda má vyššiu odrazivosť. Ďalej sa dominantná odrazená vlnová dĺžka mení so zmenou zložiek vody. Preto prítomnosť rôznych látok vo vodnom útvare vedie k jedinečným spektrálnym podpisom, ktoré sú merané rôznymi optickými a tepelnými senzormi namontovanými na rôznych satelitoch a vzdušných platformách. Na monitorovanie kvality vody je potrebné stanoviť vzťah medzi spektrálnou odrazivosťou a parametrami kvality vody, pričom všeobecná forma vzťahu je daná rovnicou:

$$Y = A + BX , \qquad (11.1)$$

alebo

$$Y = AB^X , (11.2)$$

kde Y je spektrálna odrazivosť zachytená senzormi DPZ, X je monitorovaný parameter kvality vody, a A a B sú empirické faktory.

V princípe platí, že voda s nízkou koncentráciou sedimentu má maximálny odraz pri 0,55 µm v porovnaní s 0,6 µm pre vodou s vysokou koncentráciou sedimentu. Ultrafialové žiarenie (0,25 – 0,39 µm) sa odráža od hladiny vody a zvyčajne obsahuje aj informáciu o prítomnosti ropných škvŕn na vodných plochách. Vo viditeľnej oblasti je možné v dôsledku rozdielov v absorpčných a reflexných vzorcoch identifikovať rôzne parametre kvality vody, ako je chlorofyl, suspendované sedimenty, rozpustený organický obsah, a iné. Mimo viditeľného rozsahu väčšinu energie absorbuje vodný útvar. Výber senzora je teda kritický pre monitorovanie kvality vody, pretože odrazené žiarenie závisí od sledovaného parametra a jeho koncentrácie.

11.3.1.1. Chlorophyll

Spomedzi rôznych parametrov kvality vody je chlorofyl jedným z najviac skúmaných parametrov využívajúcich informácie z DPZ. Je to pigment fotosyntézy, ktorý je zodpovedný za spôsobenie zelenej farby (odráža zelenú vlnovú dĺžku a zároveň absorbuje energiu z iných vlnových dĺžok) v rastlinách, riasach a siniciach. Jeho výskyt vo vodných útvaroch priamo súvisí s prítomnosťou kvitnutia rias, a preto naznačuje rozsah eutrofizácie vo vodných útvaroch. Dusík a fosfor sú dve zlúčeniny pochádzajúce z hnojív a spaľovania fosílnych palív, ktoré pôsobia ako katalyzátory rastu rias a spôsobujú eutrofizáciu vodných útvarov. Hoci eutrofizácia je prirodzený proces, zaťaženie živinami zvyšuje jej rýchlosť a urýchľuje degradáciu vodných útvarov.

Prítomnosť rôznych koncentrácií chlorofylu vo vode vedie ku krivke spektrálnej odrazivosti s absorpciou v modrom (~0,4 µm) a červenom (~0,7 µm) pásme a odrazivosťou v zelenom (~0,5 µm) a blízkom infračervenom (~0,8 µm) pásme (Obr. 11.12). Túto vlastnosť využívajú rôzne senzory na monitorovanie obsahu chlorofylu vo vode. Hoci niektoré štúdie a výskumy využívajú najmä pásma vo viditeľnej časti spektra EMŽ z multispektrálnych senzorov, bolo preukázané, že z multispektrálnych senzorov je náročné určiť koncentráciu chlorofylu vo vodných útvaroch s vysokým obsahom suspendovaných sedimentov. Preto sú na meranie koncentrácií chlorofylu potrebné snímky s úzkymi spektrálnymi pásmami. Väčšina literatúry odporúča, že optimálna šírka pásma na kvantifikáciu hladín chlorofylu je okolo 675 nm a 700 nm.



Obr. 11.12 Spektrálne vlastnosti chlorofylu. **Fig. 11.12** Spectral characteristics of chlorophyll. Source: www.encyclopedie-environnement.org/vivant/lumiere-photosynthese

Rovnica 11.1 predstavuje všeobecný empirický model, ktorý spája parameter kvality vody so spektrálnymi pásmami. Koncentrácie chlorofylu však možno dobre monitorovať, ak sa použije viac ako jedno spektrálne pásmo. Pomery vhodných spektrálnych pásiem môžu podstatne znížiť vplyv atmosféry a zvýšiť pomer signálu k šumu.

Na empirické stanovenie obsahu chlorofylu pomocou pomeru pásiem sa používa vzťah:

$$\log_{10}[Chlorophyl] = A + B(-\log_{10}G) , \qquad (11.3)$$

pričom:

$$G = \frac{(R_2)^2}{R_1 R_3} , \qquad (11.4)$$

kde A a B sú konštanty odvodené z in situ meraní, R_1 , R_2 a R_3 sú hodnoty spektrálnej odrazivosti pre vlnové dĺžky 460 nm, 490 nm a 520 nm.

Okrem toho existuje viacero ďalších empirických algoritmov, ktoré využívajú viaceré spektrálne pásma (vzťahy sú uvedené pre spektrálne pásma Sentinel-2):

Dvojpásmový algoritmus 2BDA (*Two Band Algorithm*) – pomer medzi červeným pásmom a NIR pásmom predpokladá, že absorpcia neriasovými časticami, žltými látkami a spätným rozptylom je v porovnaní s absorpciou chlorofylu pri červených
vlnových dĺžkach (665 nm) zanedbateľná. Medzi 700 a 720 nm je absorpcia spôsobené zložkami vody minimálna:

$$\mathbf{2BDA} = \frac{B5}{B4} \tag{11.5}$$

Trojpásmový algoritmus 3BDA (*Three Band Algorithm*) – predpokladá, že (1) absorpcia farebnej rozpustenej organickej hmoty a celkovej suspendovanej hmoty pri vlnovej dĺžke 700 nm je približne rovnaká, ako absorpcia pri vlnovej dĺžke 665 – 675 nm a rozdiel medzi nimi je možné zanedbať; (2) celková absorpcia chlorofylu, farebnej rozpustnej organickej hmoty, a celkovej suspendovanej hmoty pri vlnovej dĺžke 730 nm je takmer nulová; (3) koeficient spätného rozptylu chlorofylu je spektrálne nemenný.

3BDA =
$$B6 * \left(\frac{1}{B4} - \frac{1}{B5}\right)$$
 (11.6)

Normalizovaný diferenčný indexu chlorofylu NDCI (*Normalized Difference Chlorophyll Index*) – pre kalné nepokojné vody, využíva informáciu o vrchole odrazivosti so stredom pri vlnovej dĺžke 700 nm, ktorá je maximálne citlivá na zmeny koncentrácie chlorofylu vo vode. Okrem toho, širší vrchol spektrálnej absorpcie medzi 665 a 675 nm je všeobecne spájaný s absorpciou chlorofylovými pigmentami. Normalizácia pomocou NDCI eliminuje neistoty v odhade odrazivosti pri DPZ, sezónne rozdiely v azimute slnečného žiarenia, a atmosférických vplyvov.

$$\mathbf{NDCI} = \frac{B5 - B4}{B5 + B4} \tag{11.7}$$

Index Maximálneho Chlorofylu MCI (*Maximum Chlorophyll Index*) – umožňuje detekciu červených prílivov a vodnej vegetácie. Pre Sentinel-2 sa používa pásmo B5 (705 nm), ktoré je veľmi vhodné pre detekciu vodných plôch s vysokým obsahom biomasy oproti základným pásmam B4 a B6 (665 a 740 nm). Konštanta k predstavuje korekčný faktor pre oblačnosť (pre riedku oblačnosť k = 1.005).

$$\mathbf{MCI} = B5 - k * \left(B4 + B6 - B4 * \frac{B5 - B4}{B6 - B4} \right)$$
(11.8)

Porovnanie jednotlivých indexov na príklade Čadského jazera v severnej časti strednej Afriky je znázornené na Obr. 11.13.



Obr. 11.13 Mapovanie obsahu chlorofylu pomocou indexov 2BDA, 3BDA, NDCI a MCI na príklade Čadského jazera.
 Fig. 11.13 Mapping chlorophyll content using 2BDA, 3BDA, NDCI and MCI indices on the example of Lake Chad.
 Source: Copernicus Sentinel data [2021]. Retrieved from Copernicus SciHub [16/02/2022], processed by FBERG TUKE
 11.3.1.2. Water turbidity and total suspended sediments
 Monitorovanie, celkového, množstva, suspendovaných, sedimentov, má, zásadný

Monitorovanie celkového množstva suspendovaných sedimentov má zásadný význam pre analýzu dynamiky rieky, pretože slúži ako indikátor kvality vody a používa sa aj pri aplikáciách pre vypúšťanie a transport sedimentov. Suspendované sedimenty ovplyvňujú kvalitu vody tým, že blokujú prenos svetla, menia koncentráciu živín, množstvo kyslíka. upchávajú kanály a znižujú rozpusteného Prítomnosť suspendovaných častíc spôsobuje zakalenie vodného útvaru (Obr. 11.14). Zákal vody priamo súvisí so suspendovanými časticami - vyšší zákal, väčšia koncentrácia suspendovaných častíc. Preto sa meranie zákalu často považuje za zástupný ukazovateľ koncentrácie sedimentov vo vodnom útvare. Tak isto sa suspendované sedimenty a zákal môžu použiť aj na nepriame monitorovanie koncentrácie ťažkých kovov vo vodných útvaroch.

Prítomnosť suspendovaných sedimentov a následne zákalu vo vodných útvaroch zvyšuje odrazivosť v červenej a NIR oblasti EMŽ. Táto vlastnosť sa využíva na monitorovanie zákalu a parametrov suspendovaných sedimentov (Obr. 11.14). Na identifikáciu rôznych úrovní sa používajú rôzne pásma a ich pomery. Červené pásmo (665 nm pre Sentinel-2) je vhodné pre monitorovanie nízkych úrovní zákalu v rozmedzí 0.9 – 15 NTU (Nefelometrická Jednotka Zákalu – Nephelometric Turbidity Unit). Okrem jednotlivých pásiem sa na kvantifikáciu používajú aj ich pomery. Pomer zeleného (560 nm) a modrého (490 nm) pásma sa používa na mapovanie zákalu v rozsahu 1-60 NTU. Pomer červeného (665 nm) a modrého pásma (490 nm) sa používa na monitorovanie

vysokej koncentrácie zákalu v rozsahu od 2 do 997 NTU. Vo všeobecnosti sa za optimálnu vlnovú dĺžku na kvantifikáciu suspendovaného materiálu vo vodných útvaroch považuje 700 - 800 nm. Ako merná jednotka zákalu sa zvykne používať aj tzv. Formazínová jednotka zákalu – Formazine Turbidity Unit (FTU), resp. Formazínová nefelometrická jednotka – Formazine Nephelometric Unit (NFU), podobná NTU. Platí, že 1FTU zodpovedá 0.0118/m spätného rozptylu pri 550 nm.



Obr. 11.14 Monitorovanie vodného zákalu pri belgickom pobreží v Máji 2016: Hore – RGB kompozit Sentinel-2; dole – odvodená snímka vodného zákalu.

Fig. 11.14 Water turbidity monitoring off the Belgian coast in May 2016: top - Sentinel-2 RGB composite; bottom - derived water turbidity image.

Source: contains modified Copernicus Sentinel data (2016), processed by RBINS

11.3.1.3. Secchi Disk depth

Čistota vodného útvaru sa vo všeobecnosti považuje za vizuálne kritérium pre kvalitu vody. Hĺbka podľa Secchiho disku (SDD) je kritérium pre index čistoty vody. Pre tento účel sa používa čiernobiely disk s názvom Secchiho disk, ktorý vynašiel taliansky astronóm Pietro Angelo Secchi v roku 1865 (s priemerom v rozmedzí od od 30 do 100 cm, označený stupňovitými čiarami), sa vloží do vody a zaznamenáva sa až do bodu jeho zmiznutia. Hĺbka v ktorej disk zmizne je známa ako SDD a nepriamo súvisí s vodným zákalom a koncentráciou suspendovaných sedimentov vo vodných útvaroch. Meranie SDD je založené na princípe útlmu svetla; pričom SDD je nepriamo úmerné súčtu dvoch koeficientov útlmu svetla.

Hoci SDD predstavuje lacný spôsob monitorovania čistoty vody, je veľmi subjektívny a závisí od vizuálnej presnosti pozorovateľa. SDD je ovplyvnené aj prílivom a odlivom na vodnej hladine. Keďže SDD súvisí so zákalom a koncentráciou suspendovaných sedimentov vo vodnom útvare, bolo vyvinutých niekoľko empirických modelov na spojenie týchto dvoch parametrov. Okrem empirických vzťahov sa na meranie SDD používajú aj spektrálne pásma z rôznych satelitných misií (Obr. 11.15). Vzhľadom na jednoduché monitorovanie úrovne zákalu a suspendovaných sedimentov vo viditeľnom spektre sa červené a modré pásma EMŽ považujú za najužitočnejšie pri mapovaní SDD. Koncentrácia a veľkosť zrna suspendovaných látok sú hlavnými faktormi, ktoré ovplyvňujú SDD. Na určenie SDD existuje viacero postupov, v závislosti od typu monitorovanej vodnej plochy, dostupnosti in situ dát, ale aj od typu použitých satelitných dát. Detailnejší postup v prípade snímok Sentinel-2 je možné nájsť v Pereira-Sandoval et al., 2019; Delegido et al., 2019; Rodrigues et al., 2020.



Obr. 11.15 Mapa SDD pre jazero Albufera (Valencia, Španielsko) na základe snímky Sentinel-2. **Fig. 11.15** SDD map for Lake Albufera (Valencia, Spain) based on Sentinel-2 image. Source: Pereira-Sandoval et al., 2019

11.3.1.4. Colored Dissolved Organic Matter

Farebná rozpustená organická hmota (CDOM), označovaná aj ako vodný humus, gelbstoff alebo gilvin, sa skladá z makromolekúl s aromatickými, karboxylovými, fulvonovými a humínovými kyselinami, ktoré vznikajú rozkladom rastlinného materiálu v pôdach a mokradiach, bakteriálnou aktivitou, rastom rias a zaťažením sedimentov.

Tieto zlúčeniny dodávajú vodnému útvaru žltohnedú farbu, ak sú prítomné vo vysokých koncentráciách. Zvýšenie zaťaženia CDOM ovplyvňuje fyzikálne, chemické a biologické vlastnosti vodných útvarov. Vyššie hladiny CDOM spôsobujú oslabenie prieniku svetla do vodných útvarov a tiež podporujú rast fytoplanktónu, čím sa vodné útvary stávajú eutrofnejšími. Prítomnosť CDOM preto ovplyvňuje štruktúru a fungovanie riečneho ekosystému.

CDOM silne koreluje s inými parametrami kvality vody, ako sú obsah chlorofylu, suspendované sedimenty a úroveň zákalu; preto sa viditeľné spektrálne pásma považujú za najvhodnejšie pri monitorovaní koncentrácie CDOM vo vodných útvaroch. Tak isto platí, že prítomnosť CDOM spôsobuje absorpciu v ultrafialovom pásme a modrozelených pásmach. Maximálna energia absorpcie sa vyskytuje v pásme 440 nm v dôsledku prítomnosti CDOM, ktoré sa zhoduje s absorpčným pásmom chlorofylu. Preto je mimoriadne náročné oddeliť úroveň CDOM od koncentrácie chlorofylu (Obr. 11.16).



Obr. 11.16 Vľavo – ústia riek Kawkawlin a Saginaw do Hurónskeho jazera (Michigan, U.S.) a miesta in situ odberov vzoriek na podklade snímky Sentinel-2. a) + b) Obsah CDOM a Chlorofylu zo snímky Sentinel-2 v Októbri 2016.



Úroveň CDOM sa zvyčajne získava určením vlnovej dĺžky absorpčného koeficientu pomocou rôznych súborov údajov. V tomto ohľade sa používa niekoľko analytických modelov a rôznych spektrálnych pásiem z rôznych senzorov. Pre detailnejšie informácie pozri Chawla et al., 2020; Chen et al., 2017.

11.3.1.5. Surface and sub-surface water sources

Odhad prietoku

Prietok v rieke je dominantným procesom hydrologického cyklu, ktorým sa voda z povrchu zeme prenáša do morí a oceánov. Prietok vody v rieke je vyjadrený ako objem vody pretekajúcej prierezom rieky za jednotku času a vyjadruje sa spravidla v kubických metroch za sekundu. Meranie prietoku rieky poskytuje informácie o dostupnosti vody a preto je nevyhnutné pre manažment vodných zdrojov a riadenie povodňových rizík. Napriek tomu, že ide o kritickú zložku pre pochopenie bilancie povrchových vôd, riečne prietoky sú často nesprávne interpretované v dôsledku obmedzených in-situ meraní. Insitu meranie prietoku má niekoľko obmedzení, ak sú napríklad prietokomery umiestnené iba na niekoľkých veľkých riekach a nie sú priestorovo rozložené. Z tohto pohľadu je väčšina celosvetovo významných riek nedostatočne monitorovaná.

Navyše sa v oblastiach so zložitou topografiou takého prístroje ťažko umiestňujú; takisto môžu mať vplyv na počet a rozloženie vodomerných staníc politické a ekonomické rozhodnutia, cezhraničné zdieľanie vody v riekach, a podobne.

Meranie hladiny vody podľa prietokomeru je založené na predpoklade, že odtok vytvorený v hornej časti toku povodia tečie do jedného odtoku po prúde. Tento predpoklad nemusí platiť v povodiach, v ktorých prevládajú mokrade a záplavové územia, kde sa voda z horného toku môže čiastočne rozptýliť v krajine.

Metódy DPZ môžu tieto problémy eliminovať. Súbory údajov z DPZ majú potenciál poskytovať odhadované prietoky s globálnym pokrytím v relatívne krátkych časových intervaloch. Prietok sa však nedá merať priamo pomocou satelitných senzorov. Preto sa pomocou senzorov merajú iné hydraulické veličiny, ako napríklad výška vodnej hladiny, rýchlosť, plocha prierezu rieky, šírka rieky a sklon povrchových vôd. Presnosť určenia prietoku závisí od spoľahlivosti, s akou sú stanovené uvedené hydraulické veličiny z údajov DPZ. V súčasnosti sa na tieto účely využíva najmä:

- 1. Radarová altimetria,
- 2. Empirické rovnice a krivka hodnotenia,
- 3. Missia SWOT (Surface Water Ocean Topography).

Okrem prietoku sa ďalej monitorujú suchozemské zásoby vody, predstavujúce všetku vodu dostupnú nad a pod povrchom Zeme a tvoriace dôležitú zložku hydrologického cyklu. Pre tento účel sa využíva napríklad misia GRACE-Follow on (GRACE-FO), ako pokračovateľ misie GRACE.

Pomocou DPZ sa taktiež monitorujú vodné nádrže, zohrávajúce dôležitú úlohu pri zabezpečovaní vodnej bezpečnosti v rámci regiónu, najmä počas extrémneho sucha. Monitorovanie vodných nádrží je tak isto rozhodujúce pre systémy riadenia povodí, nakoľko nádrže regulujú medzi sezónne a medziročné výkyvy prietokov. Nádrže tak isto pomáhajú pri kontrole povodní, výrobe elektrickej energie z vodných elektrární, uľahčujú plynulé zásobovanie vodou, a iné rekreačné aktivity. Monitorovanie nádrží technikami DPZ sa stalo dostupnejším od nástupu radarovej altimetrie. Na stanovenie zásob vody v nádržiach sú zase potrebné ako merania vodnej plochy, tak batymetrické merania. Kombináciou týchto údajov je možné kontinuálne monitorovanie nádrží vo forme časových radov.

11.4. Flood mapping and monitoring

Záplavy sú jednou z najhorších prírodných katastrof, ktoré majú najväčší vplyv na život, potravinovú a vodnú bezpečnosť. Napríklad povodne v roku 2016 spôsobili celosvetovo ekonomické straty až do 56 miliárd USD. Obr. 11.17 znázorňuje celkový počet záplav ktoré boli evidované po celom svete medzi rokmi 1970 – 2020 na základe dát z databázy EM-DAT (Emergency Events Database). Na Obr. 11.18 sú zobrazené veľké povodne v Európe v rokoch 2001 – 2016. Pod záplavami rozumieme riečne záplavy, prívalové povodne, pobrežné záplavy, a iné neklasifikované záplavy. Niektoré z následkov povodní zahŕňajú rozšírenie chorôb prenášaných vodou, poškodenie plodín, a kontamináciu pitnej vody. Tieto faktory ovplyvňujú udržateľnosť vodných zdrojov, preto je nevyhnutné mať k dispozícii stratégiu na monitorovanie a riadenie povodní. Niektoré z nevyhnutných krokov zahŕňajú:

- a) určenie zraniteľných regiónov, ktoré sú často postihnuté povodňami v regióne, a následné vytvorenie vhodnej legislatívy v oblasti územného plánovania a manažmentu,
- b) rozvoj štruktúr na kontrolu a odvrátenie povodní, ktoré sa aktivujú v prípade prívalových povodní a extrémnych zrážok,
- c) rozvoj nezávislej infraštruktúry na odvádzanie povodňových vôd v mestskej krajine.

Tieto kroky vyžadujú nepretržité monitorovanie hladiny vody, objemu povodní a rozsahu povodní - čo sú tri faktory, ktoré určujú závažnosť povodní v riečnom povodí. Vzhľadom na nákladné monitorovanie povodní in situ (často dokonca nemožné), je potrebné sa pri monitorovaní záplav spoliehať na informácie získané pomocou DPZ. Za posledné dve desaťročia sa medzi vesmírnymi agentúrami zvýšilo povedomie o využívaní informácií z DPZ na monitorovanie záplav. Zvyčajne sa využívajú optické, pasívne a aktívne mikrovlnné senzory.



Obr. 11.17 Celkový počet záplav evidovaných vo svete medzi rokmi 1970 – 2020 podľa databázy EM-DAT.

Fig. 11.17 Total number of floods recorded in the world between 1970 and 2020 according to the EM-DAT database.

Source: Kuntla, 2021



Obr. 11.18 Veľké záplavy v Európe medzi rokmi 2001 - 2016. **Fig. 11.18** Major flood events in Europe between 2001 – 2016. Source: www.caliper.com/featured-maps/maptitude-flood-events-map.html

11.4.1. Flood monitoring using optical sensors

Vo viditeľnej a termálnej časti EMŽ má voda v porovnaní s inými typmi pôdnej pokrývky relatívne nízku odrazivosť. Práve na tomto princípe je založené monitorovanie povodní pomocou optických senzorov. Z dostupných optických satelitných senzorov, ktoré sa okrem iného používajú aj na tento účel je potrebné spomenúť AVHRR, VIIRS, MODIS, Sentinel, Landsat, SPOT, ASTER, IKONOS, Quickbird, Worldview, RapidEye, prípadne ďalšie.

Optické dáta satelitov DPZ zvyčajne zahŕňajú modré, zelené, červené, blízke infračervené (NIR), stredne infračervené (MIR), resp. SWIR pásma. Na mapovanie záplav sa postupne vyvinulo viacero indexov využívajúcich kombinácie týchto spektrálnych pásiem. Medzi základné indexy na monitorovanie vody patria:

Normalizovaný Diferenčný Index Vody NDWI (*Normalized Difference Water Index*) – môže sa vzťahovať na jeden z dvoch indexov odvodených z dát DPZ, ktoré sa týkajú vody v kvapalnom skupenstve.

NDWI, ktorý silne súvisí s obsahom vody v rastlinách, je veľmi dobrým ukazovateľom stresu rastlín. Je odvodený z pásiem blízkej infračervenej oblasti (NIR) a krátkovInnej infračervenej oblasti (SWIR). Odrazivosť v pásme SWIR odráža zmeny obsahu vody vo vegetácii, rastlinách a korunách stromov, zatiaľ čo odrazivosť v pásme NIR je ovplyvnená vnútornou štruktúrou listov a obsahom suchej hmoty v listoch (ale nie obsahom vody). Tento index sa zvykne uvádzať aj ako Normalizovaný Diferenčný Index Vlhkosti NDMI (Normalized Difference Moisture Index).

Na mapovanie vodných plôch a monitorovanie záplav je vhodnejší index NDWI určený na základe odrazivosti v pásme pre zelenú farbu (Green) a blízku infračervenú oblasť (NIR). Vodný útvar má silnú absorpčnú schopnosť a nízke vyžarovanie v rozsahu od viditeľných po infračervené vlnové dĺžky. Na základe toho NDWI využíva Green a NIR pásmo. Je citlivý na zastavané územia a výsledkom sú niekedy nadhodnotené vodné plochy. Pre pásma Sentinel-2 platí:

$$\mathbf{NDWI} = \frac{Green - NIR}{Green + NIR} = \frac{B3 - B8}{B3 + B8}$$
(11.9)

Hodnoty indexu pre vodné plochy sú >0.5. Pre vegetáciu nadobúda oveľa menšie hodnoty, čo má za následok ľahšie odlíšenie vegetácie od vodných plôch. Zastavané plochy nadobúdajú hodnoty 0 – 0.2. Pre eliminovanie vzniku falošných pozitívnych hodnôt v zastavaných územiach sa preto odporúča používať prahovú hodnotu 0.3.

Modifikovaný Normalizovaný Diferenčný Index Vody MNDWI (*Modified Normalized Difference Water Index*) – využíva Green a SWIR pásma na zvýraznenie prvkov otvorených vodných plôch z dôvodu intenzívnejšej absorpcie SWIR žiarenia v porovnaní s NIR pásmom. Znižuje vplyv zastavaných oblastí a je vhodnejší na detekciu vodných plôch v mestských oblastiach. Jeho nevýhodou je slabšia schopnosť identifikovať vodné plochy s vysokou koncentráciou sedimentov. Pre snímky Sentinel-2 platí:

$$\mathbf{MNDWI} = \frac{Green - SWIR1}{Green + SWIR1} = \frac{B3 - B11}{B3 + B11}$$
(11.10)

Automatizovaný Index Extrakcie Vody AWEI (*Automated Water Extraction Index*) – v priebehu minulých rokov bolo vyvinutých niekoľko indexov, ktorých cieľom bolo eliminovať vplyvy skresľujúce dáta, ako napríklad topografické tiene, tiene mrakov, zastavané plochy, sneh, a ľad. Na tento účel bol vytvorený index AWEI, ktorý sa skladá z dvoch samostatných indexov.

Index AWEInsh pre oblasti bez výrazných tieňov:

$$AWEInsh = 4 * (Green - SWIR1) - (0.25 * NIR + 2.75 * SWIR2)$$

$$AWEInsh = 4 * (B3 - B11) - (0.25 * B8 + 2.75 * B12)$$
(11.11)

A index AWEIsh pre oblasti s výraznými tieňmi:

$$AWEIsh = Blue + 2.5 * Green - 1.5 * (NIR + SWIR1) - 0.25 * SWIR2$$

$$AWEIsh = B2 + 2.5 * B3 - 1.5 * (B8 + B11) - 0.25 * B12$$
(11.12)

Index AWEInsh bol vytvorený na efektívnu elimináciu pixelov, ktoré neprislúchajú vode, vrátane tmavých zastavaných plôch v mestských oblastiach. AWEInsh zlepšuje oddelenie vodných pixelov od nevodných, predpokladá nedostatočnú a neúčinnú elimináciu pixelov obsahujúcich tieň. Preto bol vytvorený index AWEIsh, ktorý zavedením pásma BLUE pre modrú farbu zlepšuje presnosť extrakcie vodných pixelov aj v oblastiach s výraznými tieňmi.

Porovnanie histogramov a výsledkov zo všetkých 4 indexov je znázornené na Obr. 11.19 a Obr. 11.20.



Obr. 11.19 Porovnanie indexov NDWI, MNDWI, AWEInsh a AWEIsh pre rieku Bodrog pretekajúcu zastavaným územím.

Fig. 11.19 Comparison of NDWI, MNDWI, AWEInsh and AWEIsh indices for the Bodrog River flowing through the built-up area.

Source: Kseňak et al., 2022



Obr. 11.20 Porovnanie histogramov pre indexy NDWI, MNDWI, AWEInsh a AWEIsh vo vybranej oblasti.

Fig. 11.20 Comparison of histograms for NDWI, MNDWI, AWEInsh and AWEIsh indices in the selected area.

Source: Kseňak et al., 2022

Napriek jednoduchej použiteľnosti sú informácie z optických senzorov negatívne ovplyvnené atmosférou v podobe oblačnosti a pevných častíc, a vegetáciou. Okrem toho sa snímkovanie môže vykonávať len počas dňa. V prípade prítomnosti mrakov alebo vegetácie môže byť odrazivosť od týchto prvkov taká výrazná, že snímka nemusí byť použiteľná pre monitorovanie povodní v reálnom čase. Potom je nevyhnutné pre monitorovanie povodní a vodných plôch použiť informácie z radarových senzorov.

11.4.2. Flood monitoring using active radar sensors

Aktívne radarové senzory vysielajú signály elektromagnetického žiarenia (v mikrovlnnej frekvenciách) smerom k zemskému povrchu a merajú rozptýlený signál (vo forme koeficientu spätného rozptylu), ktorý obsahuje informácie o štruktúre, tvare a dielektrických vlastnostiach povrchu. Aktívne mikrovlnné (radarové) senzory sú schopné preniknúť cez oblačnosť a poskytovať informácie nezávisle od slnečného osvetlenia.

Priestorové a časové rozlíšenie SAR snímok je rozhodujúcim faktorom pre monitorovanie povodní. Medzi týmito dvoma rozlíšeniami existuje prirodzený kompromis, avšak po nástupe radarovej satelitnej misie Sentinel-1 sa globálne skrátil čas opätovného zachytenia toho istého územia na 6 dní, čo samozrejme pomôže pri monitorovaní záplav.

Koeficient spätného rozptylu zaznamenaný SAR je ovplyvnený charakteristikami cieľa a snímača, ako napr.:

- a) drsnosť povrchu,
- b) dielektrické vlastnosti cieľa,
- c) frekvencia žiarenia,
- d) polarizácia,
- e) uhol dopadu,
- f) vlastnosti atmosféry,
- g) meteorologické podmienky ako zrážky, rýchlosť vetra, atď.

Rovnako platí, že frekvencia má inverzný vplyv na hĺbku prenikania spätného rozptylu. Vo všeobecnosti koeficienty spätného rozptylu pre L-pásmo (0,5 - 1,5 GHz), C-pásmo (4 - 8 GHz) a X-pásmo (8 - 12 GHz) sú považované za vhodné pre monitorovanie povodní, pričom L- pásmo má väčšiu schopnosť preniknúť cez vegetáciu a relatívne menší vplyv drsnosti povrchu. Citlivosť koeficientu spätného rozptylu na drsnosť povrchu sa zvyšuje s rastúcim uhlom a naopak. Vodné plochy sa vo všeobecnosti javia tmavšie s nízkym spätným rozptylom signálu, pokiaľ nie sú ovplyvnené drsnosťou vodného povrchu (vietor, vlny).

Pred analýzou SAR údajov je dôležité predspracovať snímky z hľadiska rádiometrickej kalibrácie, filtrovania šumu, georeferencovania a ortorektifikácie.

Doteraz bolo vyvinutých viacero prístupov pre mapovanie rozsahu povodní pomocou SAR údajov. Tieto metódy môžeme označiť aj ako techniky klasifikácie snímok, keďže hlavným cieľom je rozlíšiť suché a mokré (zaplavené) oblasti. Tieto metódy možno všeobecne rozdeliť na:

- 1. vizuálna interpretácia,
- 2. prahovanie obrazu (thresholding),
- 3. algoritmy automatickej klasifikácie obrazu,
- 4. modely aktívnych kontúr (Active Contour Model),
- 5. techniky detekcie zmien.

Každá z týchto techník má svoje výhody a nevýhody a neexistuje optimálna technika, ktorá by sa dala aplikovať na všetky prípadové štúdie.

Vizuálna interpretácia zahŕňa skúmanie záplavových línií zo snímok. Hoci je táto metóda jednoduchým spôsobom mapovania rozsahu záplav, výsledok môže byť chybný v dôsledku vplyvu faktorov, ako sú zaplavené oblasti javiace sa ako svetlejšie v dôsledku drsnosti a vplyvu vetra.

Prahovanie obrazu je účinný a najjednoduchší prístup na klasifikáciu obrazu, pričom sa určuje rádiometrická prahová hodnota na rozlíšenie dvoch tried (záplavové, nezáplavové oblasti), ktoré majú výrazne odlišné rozloženie pixelov. Techniky prahovania obrazu možno všeobecne klasifikovať takto:

- a) metódy založené na tvare histogramu analýza vrcholov a údolí, okrem iných vlastností vyhladeného histogramu,
- b) metódy založené na blokoch klastroch rozdeľujú obraz na dva klastre, ktoré zodpovedajú vodným a nevodným pixelom,
- c) metódy založené na entropii určujú entropiu dvoch klastrov a krížovú entropiu medzi pôvodným a binárnym obrazom,

- d) metódy založené na atribútoch objektov posudzujú podobnosť medzi pôvodnými a binárnymi obrazmi,
- e) priestorové metódy využívajú rozdelenie pravdepodobnosti medzi pixelmi.

Prahová hodnota získaná niektorou z týchto techník je závislá od typu senzora, povrchu pôdy a podmienok životného prostredia. Tieto techniky sa teda musia aplikovať na základe jednotlivých scén. V dôsledku toho sa tieto techniky ukazujú ako časovo náročné a sú tiež náchylné na chyby v dôsledku subjektivity. Techniky automatického prahovania sa snažia tento problém zmierniť automatickým určením prahovej sivej hodnoty, ktorá oddeľuje hodnoty pre zaplavené a nezaplavené oblasti. Tieto techniky sa ďalej môžu rozlišovať podľa odhadu prahovej hodnoty v globálnom meradle (jediná hodnota pre celú snímku), alebo v lokálnom meradle (prahová hodnota podľa lokálnych podmienok). Rozlišujú sa aj na základe zapojenia parametrov do modelov (čo vedie k parametrickým a neparametrickým modelom). Príklad použitia prahovej hodnoty pre identifikovanie vodnej plochy je uvedený na Obr. 11.21.



Obr. 11.21 Príklad definovania prahovej hodnoty pre identifikovanie vodnej plochy na snímke Sentinel-1 pre VV a VH polarizáciu.

Fig. 11.21 Example of defining a threshold for identifying a water surface on Sentinel-1 image for VV and VH polarization.

Source: Kseňak et al., 2022

Modely aktívnych kontúr ACM sú jednou z ďalších používaných automatických techník na monitorovanie rozsahu povodní. ACM zahŕňajú dynamické krivočiare kontúry, ktoré sa vyvíjajú v závislosti od snímkových obmedzení, s cieľom identifikovať objekty na snímke. Kontúry sú súborom uzlov spojených priamkami. Kontúra je riadená energetickou funkciou, ktorá priťahuje kontúru k okrajom objektu. Táto energetická funkcia zohľadňuje zmeny v koeficientoch spätného rozptylu vo vnútri oblasti, zmeny v koeficientoch spätného rozptylu mimo oblasti a parameter dĺžky hrany. Tento proces vyhľadávania pokračuje, kým sa neidentifikuje zaplavená oblasť (Obr. 11.22 a Obr. 11.23).



Obr. 11.22 Mapovanie vodnej plochy na snímke Sentinel-1 počas 4 rôznych časových období (a, c, e, g). Svetlo modrou farbou je znázornená vodná plocha určená na základe počiatočnej extrakcie metódou prahovania; tmavo modrou farbou je znázornená vodná plocha na základe spresnenej extrakcie metódou Active Contour Model (b, d, f, h).

Fig. 11.22 Water surface mapping on Sentinel-1 image during 4 different time periods (a, c, e, g). Light blue shows the water area determined from the initial extraction by the thresholding method; dark blue shows the water area based on the refined extraction by the Active Contour Model (b, d, f, h).

Source: Hu et al., 2020



Obr. 11.23 Porovnanie vodnej plochy (c) extrahovanej metódou Active Contour Model aplikovanej na snímke S-1 (b) a extrahovanej klasifikáciou pomocou indexu AWEI na snímke S-2 (a). **Fig. 11.23** Comparison of water area (c) extracted by Active Contour Model applied on S-1 image (b) and extracted by AWEI classification on S-2 image (a). Source: Hu et al., 2020

Vyššie opísané metódy využívajú iba jednu snímku. Oproti tomu, **metódy detekcie zmien** používajú dve snímky – pred povodňovou udalosťou a po zaplavení tej istej oblasti záujmu. Prostredníctvom týchto dvoch snímok možno získať rozdiel v koeficientoch spätného rozptylu, ktorý možno ďalej použiť na vymedzenie zaplavených oblastí (Obr. 11.24). Rozdiel v oboch snímkach sa vo všeobecnosti počíta ako pomer alebo logaritmický pomer, aby sa neutralizoval multiplikačný charakter šumu v SAR údajoch (Obr. 11.25).



Obr. 11.24 Príklad využitia metódy detekcie zmien pre monitorovanie záplav v Írsku na dátach Sentinel-1; vľavo – vstupné dáta vo formáte GRD (zaplavená oblasť zvýraznená azúrovou farbou), v strede – výsledná mapa detegovaných zmien, vpravo – referenčná dáta z ESA.

Fig. 11.24 Example of using the change detection method for flood monitoring in Ireland on Sentinel-1 data; left - input data in GRD format (flooded area highlighted in cyan), centre - resulting map of detected changes, right - reference data from ESA.

Source: Amitrano et al., 2018



Obr. 11.25 (a) Snímka Sentinel-1 pred povodňou na rieke Evros (Grécko); (b) snímka Sentinel-1 zaplaveného územia po povodni; (c) výsledná snímka vymedzujúca zaplavenú oblasť vytvorená na základe logaritmického pomeru medzi (a) a (b).

Fig. 11.25 (a) Sentinel-1 image of the pre-flood Evros River (Greece); (b) Sentinel-1 image of the flooded area after the flood; (c) the resulting image delineating the flooded area based on the log-ratio between (a) and (b).

Source: Li et al., 2018

Výber referenčných (nezaplavených) snímok môže výrazne ovplyvniť konečný výsledok. Je to spôsobené vysokou variabilitou koeficientov spätného rozptylu v dôsledku atmosférických zložiek, procesov na zemskom povrchu ako je vlhkosť pôdy, evapotranspirácia, sezónnosť charakteristík vegetácie, zmeny využitia pôdy a charakteristiky získavania snímok. V tejto súvislosti platí, že detekcia zmien môže zároveň

spôsobiť falošnú detekciu povodní v poľnohospodárskych oblastiach, čo sa dá eliminovať navrhnutím nového parametra, ktorý je schopný určiť, či zistená zmena prislúcha buď zaplavenej, alebo nezaplavenej oblasti v poľnohospodárskej oblasti.

Z viacerých výskumov v posledných rokoch vyplýva, že ACM dokáže vytvoriť povodňové mapy s väčšou presnosťou na úkor výpočtových zdrojov, zatiaľ čo technika automatického prahovania je vhodná na detekciu a monitorovanie povodní v takmer reálnom čase. V záujme získania oveľa presnejších povodňových máp je často cieľom implementovať naraz viacero techník, napríklad automatizovaný systém monitorovania povodní SAR, v ktorom sú použité techniky prahovania aj detekcie zmien.

11.4.3. Flood monitoring using passive radar sensors

Pasívne mikrovlnné rádiometre zachytávajú prirodzene vyžarované elektromagnetické žiarenie zo zemského povrchu vo forme teploty jasu. V dôsledku rozdielov v tepelnej zotrvačnosti a emisivite pevniny a vody sú teploty jasu zaznamenané satelitom nad vodnou hladinou chladnejšie. Tento kontrast teplôt jasu sa vo všeobecnosti využíva na detekciu oblastí postihnutých záplavami. Za týmto účelom bola vyvinutá technika, ktorá využíva informácie o frekvencii v pásme Ka (~37 GHz) s horizontálnou polarizáciou. Ide o výpočet pomeru medzi teplotou jasu cieľovej bunky mriežky a pozadia / kalibrácie / referenčnej / suchej bunky mriežky, čo zodpovedá zmenám v rozsahu vody v bunke mriežky. Príklad využitia pasívneho mikrovlnného senzora na mapovanie záplav je znázornený na Obr. 11.26.

Tak isto bola zavedená metóda na určenie rozsahu vodných plôch na základe poklesu emisivity so zvýšením podielu vodnej plochy v pixely. Táto emisivita je spojená s rozdielom teploty jasu vo viacerých frekvenciách. Týmto postupom bol odvodený index nazvaný Basin Water Index (BWI).

Zároveň však platí, že merania teploty jasu sú k dispozícii len v rádoch desiatok kilometrov z dôvodu nízkej energie mikrovlnného vyžarovania. Rozsah záplav je teda možné vyhodnotiť len v prípade veľkých povodí (napríklad ak 1 pixel predstavuje plochu ~100 km2). Mikrovlnné žiarenie má tiež výrazné oslabenie spôsobené atmosférou vo frekvenciách nad frekvenciou X-pásma, čo je potrebné zohľadniť pri spracovaní.



Obr. 11.26 Vyhodnotenie záplav na základe pasívneho mikrovlnného senzora AMSR-E satelitu Aqua.

Fig. 11.26 Flood assessment based on the passive microwave sensor AMSR-E of the Aqua satellite. Source: De Groeve, 2010

11.4.4. Flood monitoring using a combination of optical and radar data

Pre mapovanie záplav sa v princípe používajú tri základné kombinácie dát pred a po záplavách – optické/optické dáta, SAR/SAR dáta, a SAR/optické dáta. Kombinovanie dát zo SAR a optických senzorov umožňuje využívať výhody oboch senzorov z rôznych časti spektra EMŽ (Obr. 11.27) a lepšie tak zachytiť rýchlo sa meniace podmienky počas záplav.



Obr. 11.27 Postavenie senzorov Sentinel-1 a Sentinel-2 v rámci elektromagnetického spektra. **Fig. 11.27** Sentinel-1 and Sentinel-2 sensors in the electromagnetic spectrum. Source: after Ronan 2013, CC BY SA 3.0 and Braun, 2021 Rovnako ako aj pre kombinácie dát z iných senzorov, aj pre snímky zo Sentinel-1 a Sentinel-2 existujú techniky ich syntézy s cieľom využiť ich doplnkový informačný obsah, väčšinou na úrovni pixelov. V ideálnom prípade sa snímky z oboch senzorov získavajú v rovnakom čase. Čas medzi akvizíciou oboch snímok by sa mal aspoň minimalizovať, aby sa zabezpečilo, že informácie každého pixelu sa vzťahujú na rovnaký stav zemského povrchu. Príklad základného postupu pre syntézu snímok Sentinel-1 a Sentinel-2 je uvedený na Obr. 11.28. Typický postup celého spracovania je znázornený na Obr. 11.29.



Merging Sentinel-1 and Sentinel-2 images

Obr. 11.28 Základný postup syntézy snímok Sentinel-1 a Sentinel-2. **Fig. 11.28** Basic Sentinel-1 and Sentinel-2 image synthesis procedure. Source: after Braun, 2021





Fig. 11.29 Example of a practical procedure and individual steps for combining optical and radar data for flood mapping.

Source: Notti et al., 2018

Výsledná syntéza oboch snímok môže byť interpretovaná vizuálne pomocou rôznych RGB kompozitov (napríklad *red* = Sentinel-2 B9, *green* = Sentinel-2 B5, *blue* = Sentinel-1 VH) (Obr. 11.30). Rôzne štruktúry na snímke môžu byť tak isto zvýraznené pomocou manipulácie s histogramom.

Takto získané dáta z oboch senzorov je následne možné analyzovať a klasifikovať štandardnými postupmi ako je práca s maskami, histogramom a rôznymi indexami, rozptylový diagram, tvorba profilov, riadená a neriadená klasifikácia, analýza hlavných komponentov, a pod.



Obr. 11.30 RGB kompozit Sentinel-1 a Sentinel-2 vo falošných farbách. **Fig. 11.30** RGB composite Sentinel-1 and Sentinel-2 in false colours. Source: after Braun, 2021

Kombinovanie radarových (S-1) a optických snímok (S-2) má teda viaceré výhody. S-2 poskytuje lepšie rozlíšenie výsledných vodných masiek, čo vedie k súvislejšiemu výslednému vzhľadu masky vodnej plochy. Optické dáta majú taktiež lepšiu schopnosť detegovať signál pri brehoch riek. Nevýhodou je prípadná oblačnosť na snímkach, ktorá znemožňuje ich ďalšie spracovanie. Oblačnosť na snímkach môže eliminovať práve použitie S-1 (Obr. 11.31).



Obr. 11.31 Porovnanie výsledkov identifikácie vodných plôch zo snímky Sentinel-1 (na základe prahovania) a Sentinel-2 (na základe indexu NDWI).

Fig. 11.31 Comparison of water surface identification results from Sentinel-1 (based on thresholding) and Sentinel-2 (based on NDWI index). Source: Kseňak, 2021

11.4.5. Flood mapping using Sentinel-3 OLCI

Sentinel-3 Ocean and Land Colour (OLCI) je navrhnutý tak, aby zabezpečil kontinuitu k misii ENVISAT Medium Resolution Imaging Spectrometer (MERIS), s vylepšeniami v podobe zvýšenia počtu spektrálnych pásiem (z 15 na 21), lepšej dlhodobej rádiometrickej stability a výkonu, širokého geografického pokrytia, rýchlej frekvencie opakovaných preletov, rýchleho poskytovania údajov a schopnosti uľahčiť synergické využívanie produktov OLCI a rádiometra Sea and Land Surface Temperature (SLSTR) vďaka 100 % prekrývaniu a simultánnemu snímkovaniu. Konštelácia OLCI na palube Sentinel-3 s priestorovým rozlíšením 300 m v režime plného rozlíšenia (FR) a frekvenciou opakovaných výstupov menej ako 2 dni nad akýmkoľvek zemským povrchom poskytuje kompromis medzi priestorovým rozlíšením optických snímačov s vysokým rozlíšením, ako je MSI na Sentinel-2, LISS-IV na ResourceSat-2, a pokrytím optických senzorov, ako je MODIS, vďaka čomu je vhodná na širokú škálu aplikácií v oblasti monitorovania povodní.

V Októbri 2018 postihli severné regióny Talianska prívalové dažde a silný vietor, čo malo za následok extrémne záplavy. Agentúra EOMAP využila na monitorovanie povodní súbory dát z misií Copernicus Sentinel-2 a Sentinel-3 na monitorovanie zákalu spôsobeného prítokom výrazných riečnych sedimentov do Jadranského mora (Obr. 11.32).



Obr. 11.32 Vľavo - prítok riečnych sedimentov do Jadranského mora po extrémnych záplavách; vpravo – úroveň zákalu vyhodnotená na základe kombinácie snímok Sentinel-2 a Sentinel-3. **Fig. 11.32** Left - river sediment inflow into the Adriatic Sea after extreme flooding; right - turbidity level assessed from a combination of Sentinel-2 and Sentinel-3 imagery. Source: ©EOMAP, 2018; www.eomap.com/using-satellite-data-for-flood-monitoring

Hoci jeho snímky s hrubším priestorovým rozlíšením nemusia byť ideálne pre povodne malého rozsahu (na úrovni malého povodia / mikropovodia), jeho vlastnosti vyššieho počtu opakovaných snímok a širokého synoptického pokrytia, ktoré umožňujú zachytiť väčšie územie naraz, ho robia vhodnou možnosťou pre efektívne mapovanie povodní veľkého rozsahu. Ďalšie dva identické satelity v rámci tejto misie Sentinel-3C a Sentinel-3D, ktorých vypustenie sa plánuje v najbližších rokoch (2023 a 2025), by mali ešte viac zvýšiť frekvenciu opakovaného zachytenia akéhokoľvek povrchu na Zemi na menej ako 1 deň a poskytnú tým priestor na rýchle monitorovanie záplav v reálnom čase na kontinentálnej a globálnej úrovni. Okrem toho by Sentinel-3 v budúcnosti mohol poskytovať dáta zo senzora OLCI takmer v reálnom čase, čo znamená dodanie výstupných dát do 3 hodín od ich získania, čo by z tejto misie robilo dominantnú voľbu pre rýchle reakcie na núdzové situácie. Rozsah záplav v reálnom čase by bol rozhodujúcim zdrojom informácií pre záchranné a pomocné práce.

Rovnako ako rozsahy povodní odvodené z dát Sentinel-1 a Sentinel-2, postupné vymedzovanie rozsahu povodní zo snímok Sentinel-3 OLCI pomôže pri odvodzovaní vzorcov povodňových záplav na úrovni veľkých povodí, tak isto pri pochopení, navrhovaní a budovaní modelových štruktúr a môže poskytovať informácie pre systémy predpovedania povodní, hydrodynamické a hydrologické modely.

Z dôvodu hrubšieho rozlíšenia (300 m) však identifikovaný rozsah záplav, nemusí byť rovnako presný v porovnaní s mapou odvodenou zo snímok s vysokým rozlíšením v dôsledku vyššieho počtu chýb. Napríklad jeho neschopnosť zachytiť malé miesta povodňovej záplavy alebo v skutočnosti akékoľvek iné malé útvary na zemskom povrchu, ktoré sú menšie ako veľkosť pixelu, má za následok viac zmiešaných pixelov, ktoré vynechávajú a vytvárajú chyby v príslušných mapách. Napriek tomu je možné použiť niekoľko metód na zlepšenie rozlíšenia, vrátane kombinovania snímok Sentinel-3 OLCI so snímkami vo vysokom rozlíšení, ako sú snímky Sentinel-2 MSI.

11.5. Drought monitoring

Dopyt po vode sa výrazne zvýšil v dôsledku rastu populácie a expanzie poľnohospodárskych, energetických a priemyselných sektorov, čo malo za následok častý nedostatok vody v mnohých častiach sveta. Nedostatok vody zhoršuje suchá, ktoré ovplyvňujú povrchové a podzemné zdroje vody, čo vedie k zníženiu dodávok vody, zhoršenej kvalite vody, riziku požiarov, ohrozenie dobytku a produkcie potravín, a vodnému stresu. Preto je prieskum týkajúci sa manažmentu sucha (napr. monitorovanie, prognózovanie a hodnotenie rizík) nevyhnutný pre plánovanie a riadenie vodných zdrojov.

Sucho je vyvolané anomálnym správaním hydroklimatických premenných, ako je zníženie zrážok, zvýšenie teplôt, nízka relatívna vlhkosť a rozloženie daždivých dní. Pomocou technológií DPZ je možné sledovať anomálne správanie takýchto premenných v rôznych časopriestorových mierkach. Suchá sa všeobecne klasifikujú na:

- meteorologické,
- hydrologické,
- poľnohospodárske,
- sociálno-ekonomické.

Hoci neexistuje štandardná definícia sucha, vo všeobecnosti vzniká v dôsledku deficitu vody v porovnaní s normálnymi podmienkami (Obr. 11.33, Obr. 11.34). V dôsledku toho, že suchá súvisia s pohybom vody v hydrologickom cykle, často sú navzájom zložito prepojené. V tejto súvislosti bolo v minulosti navrhnutých niekoľko indexov sucha, ktoré hodnotia individuálny, ako aj viacrozmerný charakter sucha.



Obr. 11.33 Jazero Bracciano v Taliansku; časť pobrežia ustúpila až o 60 m v dôsledku sucha v roku 2017, na snímke Sentinel-2.

Fig. 11.33 Lake Bracciano in Italy; part of the shoreline has receded by up to 60 m due to drought in 2017, pictured by Sentinel-2.

Source: ©ESA – J. Benveniste; contains modified Copernicus Sentinel data (2017), processed by ESA



Obr. 11.34 Miera intenzity sucha v celom pôdnom profile na Slovensku, 26 Apríla 2020. Intenzita sucha bola na úrovni výrazného až extrémneho sucha na 84% územia.

Fig. 11.34 Measure of drought intensity across the entire soil profile in Slovakia, 26 April 2020. Drought intensity was at the level of severe to extreme drought over 84% of the territory. Source: www.intersucho.sk

11.5.1. Meteorological drought

Meteorologické sucho je spojené s nedostatkom zrážok počas určitého obdobia. Tradične sa meteorologická analýza sucha vykonáva na základe in situ informácií o zrážkach. Ako meteorologický index sucha sa používa **Palmerov Index Závažnosti Sucha PDSI** (*Palmer Drought Severity Index*), ktorý meria stratu vlahy na základe rovnice vodnej bilancie. PDSI sa vypočítava na základe údajov o zrážkach a teplote, ako aj miestneho dostupného obsahu vody v pôde.

Ďalším meteorologickým indexom pre monitorovanie sucha je **Štandardizovaný Zrážkový Index SPI** (*Standardized Precipitation Index*), ktorý sa počíta na základe dlhodobých údajov o zrážkach v danej lokalite. SPI zahŕňa prispôsobenie zrážok na príslušné pravdepodobnostné rozdelenie a jeho následnú transformáciu na normálne rozdelenie. Keďže SPI vyžaduje len údaje o zrážkach, je jedným z najčastejšie používaných meteorologických indexov sucha. Na získanie spoľahlivej štatistickej zhody pri odhade SPI je však potrebných aspoň 30 rokov údajov o zrážkach. S príchodom technológií založených na DPZ poskytujúcich dlhodobé dáta, ako sú CHIRPS (Climate Hazards Group InfraRed Precipitation with Station) a MSWEP (Multi-Source Weighted-Ensemble Precipitation), je teraz možné určiť SPI pomocou ich dlhodobých údajov.

Okrem týchto dvoch indexov existuje ešte niekoľko ďalších, využívajúcich údaje DPZ. Index Evaporačného Stresu ESI (*Evaporative Stress Index*) vyjadruje časové anomálie v pomere medzi skutočnou evapotranspiráciou a potenciálnou evapotranspiráciou (Obr. 11.35). ESI sa určuje pomocou TIR snímok a snímok podielu vegetačného krytu zo satelitov GEOS (Geostationary Operational Environmental Satellites).



Obr. 11.35 Príklad indexu ESI v globálnej mierke.. **Fig. 11.35** Example of an ESI index on a global scale. Source: medium.com/euro-data-cube/world-food-supply-amid-a-pandemic-3940ef855f07

Existuje aj **Štandardizovaný Index Deficitu Evapotranspirácie SEDI** (*Standardized Evapotranspiration Deficit Index*), ktorý je odvodený pomocou komplementárneho vzťahu medzi evaporačným dopytom a skutočnou evapotranspiráciou. Keďže ESI a SEDI sú nezávislé od zrážok, je možné ich použiť ako referenčné indexy pre hodnotenie meteorologických indexov založených na zrážkach.

Kvôli potrebe zahrnúť evapotranspiráciu do hodnotenia meteorologického sucha bol navrhnutý nový index sucha **Štandardizovaný Index Evapotranspirácie Zrážok SPEI** (*Standardized Precipitation Evapotranspiration Index*). SPEI funguje podobne ako SPI, pričom náhodnou premennou je rozdiel medzi zrážkami a potenciálnou evapotranspiráciou. Tento rozdiel totiž v podstate poskytuje klimatickú vodnú bilanciu, t.j. či je v danom mesiaci prebytok alebo deficit vody.

Podobne ako SPEI existuje aj **Index Prieskumu Sucha RDI** (*Reconnaissance Drought Index*), ktorý sa určuje ako pomer medzi akumulovanými zrážkami a potenciálnou evapotranspiráciou. Použiť sa dajú napríklad dáta o potenciálnej evapotranspirácii získanej pomocou DPZ a údaje zo zrážkomerných staníc.

11.5.2. Agricultural drought

Poľnohospodárske sucho nastáva v dôsledku poklesu pôdnej vlhkosti, čo následne vedie k neúrode v danom území. Nedostatok vody v pôde možno pripísať deficitu zrážok alebo nedostatku závlahy (kvôli nedostatku vody v nádržiach) spolu s väčším množstvom evapotranspirácie z pôdy. Monitorovanie poľnohospodárskeho sucha sa preto vykonáva predovšetkým analýzou charakteru vegetácie a pôdnej vlhkosti. Poľnohospodárske sucho tiež úzko súvisí s meteorologickými podmienkami. Viaceré štúdie naznačili súvislosť medzi poľnohospodárskym suchom a zrážkovými anomáliami. V princípe existuje relatívne väčší počet indexov pre určenie poľnohospodárskeho sucha v porovnaní s meteorologickými indexmi sucha.

Nevýhodou indexu PDSI je jeho pomalá reakcia na krátkodobé suchá, čo môže ovplyvniť monitorovanie rastu plodín. Tento problém sa snaží riešiť **Index Vlhkosti Plodín CMI** (*Crop Moisture Index*), určený na základe potenciálnej evapotranspirácie a vyčerpania pôdnej vlhkosti, pričom riadiacim konceptom je bilancia pôdnej vlhkosti. Na podobnej myšlienke je založený aj index **Relatívnej Pôdnej Vlhkosti RSM** (*Relative Soil Moisture*), resp. **Index Poľnohospodárskeho Sucha DTx** (*Agricultural Drought Index*). Nevýhodou CMI, podobne ako pri PDSI, je obmedzenie vyplývajúce z predpokladu jednotných vlastností využívania krajiny a pôdy v danej klimatickej zóne. Tento problém sa dá eliminovať prostredníctvom nových indexov – **Index Deficitu Pôdnej Vlhkosti SMDI** (*Soil Moisture Deficit Index*), pričom sa využije simulácia pôdnej vlhkosti a evapotranspirácie pomocou nástroja Soil Water Assessment Tool (SWAT).

S nástupom DPZ dát bolo navrhnutých viacero kompatibilných indexov pre monitorovanie poľnohospodárskeho sucha. Jedným z nich je **Index Pôdnej Vlhkosti SMI** (*Soil Moisture Index*) (Obr. 11.36), ktorý sa vypočíta ako funkcia pomeru rozdielu medzi vlhkosťou pôdy a bodom vädnutia a rozdielu medzi kapacitou poľa a bodom vädnutia. Modifikovanou formou SMI je **Index Deficitu Vody v Pôde SWDI** (*Soil Water Deficit Index*), v ktorom je deficit pôdnej vlhkosti obmedzený kapacitou poľa namiesto bodu vädnutia. Vzhľadom na to, že SWDI je nezávislý na dĺžke záznamu, je možné po použiť aj na analýzu kratších časových radov pôdnej vlhkosti.



Obr. 11.36 Globálna vlhkosť pôdy vyjadrená indexom SMI, na základe meraní misie ESA SMOS. **Fig. 11.36** Global soil moisture expressed by SMI, based on ESA SMOS mission measurements. Source: ©ESA; esa.int/ESA_Multimedia/Images/2012/06/SMOS_soil_moisture_index

Z hľadiska charakterizácie poľnohospodárskeho sucha zodpovedajúceho vegetácii je pravdepodobne najznámejším indexom založeným na DPZ Index NDVI, charakterizujúci stav vegetácie (zdravá/nezdravá) a jej prítomnosť. Keďže je však spojený aj s určitými obmedzeniami, postupne boli vytvorené alternatívne vegetačné indexy ako EVI, SAVI, NDWI, resp. **Normalizovaný Viacpásmový Index Sucha NMDI** (*Normalized Multi-band Drought Index*). Okrem nich sa ešte používa škálovaná verzia NDVI – **Index Stavu Vegetácie VCI** (*Vegetation Condition Index*), ktorý sa vypočíta ako **VCI**_t = (**NDVI**_{min})/(**NDVI**_{max} - **NDVI**_{min}) v čase t, pričom eliminuje vplyv počasia (Obr. 11.37).



Obr. 11.37 Príklad indexu VCI pre Európu v roku 2019 na základe snímok misie Proba-V. **Fig. 11.37** Example of the VCI index for Europe in 2019 based on Proba-V images. Source: ©Copernicus Global Land Service, 2015. Distributed and produced by VITO NV, Belgium

Okrem nich existuje ešte viacero ďalších indexov na monitorovanie sucha v poľnohospodárskej krajine – Index Zdravia Vegetácie VHI (Vegetation Health Index); Index Reakcie Vegetácie na Sucho VegDRI (Vegetation Drought Response Index); Škálovaný Index Stavu Sucha SDCI (Scaled Drought Condition Index); Index Závažnosti Sucha DSI (Drought Severity Index); Index Kombinovaného Deficitu CDI (Combined Deficit Index); a iné.

Pri určovaní integrovanej reakcie poľnohospodárstva na sucho je nevyhnutné poznamenať, že vegetácia vykazuje oneskorenú reakciu na meteorologické sucho v dôsledku obsahu zvyškovej pôdnej vlhkosti a pamäte pôdnej vlhkosti. Pre presnú charakteristiku poľnohospodárskeho sucha je preto dôležité zohľadniť toto oneskorenie. V tejto súvislosti bol navrhnutý **Index Vlhkosti Pôdy Poľnohospodárskeho Sucha SMADI** (*Soil Moisture Agricultural Drought Index*).

11.5.3. Hydrological drought

Hydrologické sucho je spojené s deficitom povrchových a podpovrchových vodných zdrojov. Meteorologické sucho môže vyvolať poľnohospodárske sucho, ktoré môže viesť k hydrologickému suchu. Na identifikáciu období hydrologického sucha sa analyzujú anomálie prietoku v tokoch. Najstarším indexom pre monitorovanie hydrologického sucha je Palmerov Index Hydrologického Sucha PHDI (Palmer Hydrological Drought Index), ktorý funguje podobne ako PDSI. Zatiaľ čo PDSI považuje za koniec sucha moment, keď sa deficit vlahy začína postupne znižovať, PHDI považuje za koniec sucha moment, keď deficit vlahy úplne ustúpi. PHDI nie je vhodný v povodiach, kde do celkového odtoku z územia prispieva aj odtok z topiaceho sa snehu. Na charakterizovanie hydrologického sucha bol vytvorený Index Povrchového odtoku SRI (Surface Runoff Index). Vo všeobecnosti však platí, že do nedávnej minulosti neexistovali takmer žiadne výskumy, ktoré by do indexov hydrologického sucha integrovali aj údaje z DPZ. Až vypustenie misie GRACE a jej následných misií (2002, resp. 2018) otvorilo možnosti ako identifikovať zložky Zásob Suchozemskej Vody TWS (Terrestrial Water Storage) pre pôdnu vlhkosť, povrchovú, a podpovrchovú vodu v rámci povodia. Tým sa výskum v oblasti aplikácie DPZ na skúmanie hydrologického sucha rozšíril. Na identifikovanie hydrologického sucha sa môže použiť rozdiel medzi mesačnými anomáliami TWS a klimatológiou TWS. Pre tento účel sa používa **Index Celkového Deficitu Zásob TSDI** (*Total Storage Deficit Index*), na základe štandardizácie mesačnej anomálie TWS s následným spojením výsledku z časového intervalu s výsledkom v predchádzajúcom časovom intervale, prostredníctvom aritmeticky váženého súčtu (Obr. 11.38). Okrem toho, pre analyzovanie hydrologického sucha sú dáta z misie GRACE prispôsobené na hydrologické modely.



Obr. 11.38 Analýza sucha v juhozápadnej Číne v rokoch 2009 – 2010; a) index TSDI; b) pre porovnanie index PDSI.

Fig. 11.38 Analysis of drought in southwest China in 2009-2010; a) TSDI index; b) PDSI index for comparison.

Source: Wu et al., 2020

Podzemná voda je dôležitou súčasťou hydrologického cyklu. Sucho v oblasti podzemných vôd je definované ako situácia, keď je hladina podzemnej vody pod normálnou úrovňou. Keďže misia GRACE poskytuje informácie týkajúce sa zásob podzemných vôd, viaceré štúdie použili údaje GRACE na posúdenie sucha podzemných vôd. Oddelenie zložiek podzemnej vody z odhadov TWS sa vykonáva spravidla pomocou rovnice vodnej bilancie alebo pomocou simulácií modelov zemského povrchu. V súčasnosti sa uskutočňujú pokusy o využitie odhadov GRACE TWS spolu s interferometrickými údajmi SAR a meracími senzormi GNSS na určenie úbytku podzemných vôd. Niektoré štúdie tak isto prispôsobili údaje GRACE do hydrologických modelov na posúdenie vyčerpania podzemných vôd.

11.5.4. Drought monitoring in ESA mission applications

11.5.4.1. Copernicus Sentinel-1 data for arable drought monitoring system

Deficit zrážok v Argentíne v roku 2020 viedol k prognóze zníženia produkcie ozimín, ako aj produkcie krmovín, čo ovplyvnilo úžitkovosť hospodárskych zvierat v centrálnych regiónoch krajiny. Práve dáta z misie Sentinel-1 pomohli vytvoriť systém monitorovania týchto poľnohospodárskych plôch.

Švajčiarska spoločnosť Cropix vytvorila index na základe dát Sentinel-1 – **SAR Vodný Index SWI** (*SAR Water Index*), ktorý slúži ako zástupný ukazovateľ obsahu vody v rastlinách a vo vrchnej časti pôdy, kde nie je žiadna vegetácia. Pomocou SWI bolo možné vyhodnotiť vplyv nedostatku zrážok na vegetáciu. Analýza vychádzala z dvoch snímok spracovaných do podoby SWI indexu – z Augusta 2019 (rok s normálnymi zrážkami) a z Augusta 2020 (rok s nízkymi zrážkami) (Obr. 11.39).



Obr. 11.39 Vlavo - SAR Vodný Index z Augusta 2019; vpravo – SAR Vodný Index z Augusta 2020. **Fig. 11.39** Left - SAR Water Index from August 2019; right - SAR Water Index from August 2020. Source: Contains modified Copernicus Sentinel data (2019)/ processed by Cropix; sentinels.copernicus.eu/web/success-stories/-/copernicus-sentinel-1-data-help-establishdrought-monitoring-system-for-croplands

Na Obr. 11.40 je znázornený rozdiel medzi oboma akvizíciami na úrovni pixelov. Hoci k zmenám dochádza aj v dôsledku striedania rôznych plodín, tak celkový výsledok jasne preukazuje výrazne zníženie hodnôt SWI indexu medzi rokmi 2020-2019, pričom najväčšie rozdiely boli identifikované v okresoch s najvyšším osivom ozimín a krmovín.

Z obrázku vyplýva, že okresy s väčším počtom poľnohospodárskych plôch majú vyšší záporný rozdiel. Vo všeobecnosti možno povedať, že úroda ozimín bude výrazne nižšia ako v minulom roku. Na odhad vplyvu na úrodu je relevantné použiť objektívne údaje na zhodnotenie situácie. Využitie možností SAR na kontinuálne snímanie veľkých plôch so stabilnými časovými radmi umožňuje krížovú kontrolu stavu vegetácie v rôznych ročných obdobiach.



Obr. 11.40 Rozdielová snímka SAR Vodného Indexu medzi rokmi 2020-2019. **Fig. 11.40** Difference image of SAR Water Index between 2020-2019. Source: Contains modified Copernicus Sentinel data (2019)/ processed by Cropix; sentinels.copernicus.eu/web/success-stories/-/copernicus-sentinel-1-data-help-establishdrought-monitoring-system-for-croplands

SWI umožňuje kvantifikovať rozdiel medzi normálnym rokom a suchým rokom. Na základe týchto informácií je možné predpovedať výpadok poľnohospodárskej produkcie. Použitie indexov odvodených z údajov Copernicus Sentinel-1 SAR, ako sú SWI a ESVI (Vylepšený SAR Vegetačný Index), predstavuje základ pre tvorbu časových radov údajov na vytvorenie systému monitorovania ornej pôdy.

Copernicus Sentinel-1 je ideálny na realizáciu takýchto systémov z troch dôvodov. Prvým je, že priestorové rozlíšenie 20 x 20 m je dostatočné v prípade, že pozemky majú rozlohu viac ako 1 ha. Po druhé, časové rozlíšenie 6 alebo 12 dní je vo väčšine prípadov dostatočné na monitorovanie vývoja plodín. A tak isto je to spoľahlivosť systému Copernicus Sentinel-1.

11.5.4.2. Large-scale surface water changes from Sentinel-2 images during the 2018 drought in Germany

Monitorovanie a pochopenie časopriestorovej dynamiky hydrologického sucha s plynulým geografickým pokrytím veľkých oblastí je nevyhnutné na posúdenie vplyvov na vodné zdroje, priemysel, dopravu a ľudské zdravie. To sa stalo obzvlášť aktuálnym počas horúčav a sucha v roku 2018 v Nemecku, ktoré postihli krajinu v rôznych odvetviach a spôsobili výrazné prerušenie lodnej dopravy na riekach a jazerách s negatívnym vplyvom na cestovný ruch, dopravu a dodávateľské reťazce. Hydrologické sucho v Nemecku v roku 2018 bolo analyzované z pohľadu satelitných snímok Sentinel-2. Do analýzy boli zahrnuté vodné plochy s celoštátnym pokrytím v rôznych časových okamihoch pomocou automatizovaného spracovania, ktoré bolo založené na konvolučnej neurónovej sieti. Táto metóda pomohla vykonať segmentáciu vody s konzistentne vysokou celkovou presnosťou aj napriek rôznej topografii, využívaniu krajinnej pokrývky a atmosférickým podmienkam. Okrem toho boli v rámci analýzy identifikované hotspoty zmien v rozsahu vodných plôch v národnej mierke porovnaním mesačných máp vodných plôch za rok 2018 s príslušnými mapami z predchádzajúceho roka 2017.

Na kvantifikáciu zmien povrchovej vody počas sucha 2018 boli použité snímky Sentinel-2, s dôkladným pokrytím celého územia Nemecka v referenčných mesiacoch Október 2017 a 2018. Použité boli snímky L1C – rádiometricky kalibrované, ortorektifikované, v dlaždiciach 100 x 100 km (celkovo bolo potrebných 58 dlaždíc pre každý referenčný mesiac). Pre každý mesiac a každú dlaždicu bola zvolená scéna s najmenšou oblačnosťou a susedné časovo blízke dlaždice. Pre tri hotspoty boli použité všetky dostupné snímky Sentinel-2 počas 12 mesiacov.

Okrem snímok Sentinel-2 bola použitá aj dlhodobá globálna vrstva výskytu povrchovej vody odvodená zo snímok Landsat z rokov 1984 – 2015. Výskyt vody sa určil ako súčet detekcií vody za mesiac vydelený súčtom platných pozorovaní za ten istý mesiac. Z toho bol extrahovaný maximálny rozsah vody, ktorý bol definovaný ako – všetky lokality, ktoré boli niekedy počas 31 rokov detegované ako voda.

Detailný postup spracovania je možné nájsť v publikácii (Wieland & Martinis, 2020).

Na Obr. 11.41 je znázornená zmena medzi Októbrom 2017 a 2018 v podobe zmien detegovaných na úrovni pixelov, vyobrazená ako súhrnné oblasti zmien v 10 km šesťuholníkových bunkách. Na národnej úrovni je možné pozorovať výrazný pokles vody pozdĺž riek Rýn a Labe, a menej výrazný pokles vody pozdĺž riek Dunaj a Ems. Úbytok vody bol zaznamenaný aj v Bodamskom jazere a niekoľkých vodných plochách v severovýchodnom Nemecku.

Toto riešenie umožnilo spracovať satelitné údaje na použiteľné informačné produkty, ktoré môžu poskytnúť rýchle informácie v situáciách sucha. DPZ môže poskytnúť doplnkové informácie o rozsahu povrchovej vody na veľkých geografických územiach, s vysokou časovou frekvenciou a nízkymi nákladmi. Satelitné monitorovanie vody môže poskytnúť nielen relevantné informácie o hydrologických pomeroch v nemeraných oblastiach, ale môže poskytnúť aj dodatočné informácie o rozsahu vody v meraných oblastiach. Vďaka bezproblémovému pokrytiu a systematickému získavaniu údajov Sentinel-2 mohol byť vytvorený ucelený pohľad na hydrologické sucho v Nemecku v roku 2018. To môže podporiť vodohospodárske orgány pri lepšom pochopení vplyvu zmien v hydrologických pomeroch na životné prostredie, hospodárstvo a ľudské zdravie.



Obr. 11.41 Celková zmena povrchovej vody medzi Októbrom 2017 a 2018 v oblastiach s 10 km šesťuholníkovou sieťou.

Fig. 11.41 Total surface water change between October 2017 and 2018 in zones with a 10 km hexagonal network.

Source: Wieland & Martinis, 2020

11.5.4.3. Agricultural drought monitoring using Sentinel 3A

Využívaniu satelitných snímok na monitorovanie poľnohospodárskeho sucha sa venuje čoraz väčšia pozornosť vo výskume a uplatňuje sa aj v regionálnom a globálnom meradle. Na tento účel sa už používajú aj produkty teploty povrchu zeme LST (Land Surface Temperature) a žiarenia zo satelitu Sentinel-3A SLSTR (Sea and Land Surface Temperature Radiometer). Tieto dáta sa použili napríklad pre stanovenie Indexu **Teplotného Stavu Vegetácie VTCI** (*Vegetation Temperature Condition Index*) za účelom monitorovania poľnohospodárskeho sucha v Mongolsku v roku 2017. Index VTCI bol definovaný ako:

$$\mathbf{VTCI} = \frac{LST_{NDVI_{i,max}} - LST_{NDVI_{i}}}{LST_{NDVI_{i,max}} - LST_{NDVI_{i,min}}}$$
(11.13)

pričom:

 $LST_{NDVI_{i,max}} = a + b * NDVI_i \quad a \quad LST_{NDVI_{i,min}} = a' + b' * NDVI_i$ (11.14)

kde *a*, *b*, *a'* a *b'* sú koeficienty lineárnej regresie, pričom ich presnosť je rozhodujúca pre určenie VTCI.

Na tento účel je najprv potrebné analyzovať koreláciu medzi LST a indexom NDVI pomocou časových radov produktov MODIS LST a NDVI v rôznych podmienkach rastu vegetácie. Z toho bolo možné usúdiť, že VCI sa dá použiť iba v teplých obdobiach (neskoré jarné a letné obdobia), kedy boli identifikované negatívne korelácie medzi LST a NDVI. Pre oblasť Mongolska boli preto použité produkty Sentinel-3A z obdobia Júl – August 2017. Z ich analýz vyplynulo , že VTCI rýchlo a včas reaguje na zrážky. Tak isto krížové porovnanie hodnôt VTCI zo Sentinel-3A SLSTR ukazuje vysokú konzistenciu z hľadiska priestorového rozloženia s hodnotami odhadnutými z produktov MODIS.

Na Obr. 11.42 je zobrazené porovnanie troch snímok VTCI získaných v troch rôznych dátumoch. V časti a) je rozdiel v snímkach VTCI zaznamenaných 28. júla a 12. augusta. Vzhľadom na to, že v období od 12. augusta do 18. augusta sa v skúmanej oblasti vyskytlo viacero zrážok, intenzita sucha by sa mala znížiť. Z časti (a) tiež vyplýva, že hodnota rozdielu VTCI (VTCI 12. augusta mínus VTCI 28. júla) bola vo väčšine oblastí kladná, čo naznačuje, že závažnosť sucha sa oslabila. V južnej časti sa však hodnota rozdielu VTCI znížila možno vplyvom vysokej teploty a suchého vetra, ktorý sa šíril z južnej púštnej oblasti.

Ako je znázornené v časti b), hodnota rozdielu (VTCI 18. augusta mínus VTCI 12. augusta) bola vo väčšine oblastí záporná, čo naznačuje, že závažnosť sucha sa v týchto oblastiach zvýšila. Zmeny VTCI zaznamenané v troch vybraných termínoch naznačili, že výsledky monitorovania poľnohospodárskeho sucha zodpovedajú skutočným pozorovaniam.



Obr. 11.42 Rozdiely vo VTCI medzi tromi dátumami. **Fig. 11.42** Differences in VTCI between the three dates. Source: Hu et al., 2019

V kombinácii s LST a NDVI získanými zo satelitných údajov môže VTCI poskytnúť cennejšie informácie na monitorovanie poľnohospodárskeho sucha, najmä v rozsiahlych oblastiach a regiónoch s nedostatočným počtom pozemných monitorovacích staníc alebo infraštruktúry. Index je tiež citlivý na zrážky a môže účinne poskytovať informácie o suchu v krátkom čase. Porovnanie hodnôt VTCI získaných z rôznych satelitov ukazuje určité rozdiely, o ktorých sa predpokladá, že sú dôsledkom rôznych časov preletu, ktorými sa získavajú rôzne odhady LST, ale medzi produktmi existuje konzistentnosť, ktorá podporuje ďalší vývoj VTCI z produktov Sentinel-3A SLSTR.

Porovnanie výsledkov z MODIS a SLSTR odhalilo vysokú zhodu v ich priestorovom rozložení v obrábaných oblastiach. To ukazuje, že produkty Sentinel-3A SLSTR sa môžu používať na monitorovanie poľnohospodárskeho sucha rovnako ako produkty MODIS, ale nemožno ich priamo porovnávať kvôli časovým rozdielom pri prelete jednotlivých satelitov.

11.6. Space4Water portal

V roku 2016 Úrad OSN pre vesmírne záležitosti (UNOOSA) a Medzinárodná cena princa Sultána bin Abdulaziza za vodu (PSIPW) podpísali dohodu o spolupráci na spoločnom cieli, ktorým je podpora využívania vesmírnych technológií na zlepšenie prístupu k vode.

K formálnej dohode došlo po mnohých rokoch prebiehajúcej spolupráce medzi oboma subjektmi - spolupráce, ktorá sa začala v roku 2008 prvým spoločným projektom na spoločné vytvorenie informačného portálu o vode.

Partnerstvá s ďalšími subjektmi v oblasti vesmíru a vodného hospodárstva sa považujú za neoddeliteľný prvok iniciatívy Space4Water Portal na podporu interoperability a spoločného využívania zdrojov.

Projekt Space4Water bol spustený v roku 2018 s cieľom podporiť využívanie vesmírnych technológií na zlepšenie prístupu k vode. Projekt pozostáva z troch pilierov (Obr. 11.43):

- 1. podporovať vedeckú výmenu prostredníctvom konferencií s cieľom informovať o rozhodovaní a mať vplyv na politiku,
- 2. osloviť a informovať používateľov na celom svete prostredníctvom portálu Space4Water s cieľom prezentovať profesionálnu prácu a umožniť používateľom nájsť partnerov na základe ich odborných znalostí alebo regionálneho zamerania,
- 3. budovanie komunity prostredníctvom interaktívnych stretnutí zainteresovaných strán na portáli Space4Water s cieľom vytvoriť výbor expertov pre zabezpečenie kvality a vedecké usmernenie.



Obr. 11.43 Tri základné piliere projektu Space4Water. **Fig. 11.43** The three pillars of the Space4Water project. Source: www.space4water.org/s4w/web/about/vision-mission

UNOOSA a PSIPW spoločne organizujú sériu medzinárodných konferencií zameraných na využívanie vesmírnych technológií vo vodnom hospodárstve, pričom od roku 2008 sa úspešne uskutočnili štyri takéto podujatia. Prvá konferencia sa konala v Saudskej Arábii, druhá v Argentíne, tretia v roku 2014 sa uskutočnila v Maroku a posledná sa konala začiatkom roka 2018 v Pakistane.

Portál

Portál združuje organizácie pôsobiace v tejto oblasti s cieľom zdieľať informácie o projektoch, iniciatívach, satelitných misiách, softvéri, komunitných portáloch, materiáloch na budovanie kapacít a odbornú prípravu, konferenciách, seminároch, údajoch, ako aj o novinkách a publikáciách v tomto odvetví.

Portál Space4Water slúži ako:

- platforma na interdisciplinárnu výmenu poznatkov o vesmírnych riešeniach a technológiách pre témy súvisiace s vodou,
- iniciatíva na sprístupnenie a porovnanie informácií v tejto oblasti,
- platforma pre viaceré zainteresované strany,
- platforma na podporu budovania kapacít,
- portál pre odborné komunity, ktoré si vymieňajú informácie o softvéri, aplikáciách, publikáciách, projektoch a iniciatívach,
- portál, ktorý je prístupný aj pre aktérov z rozvojových krajín.

Základné dôvody vzniku portálu:

- Voda je kľúčová pre život a pre dosiahnutie najnovších globálnych cieľov udržateľného rozvoja.
- Pitná voda je vzácny zdroj a nedostatok sladkej vody sa stále zvyšuje a predstavuje výzvu pre rastúce populácie na celom svete, čo často vedie ku konfliktom a ďalším ekonomickým dopadom.
- Vesmírne technológie a riešenia založené na vesmírnych technológiách môžu byť celkovo prínosom pre vodné hospodárstvo, môžu pomôcť monitorovať ciele udržateľného rozvoja a ukazovatele priamo alebo nepriamo súvisiace s vodou a môžu uľahčiť lepšie využívanie vody a zdieľanie vodných zdrojov na medzinárodnej úrovni a môžu pomôcť aj pri súvisiacich činnostiach v oblasti riadenia katastrof a reakcie na krízy.
- Je preto kľúčové, aby sa takéto výhody a riešenia sústredene zhromažďovali a aby sa ďalej zvyšovalo povedomie o ich existencii prostredníctvom iniciatív na šírenie poznatkov, na ktoré je zameraný tento portál.
- Účinné hospodárenie s vodou nám môže pomôcť konkrétne dosiahnuť viacero cieľov trvalo udržateľného rozvoja.
- Projekt Space for Water je súčasťou úsilia UNOOSA o podporu vesmíru ako nástroja na dosiahnutie Agendy 2030 pre udržateľný rozvoj a jej 17 cieľov udržateľného rozvoja. Tento projekt sa konkrétne zaoberá cieľom 6 "Zabezpečiť dostupnosť a udržateľné riadenie vody a sanitácie pre všetkých" a cieľom 17 "Posilniť prostriedky implementácie a oživiť globálne partnerstvo pre udržateľný rozvoj".

Ďalšie informácie a odkazy na príslušný softvér, webové aplikácie, a nástroje, je možné nájsť na adrese <u>http://www.space4water.org</u>.
11.7. Snow and Ice

Veľká časť zemského povrchu je aspoň časť roka pokrytá snehom, ľadom alebo zamrznutou zemou, najmä vo vysokých zemepisných šírkach a/alebo vo vysokých nadmorských výškach. Táto oblasť, v ktorej sa voda vyskytuje v zamrznutom stave, sa označuje ako kryosféra. Sneh a ľad majú veľkú rozmanitosť foriem - mäkké alebo tvrdé, hladké alebo drsné, jasne biele alebo veľmi tmavé. Sneh a ľad vnímame ako chlad, ale môžu tiež poskytovať izoláciu. Ľad môže byť tvrdý ako skala, ale pod tlakom v hĺbke ľadovca môže prúdiť a pohybovať sa, čím mení tvar samotnej krajiny (Obr. 11.44).



Obr. 11.44 Zložky kryosféry a ich časové rozpätie. **Fig. 11.44** Components of the cryosphere and their timescales. Source: Lemke et al., 2007

Celkovo je sneh zvyčajne vysoko odrazivý vo viditeľnom spektre, so silnejšou absorpciou v častiach v strednom infračervenom pásme. Jeho spektrálna odozva sa však môže líšiť v závislosti od hustoty, veľkosti zrna, obsahu vody v kvapalnom skupenstve a prítomnosti nečistôt, ako napr. prach, sadze a riasy. Vo všeobecnosti platí, že so starnutím snehovej pokrývky jej celková odrazivosť klesá. Čiastočne je to spôsobené štrukturálnymi zmenami v samotných kryštáloch snehu a čiastočne v dôsledku hromadenia a koncentrácii vyššie uvedených nečistôt. Spektrálna odrazivosť ľadu môže byť veľmi premenlivá (Obr. 11.45). Vzhľad ľadu závisí od drsnosti a veku jeho povrchu, jeho hrúbky (a v prípade tenkého ľadu aj na odrazových vlastnostiach povrchu pod ním) a prítomnosti alebo neprítomnosti vzduchových bublín spolu s mnohými ďalšími faktormi. Sneh a ľad majú tendenciu pôsobiť ako zrkadlové reflektory, najmä drsné povrchy môžu rozptyľovať svetlo viac difúzne. Oba povrchy majú relatívne vysokú mieru vyžarovania v tepelnej infračervenej oblasti, zvyčajne 0,85 až 0,90 pre suchý sneh a 0,97 až 0,98 pre drsný ľad. Odozva snehu a ľadu na radarové signály je ešte komplikovanejšia ako vo viditeľnom/infračervenom spektre. Čiastočne je to spôsobené už spomínanou

rôznorodosťou foriem a štruktúr, ktoré sa môžu vyskytovať v snehu a ľade. Čiastočne kvôli tomu, že ich dielektrická konštanta sa môže radikálne líšiť v závislosti od hustoty a prítomnosti alebo neprítomnosti kvapalnej vody. Dielektrická konštanta suchého snehu je zvyčajne niekde medzi hodnotami pre ľad (3,2) a vzduch (1,0), v závislosti od hustoty, zatiaľ čo dielektrická konštanta pre mokrý sneh je silne ovplyvnená vysokou dielektrickou konštantou vody (80).





DPZ sa výrazne používa na monitorovanie sezónnej snehovej pokrývky v stredných až vysokých zemepisných šírkach. Takéto údaje sú nevyhnutné pre hospodárenie s vodnými zdrojmi (kde sú zásoby vody po prúde napájané snehovou pokrývkou vo vyšších nadmorských výškach), predpovedanie povodní a modelovanie regionálnej energetickej bilancie. Monitorovanie rozsahu snehovej pokrývky sa zvyčajne vykonáva na veľkých plochách pomocou optických senzorov s relatívne hrubým rozlíšením, ale v rámci špecifických štúdií sa môžu použiť senzory s vyšším rozlíšením. Chyby v snehových mapách odvodených zo satelitov sú vo všeobecnosti najväčšie v zalesnených oblastiach, zatiaľ čo ich spoľahlivosť sa zvyšuje v otvorenom teréne. Pasívne mikrovlnné systémy sa používajú aj na vytváranie snehových máp v kontinentálnej až globálnej mierke.

Pozemný ľad, najmä v horských ľadovcoch a väčších ľadových príkrovoch, je taktiež predmetom sledovania pomocou DPZ. Historické letecké fotografie (alebo historické satelitné fotografie) spolu s modernými satelitnými snímkami s vysokým rozlíšením sa často používajú na meranie dlhodobých zmien koncových polôh ľadovcov ako súčasť štúdií hmotnostnej bilancie ľadovcov (rýchlosť, akou koncové časti ľadovca postupujú alebo ustupujú, je ovplyvnená kladnou alebo zápornou bilanciou hmotnosti ľadovca, ktorá zasa naznačuje, či ľadovec získava alebo stráca ľad). Rýchlosť toku ľadu v ľadovci možno merať pomocou algoritmov na sledovanie prvkov s multitemporálnymi optickými alebo radarovými snímkami alebo pomocou diferenciálnej radarovej interferometrie, a tým kvantifikovať variabilitu rýchlosti toku ľadu. Zmeny nadmorskej

výšky (a hrúbky) ľadovca alebo ľadovej pokrývky možno merať pomocou LIDAR-u, radarovej altimetrie alebo radarovej interferometrie. Identifikácia ľadovcových foriem reliéfu, ako sú morény, eskery, a iné prvky na leteckých alebo satelitných snímkach, môže pomôcť geológom odvodiť históriu a minulé podnebie postglaciálnej krajiny.

Z hľadiska priestorového rozsahu sa veľká časť svetového ľadu nenachádza na pevnine, ale ako morský ľad v Severnom ľadovom oceáne a jeho susedných vodných plochách a v Južnom oceáne obklopujúcom Antarktídu. Morský ľad zohráva významnú úlohu v planetárnej klíme, pretože v lete odráža slnečné žiarenie od Zeme a v zime izoluje oceán pod ľadom od chladnejšej atmosféry. Poskytuje prostredie pre arktické voľne žijúce živočíchy, ako sú tulene, mrože a ľadové medvede. Predstavuje vážne obmedzenie pre množstvo hospodárskych činností vo vysokých zemepisných šírkach, od lodnej dopravy (cez Severozápadný priechod v kanadskej Arktíde alebo Severnú morskú cestu pozdĺž ruského arktického pobrežia) až po prieskum ložísk ropy na mori. Morský ľad sa bežne monitoruje pomocou pasívneho mikrovlnného DPZ, pričom sa používajú aj optické senzory a aktívne mikrovlnné (radarové) systémy.

11.7.1. Optical RS of Snow Cover

Snehová pokrývka má zásadný význam pre našu klímu. Sneh mení energetickú bilanciu kontinentálneho povrchu, pretože odráža významnú časť dopadajúceho slnečného žiarenia. Prítomnosť snehu ovplyvňuje aj povrchovú vlhkosť a teplotu na spodnej hranici atmosféry, čo následne ovplyvňuje dynamiku klímy. Táto "klimatická" úloha snehovej pokrývky má významný vplyv na boreálne a polárne oblasti (Sibír, Grónsko, Antarktída, atď.). Techniky DPZ sú vhodným nástrojom na štúdium vlastností snehovej pokrývky pre takto rozsiahle a nedostatočne monitorované oblasti. V niektorých regiónoch navyše sneh predstavuje aj základný zdroj čerstvej vody. Odhaduje sa, že šestina svetovej populácie je závislá od zásobovanie sladkou vodou z topiaceho sa snehu. V mnohých polosuchých a stredomorských oblastiach umožňuje jarné topenie najmä v horných povodiach zavlažovať obrábanú pôdu po prúde riek práve v čase, keď začína rásť vegetácia. V horách sa topenie snehu využíva aj na vodnú energiu. V horských oblastiach nemôžu in situ merania zobraziť vysokú prirodzenú variabilitu snehovej pokrývky v dôsledku topografických podmienok, čo je však možné pozorovať pomocou satelitných snímok. Znalosť vlastností snehovej pokrývky je tiež nevyhnutná pre predpovedanie prírodných rizík, ako sú lavíny alebo povodne v horských oblastiach. V mnohých horských oblastiach je zároveň sneh ekonomickým zdrojom pre zimný cestovný ruch.

Snehová pokrývka je jednou zo zložiek systému Zeme, ktorá je najviac najzraniteľnejšia voči klimatickým zmenám. Zvyšujúce sa teploty majú priamy vplyv na rozšírenie, množstvo a fyzikálne vlastnosti snehovej pokrývky, ktoré majú potom významné dôsledky na fungovanie ekosystémov, na hydrológiu povodí ovplyvnených snehovou pokrývkou a na samotné fungovanie klímy. Napríklad bolo pozorované, že v povodiach nachádzajúcich sa v západných štátoch USA a Kanady existuje od polovice 20. storočia trend skoršieho nástupu jarného maximálneho prietoku v dôsledku skoršieho topenia snehu. Dôsledkom je zníženie prietoku riek v lete, keď je tlak na vodu a na vodné zdroje je najvyšší.

Optické vlastnosti snehu

Sneh na zemi sa od väčšiny zemských povrchov líši vysokou odrazivosťou vo viditeľnej a blízkej infračervenej oblasti vlnových dĺžok (0,350 až 1 µm), kde sa odrazivosť snehu blíži k hodnote 1 (pozri Obr. 11.46); inými slovami, sneh odráža takmer všetko dopadajúce žiarenie. Pri väčších vlnových dĺžkach (typicky nad 1 µm, ktoré sa často označujú ako stredná infračervená oblasť alebo "MIR") sa odrazivosť snehu výrazne

znižuje. V týchto vlnových dĺžkach sneh odráža dokonca menej ako niektoré druhy vegetácie. Väčšina dopadajúceho žiarenia v týchto vlnových dĺžkach je absorbovaná v snehovej pokrývke. Tieto jedinečné spektrálne charakteristiky sa využívajú v DPZ s cieľom rozlíšiť sneh od iných typov povrchov. Z optických vlastností snehu tiež vyplýva, že hĺbka prieniku slnečného svetla do snehovej pokrývky sa mení v závislosti od vlnovej dĺžky. Vo viditeľnom spektre môže svetlo preniknúť do snehovej pokrývky až do pol metra, zatiaľ čo v infračervenom pásme je signál rýchlo absorbovaný pod povrchom a odráža len vlastnosti niekoľkých milimetrov vrchnej vrstvy snehovej pokrývky.





V blízkych infračervených vlnových dĺžkach je odrazivosť snehu ovplyvnená hlavne jeho mikroštruktúrou. Mikroštruktúru snehu možno v prvej aproximácii opísať hustotou snehu a pomerom medzi celkovým povrchom ľadových kryštálikov a ich hmotnosťou, ktorý je známy ako špecifická plocha povrchu (Specific Surface Area - SSA). SSA je nepriamo úmerná optickému polomeru, ktorý sa zvykne používať na výpočet odrazivosti. Čím menšie sú ľadové kryštály (a teda čím vyššia je SSA), tým väčšia je odrazivosť. Pre slnečné žiarenie je rozptyl úmerný povrchu, zatiaľ čo absorpcia je úmerná objemu. Z tejto závislosti vyplýva, že čím väčšie sú kryštály, tým nižšia je odrazivosť a teda aj väčšie množstvo energie absorbovanej snehovou pokrývkou. Táto posledná vlastnosť má za následok zvýraznenie premeny snehu – t.j. urýchľuje rast zŕn. Na druhej strane SSA naďalej klesá a odrazivosť sa znižuje. Tento efekt je známy ako vplyv sneh - odrazivosť (resp. ľad – odrazivosť).

Vo viditeľných vlnových dĺžkach je odraz snehu citlivý na prítomnosť nečistôt absorbujúcich svetlo, ako sú sadze alebo minerálny prach, kvôli vysokej priehľadnosti ľadu. Čím väčšie je množstvo nečistôt, tým nižšia je odrazivosť. V podstate platí, že čím je SSA nižšia, tým väčší je vplyv nečistôt na odrazivosť. V dôsledku toho bude mať prítomnosť nečistôt účinok na posilnenie vplyvu sneh – odrazivosť.

Okrem toho je odrazivosť citlivá na uhlové charakteristiky dopadajúceho žiarenia. V podstate čím bližšie je dopadajúce žiarenie k vertikále, tým slabšia bude odrazivosť. Pre

fotón, ktorý dopadne kolmo na snehovú pokrývku, bude ťažšie opustiť snehovú pokrývku ako pre fotón, ktorý sa iba "otrie" o povrch.

Index lomu tekutej vody je veľmi podobný indexu lomu ľadu, ale medzi indexmi dvoch skupenstiev vody je mierny spektrálny posun. Odrazivosť suchého snehu je preto veľmi podobná odrazu mokrého snehu, okrem toho, že v mokrom snehu sa zväčšujú snehové zrná, čo spôsobuje pokles odrazivosti. Je to viditeľné najmä v strednej infračervenej oblasti. Pomocou hyperspektrálnych údajov je možné identifikovať prítomnosť vody v snehu v tekutej forme prostredníctvom mierneho spektrálneho rozdielu medzi týmito dvoma indexmi. Okrem toho drsnosť povrchu snehu (napríklad tvorba štruktúr vplyvom vetra) zmení odrazivosť snehu. Ako vo všeobecnosti platí, zvýšená drsnosť povrchu spôsobí zníženie odrazivosti.

Možno teda konštatovať, že sneh je komplexný materiál, ktorého optické vlastnosti závisia od charakteristík dopadajúceho žiarenia, od jeho fyzikálnych vlastností a od množstva prímesí pohlcujúcich svetlo, ktoré obsahuje.

11.7.1.1. Methods of optical RS of snow cover

Kvôli špecifickej odrazivosti snehu sú metódy používané na detekciu jeho prítomnosti relatívne jednoznačné a dostatočne účinné. Najčastejšie používanou metódou je detekcia pomocou indexu **Normalizovaný Diferenčný Snehový Index NDSI** (*Normalized Difference Snow Index*):

$$\mathbf{NDSI} = \frac{Green - SWIR}{Green + SWIR} = \frac{B3 - B11}{B3 + B11}$$
(11.15)

NDSI je založený na skutočnosti, že odrazivosť snehu je vyššia vo viditeľnom spektre a nižšia v SWIR pásme (1-3 µm), čo umožňuje rozlíšiť medzi snehom a oblakmi, ktorých odrazivosť zostáva v SWIR vysoká. Pre výsledné hodnoty NDSI platí:

- pixely s výrazne negatívnymi hodnotami sú považované za bezoblačné;
- pixely obsahujúce s najväčšou pravdepodobnosťou oblačnosť dosahujú hodnoty od -0.1 do 0.2;
- pixely s hodnotou NDSI < 0.2 sú považované za pixely "bez snehu";
- pixely s hodnotou NDSI > 0.41 sú považované za pixely obsahujúce sneh, s pravdepodobnosťou 1.0;
- pixely s hodnotou 0.2 < NDSI < 0.4 sú považované za pixely pravdepodobne obsahujúce sneh, s pravdepodobnosťou snehu vypočítanou lineárne od 0.0 do 0.1.

Ukážka využitia indexu NDSI je zobrazená na Obr. 11.47. Vo vrchnej časti je RBG kompozit snímky Sentinel-2 pre oblasť Vysokých Tatier (Slovensko) z 18.06.2021, obsahujúci zelenú farbu novej vegetácie, snehové polia vo vyšších polohách, aj oblačnosť zakrývajúcu časť scény. Spodná časť znázorňuje masku snehu vypočítanú podľa NDSI.



Obr. 11.47 Vymedzenie snehovej pokrývky na základe indexu NDSI vo Vysokých Tatrách (Slovensko) v Júni 2021.

Fig. 11.47 Identification of snow cover based on NDSI index in the High Tatras (Slovakia) in June 2021.

Source: Modified Copernicus Sentinel data [2021]/Sentinel Hub

Detailnejší postup je možné nájsť v dokumente S2 MPC Level-2A Algorithm Theoretical Basis Document (*Louis & L2A Team, 2021*).

Pokročilejšie modely umožňujú vypočítať percento snehovej pokrývky v pixeli; väčšinou sa jedná o metódy *spectral unmixing*. Tieto metódy sa opierajú o knižnicu spektrálnych referencií rôznych typov povrchov (starý alebo čerstvý, špinavý alebo čistý sneh, ľad, skaly, vegetácia), čo umožňuje opísať spektrum pixelu ako (spravidla) lineárnu kombináciu spektrálnych referencií. Koeficienty tejto lineárnej kombinácie, označované ako abundancia, charakterizujú percentuálny podiel každého typu povrchu v pixeli. Tieto metódy sú síce náročnejším spôsobom výpočtu ako NDSI, ale poskytujú presnejšiu identifikáciu (Obr. 11.48).



Obr. 11.48 Hore – snímka Sentinel-2 vo falošných farbách (SWIRI, NIR, Red) zobrazujúca časť pobrežia v Nórsku, pričom sneh sa zobrazuje ako tyrkysový. Dole – snímka zobrazujúca podiel zasneženej plochy získaný pomocou metód spectral unmixing, pričom čierne oblasti sú bez snehu, sivé sú čiastočne pokryté snehom, a biele úplne pokryté snehom.

Fig. 11.48 Left - Sentinel-2 image in false colours (SWIR1, NIR, Red) showing part of the coastline in Norway, with the snow appearing as turquoise. Right - an image showing the fractional snow-covered area obtained using spectral unmixing, with black areas free of snow, grey areas partially covered with snow, and white areas completely covered with snow. Source: Aalstad, 2019

11.7.1.2. Reflectance and optical radius, light-absorbing impurities

Okrem rozsahu zasneženej oblasti umožňujú údaje o spektrálnej odrazivosti zachytené na satelitnej snímke určite niektoré fyzikálne a chemické vlastnosti samotného snehu. Pomocou optických satelitných snímok možno vo všeobecnosti identifikovať dva hlavné parametre: odrazivosť, a optický polomer, t.j. sférický polomer s rovnakou špecifickou plochou povrchu (SSA) ako sneh.

Odrazivosť sa používa na odhad radiačnej a povrchovej energetickej bilancie alebo na vyhodnotenie detailných snehových modelov. Existujú dva hlavné typy metód na získavanie spektrálnej odrazivosti snehu z multispektrálnych senzorov. Prvá a najjednoduchšia metóda spočíva v stanovení parametrizácie medzi satelitnými spektrálnymi odrazivosťami a odrazivosťou nameranou in situ. Potom je možné aplikovať tento lineárny alebo kvadratický vzťah na väčšiu priestorovú alebo časovú oblasť. Pri tejto jednoduchej metódou nie je možné brať do úvahy spektrálne variácie optických vlastností snehu s charakteristikami povrchu. Druhá metóda spočíva vo výpočte fyzikálnych parametrov snehovej pokrývky pomocou spektrálnych údajov a extrapolácii hodnôt pásiem naprieč celým spektrom pomocou modelu prenosu žiarenia pre snehovú pokrývku.

Optický polomer je príkladom ďalšej premennej, ktorá sa dá vypočítať pomocou satelitných snímok, či už na výpočet odrazivosti, na sledovanie fyzikálnych vlastností snehovej pokrývky alebo na vyhodnotenie simulácií snehovej pokrývky. Algoritmy spracovania sú často založené na použití infračerveného pásma a buď jedného alebo niekoľkých pásiem vo viditeľnom spektre, pričom infračervené pásmo nesie podpis optického polomeru a viditeľné pásmo(á) umožňujú oddeliť vplyv atmosféry na satelitné údaje. Algoritmy sa líšia vo vzťahu medzi optickým polomerom a odrazivosťou na základe rôznych typov modelov prenosu žiarenia. Príklad mapy optického polomeru je znázornený na Obr. 11.49.



Obr. 11.49 Optický rádius snehu pre oblasť vo Francúzskych Alpách, získaný z dát MODIS v Marci 2009.

Fig. 11.49 Snow Optical radius for an area in the French Alps, obtained from MODIS data in March 2009.

Source: Mary et al., 2013

Ako už bolo uvedené, odrazivosť snehu závisí aj od typu a množstva nečistôt obsiahnutých v snehovej pokrývke. Získavanie obsahu nečistôt pomocou satelitných snímok je náročné, vzhľadom na:

- presnosť spektrálnej odrazivosti v satelitných dátach;
- kvalitu atmosférickej korekcie;
- neistoty indexov lomu rôznych typov nečistôt.

Z toho vyplýva, že je vhodnejšie obmedziť sa na skúmanie ich vplyvu alebo trendov, bez snahy získať presný obsah nečistôt.

Spektrálna odrazivosť získaná zo satelitných dát nám teda umožňuje určiť odrazivosť a optický polomer snehovej pokrývky. Zároveň poskytuje aj informácie o čistote snehu. Je dôležité poznamenať, že presnosť satelitného určovania vlastností snehu je obmedzená atmosférickou korekciou, uhlovým rozložením svetla odrazeného snehom a drsnosťou snehu.

11.7.2. Methods of Radar RS of Snow Cover

Zasnežené oblasti ovplyvňujú globálnu radiačnú bilanciu, podzemnú vodu, odtok vody, ľadovce, flóru a faunu a ľudské aktivity, ako je cestovný ruch, stavebné inžinierstvo a infraštruktúra. V rámci všetkých kryosférických zložiek sneh pokrýva najširšiu oblasť: počas zimy je viac ako 40 % severnej pologule pokrytých snehom. V dôsledku mnohých vplyvov na životné prostredie sa snehová pokrývka rieši v Piatej hodnotiacej správe (AR5) Medzivládneho panelu pre zmenu klímy (IPCC) a identifikuje sa ako kritická premenná klímy v rámci globálneho systému pozorovania klímy. Obr. 11.50 poskytuje prehľad

niektorých aspektov súvisiacich so snehovou pokrývkou a tiež znázorňuje niektoré premenlivejšie charakteristiky snehovej pokrývky, ako je obsah tekutej vody, veľkosť zŕn, hustota a ekvivalent vody v snehu (Snow Water Equivalent - SWE).



Obr. 11.50 Rôzne typy snehu a snehovej čiary (tmavo modré písmo), dôležitosť snehu (čierne písmo), vlastnosti súvisiace so SAR technológiou (písmo kurzívou), faktory ovplyvňujúce sneh (zelené písmo), parametre snehovej pokrývky (červené písmo).

Fig. 11.50 Different types of snow and snow line (dark blue font), importance of snow (black font), characteristics related to SAR (italics), factors influencing snow (green font), snow cover parameters (red font).

Source: Tsai et al., 2019

Vzhľadom na široké plošné pokrytie, časovú variabilitu, nedostupnosť a odľahlú polohu mnohých zasnežených oblastí je DPZ ideálnou technikou získavania údajov na monitorovanie snehovej pokrývky a jej trendov a vývoja v priestorovom aj časovom meradle. Hoci využívanie údajov z optického/multispektrálneho DPZ na monitorovanie rozsahu snehovej pokrývky je limitované oblačnosťou a tmou počas polárnej noci v polárnych oblastiach, tak má dlhšiu históriu v porovnaní s údajmi SAR. Údaje SAR ponúkajú cennú alternatívu na monitorovanie snehovej pokrývky, pretože sú nezávislé od oblačnosti a podmienok osvetlenia. V dôsledku dostupnosti nových satelitov SAR počas posledných desaťročí spolu s vývojom detekčných algoritmov založených na SAR sa výraznejšie rozšírila detekcia rozsahu snehovej pokrývky na základe SAR dát namiesto optických senzorov.

11.7.2.1. Characteristics of SAR and snow

Vďaka svojej aktívnej a relatívne dlhej vlnovej dĺžke sa SAR nespolieha na slnečné osvetlenie, a preto môže fungovať vo dne aj v noci. SAR môže preniknúť aj cez oblačnosť,

čo umožňuje meranie povrchu za každého počasia a svetelných podmienok. Tieto schopnosti sú obzvlášť cenné, pokiaľ ide o monitorovanie snehovej pokrývky, pretože zasnežené alpské oblasti sú často pokryté mrakmi a oblasti s vysokými zemepisnými šírkami sú počas zimy ovplyvnené polárnou tmou. Navyše dlhšie vlnové dĺžky SAR môžu preniknúť do snehovej pokrývky, čo môže poskytnúť informácie o podmienkach snehovej pokrývky, ako je zrnitosť snehu a obsah tekutej/zmrznutej vody – SWE (Snow Water Equivalent), a môžu dokonca preniknúť zamrznutou vrstvou na povrchu snehu.

Vďaka jedinečným charakteristikám snímania SAR sú informácie o snehu zaznamenané V snímkach SAR zásadne odlišné V porovnaní S optickými/multispektrálnymi snímkami. SAR zaznamenáva povrchové charakteristiky súvisiace s drsnosťou a dielektrickými vlastnosťami; optické DPZ zaznamenáva odraz/absorpciu prichádzajúceho slnečného žiarenia vo vrchnej vrstve povrchu. Keďže sneh, ľad a oblaky sa vyznačujú porovnateľne podobnými odrazovými vlastnosťami vo viditeľnej a – v závislosti od fázy oblačnosti – v blízkej až strednej infračervenej časti spektra, pri pokuse o klasifikáciu snehovej pokrývky a jej odlíšenie od ľadu alebo oblačnosti môžu nastať nejasnosti. SAR senzory dokážu prekonať túto nejednoznačnosť, pretože merajú povrchové vlastnosti v inej oblasti z hľadiska koeficientu spätného rozptylu, ktorý je funkciou vlnovej dĺžky signálu SAR, drsnosti a dielektrických vlastností povrchu, a nie odrazových vlastností (Obr. 11.51).



Obr. 11.51 Rozptyl radarového signálu pre sneh a ľad, pričom je celkový koeficient spätného rozptylu; je koeficient spätného rozptylu rozhrania vzduch/sneh; je koeficient objemového spätného rozptylu; je koeficient spätného rozptylu zeme; je hĺbka snehu; a je priepustnosť snehovej vrstvy.

Fig. 11.51 Radar signal scattering for snow and ice, where is target backscattering coefficient; is backscattering coefficient of air/snow interface; is volume backscattering coefficient; is backscattering coefficient of ground; is snow depth, and is transmissivity of snow layer. Source: Schweizer, 2018

Ďalšia výhoda SAR senzorov je odvodená z informácií o fáze, ktoré zaznamenávajú. Rôzne polarizácie (horizontálna, vertikálna) umožňujú detekciu dodatočných fyzikálnych charakteristík povrchu, ako je tvar, materiál alebo uhol pozorovaného cieľa. Navyše, na základe fázových informácií zaznamenaných pomocou SAR možno generovať koherenciu a interferometriu, čo môže indikovať deformáciu a stabilitu pozemných prvkov. Takéto informácie možno analyzovať na detekciu a kvantifikáciu napríklad rýchlosti ľadovca alebo iných pohyblivých cieľov.

SAR má však aj niektoré praktické nevýhody pre aplikácie v kryosfére. Nevýhodou je pomerne nízke temporálne rozlíšenie (t.j. dni opakovanej návštevy, často viac ako päť dní) v porovnaní s aktuálnymi optickými/multispektrálnymi misiami DPZ. Na základe správy o kryosfére, ktorú vydal Global Climate Observing System (GCOS), je minimálna požiadavka z hľadiska temporálneho rozlíšenia pre aplikácie analyzujúce topenie snehu pre následný výskum hydrológie a klímy jeden až päť dní. Súčasné optické/multispektrálne misie sú navrhnuté s kratším, dokonca aj denným časom opakovania (napr. Advanced Very High Resolution Radiometer (AVHRR), Moderate Resolution Imaging Spectroradiometer (MODIS), Sentinel-3A/B). Aj keď temporálne rozlíšenie ešte nie je dostatočné na poskytovanie denných snímok, tak priestorové rozlíšenie aktuálnych misií SAR, ako je Sentinel-1 (5 × 20 m), je viac než dostatočné, vzhľadom na to, že min. požiadavky vyjadrené GCOS sa pohybujú medzi 100 – 500 m.

11.7.2.2. Interaction between SAR signal and snow

Vzhľadom na charakteristiku prieniku SAR signálu sa vlhký a suchý sneh správa odlišne. Prakticky existujú dve rôzne definície suchého a mokrého snehu. Prvá je založená na objemovom obsahu vody (Volume Water Content - VWC), t. j. snehová pokrývka s VWC nad 1 % sa považuje za mokrý sneh, zatiaľ čo sneh pod 1 % VWC sa označuje ako suchý sneh. Druhá definícia, ktorá sa používa častejšie, súvisí s teplotou snehovej pokrývky. Pri teplotách pod 0°C sa predpokladá, že snehová pokrývka zostane suchá, kým nad 0°C sa sneh považuje za mokrý. Pri definícii podľa teploty sa preukázalo, že je vhodnejšia v porovnaní s definíciou podľa VWC, pretože je jednoduchšie získať merania teploty snehu ako hodnoty VWC.

SAR snímky mokrého snehu sa výrazne líšia od snímok suchého snehu. SAR signál môže prenikať do snehovej pokrývky, pričom hĺbka prieniku závisí od vlnovej dĺžky signálu (Obr. 11.52). Napríklad C-pásmo SAR má potenciálnu hĺbku prieniku približne 20 m pri suchom snehu. Keďže veľkosť zŕn snehu sa pohybuje medzi 0.1 a 0.3 mm, tak SAR signál s väčšími vlnovými dĺžkami prechádza cez snehové kryštály takmer bez prekážok, čo v podstate takmer zabraňuje akémukoľvek druhu spätného rozptylu od snehových kryštálov. Keď sa snehová pokrývka začne topiť tak sa dielektrické vlastnosti snehovej pokrývky značne zmenia, pričom sa hĺbka prieniku zníži na približne 3 cm, pričom dominantným procesom sa stáva spätný rozptyl ako pri vode. Keď sa začína topenie snehu, tak sa pomery vzduchu, ľadu a vody v snehovej pokrývke menia, v dôsledku čoho sa mení aj kumulatívna dielektrická konštanta, čo veďie z pôvodne nízkych hodnôt dielektrickej konštanty pre vzduch, ľad a vodu, k oveľa vyšším hodnotám.



Obr. 11.52 Spätný rozptyl SAR signálu v C-pásme pre suchý a mokrý sneh. **Fig. 11.52** Backscatter of SAR signal in C-band for dry and wet snow. Source: Marin et al., 2020

Obsah kvapalnej vody v snehovej pokrývke navyše ovplyvňuje aj mechanizmus rozptylu, t.j. ako viacvrstvová snehová pokrývka odráža dopadajúci SAR signál. Pri suchej snehovej pokrývke je dominantný súčet objemového rozptylu snehovej pokrývky a povrchového rozptylu na rozhraní sneh/zem. Keď má snehová pokrývka vyššiu vlhkosť, tak v mechanizme spätného rozptylu dominuje povrchový rozptyl na rozhraní vzduch/sneh (Obr. 11.53).



Obr. 11.53 Mechanizmus spätného rozptylu SAR signálu pre suchý a mokrý sneh. **Fig. 11.53** SAR signal backscatter mechanism for dry and wet snow. Source: Park et al., 2021

Snehová pokrývka je však komplexnou viacvrstvovou štruktúrou, preto môže byť spätný rozptyl SAR signálu ovplyvnený aj veľkosťou zŕn snehu, hustotou, hĺbkou, stratigrafiou, množstvom nečistôt a drsnosťou povrchu. Povrchový a objemový rozptyl je úmerný amplitúde polarizácie a priepustnosti snehovej pokrývky. Priepustnosť je tiež ovplyvnená dielektrickou konštantou a lokálnym uhlom dopadu. Prehľad vplyvu každého faktora na rozptyl pre suchý a mokrý sneh, ako aj charakteristiku spätného rozptylu, je uvedený v Tab. 11.1. Dôležité tiež je, že mechanizmy rozptylu ovplyvňujú mnohé faktory, ako napríklad vlnová dĺžka SAR signálu, polarizácia, uhol dopadu, drsnosť povrchu a dielektrické vlastnosti. Väčšie vlnové dĺžky spôsobia väčší objemový rozptyl v dôsledku hlbšieho prieniku.

Tab. 11.1 Vplyv mokrého a suchého snehu na SAR signál na základe fyziológie snehu. "+" sa vzťahuje na pozitívnu koreláciu; "-" sa vzťahuje na negatívnu koreláciu.

Tab. 11.1 Effect of wet and dry snow on SAR signal based on snow physiology. "+" refers to positive correlation; "-" refers to negative correlation.

Source: Tsai et al., 2019a

Snow type	Dry snow	Wet snow		
Zdroj spätného rozptylu	Objemový rozptyl od snehovej pokrývky, Povrchový rozptyl na rozhraní sneh/zem	Povrchový rozptyl na rozhraní vzduch/sneh		
Dominantné faktory ovplyvňujúce mechanizmus rozptylu	Povrch pod snehom (frekvencia SAR <~10 GHz), Veľkosť zrna (frekvencia SAR > ~10 GHz)	Obsah tekutej vody (najdôležitejšie), Drsnosť povrchu		
Koeficient spätného rozptylu	Vysoký	Nízky		
Vzťah medzi parametrami snehovej pokrývky a amplitúdou spätného rozptylu				
Vlhkosť snehu	-	+		
Zrnitosť snehu	+	bezvýznamné		
	+			
Hĺbka/hrúbka snehu	+ hrubozrnná snehová pokrývka	-		



Z hľadiska jednotlivých pásiem SAR senzorov vyniká najdlhším dostupným časovým radom kontinuálnych pozorovaní C-pásmo, najmä vďaka misiám ERS-1/2, Envisat, Radarsat-1/2, a nakoniec Sentinel-1. Súvislá časová séria SAR snímok v C-pásme teda existuje už viac ako 20 rokov, čím sa tento časový rad stal najčastejšie používaným súborom údajov na analýzu snehovej pokrývky zo SAR údajov. Navyše, charakteristika C-pásma je vhodná na detekciu snehu, pričom každé C-pásmo jednotlivých senzorov je navzájom zameniteľné a je teda možné tieto dáta kombinovať.

Čo sa týka ostatných pásiem, tak v dôsledku väčšej vlnovej dĺžky L-pásma a následne hlbšieho prenikania signálu do snehovej pokrývky zostáva snehová pokrývka v údajoch z L-pásma prakticky neviditeľná. SAR dáta v X-pásme sa využívajú častejšie ako L-pásmo, čo je spôsobené vyššou citlivosťou signálu v X-pásme na snehovú pokrývku, dokonca aj v porovnaní s C-pásmom. Nevýhodou oproti C-pásmu je však kratšia časová dostupnosť.

Metódy monitorovania snehovej pokrývky SAR dátami sa dajú rozdeliť do troch základných kategórií (zároveň však platí, že s vývojom SAR senzorov a techník spracovania obrazu sa menia a vyvíjajú aj ciele monitorovania snehovej pokrývky):

1. rozsah mokrej snehovej pokrývky

Najbežnejšie používaným prístupom na odvodenie rozsahu mokrej snehovej pokrývky je využitie koeficientu spätného rozptylu. Ako už bolo uvedené, koeficient spätného rozptylu výrazne klesá, keď sa snehová pokrývka začne topiť, pretože obsahuje tekutú vodu ktorá znižuje dielektrickú konštantu (Obr. 11.54).



Obr. 11.54 Mapa rozsahu topenia snehu nad Alpami, odvodená z údajov Sentinel-1 medzi Aprílom až Júlom 2015.

Fig. 11.54 Map of snowmelt extent over the Alps, derived from Sentinel-1 data between April and July 2015.

Source: Nagler et al., 2016

2. celkový rozsah snehovej pokrývky

Na základe informácií o fáze z dvoch SAR snímok zaznamenaných pre rovnaké miesto, ale v rôznych časových obdobiach, je možné na základe InSAR techniky odhaliť podobnosť povrchových podmienok. Základnou teóriou detekcie celkového rozsahu snehovej pokrývky na základe InSAR je, že v porovnaní som zasneženými oblasťami si môže oblasť bez snehu zachovať vysokú koherenciu medzi oboma časmi pozorovania. Dôvodom dekorelácie medzi pozorovaniami so snehovou pokrývkou (pre suchý aj mokrý sneh) je zmena hĺbky prieniku SAR signálu a mechanizmu rozptylu. Na rozdiel od prístupu založeného na spätnom rozptyle, ktorý dokáže detegovať iba rozsah mokrého snehu, InSAR prístup dokáže detegovať mokrý aj suchý sneh (Obr. 11.55).



Obr. 11.55 Mapa celkového rozsahu snehovej pokrývky pre celé Alpy medzi marcom až aprílom 2018, odvodená z údajov Sentinel-1, topografických vlastností, vegetačných indexov, a informácií o teplote.

Fig. 11.55 Map of the total snow cover extent for the whole Alps between March and April 2018, derived from Sentinel-1 data, topographic features, vegetation indices, and temperature information.

Source: Tsai et al., 2019b

3. rozsah mokrej a suchej snehovej pokrývky

Kým ešte neboli techniky polarimetrického SAR (PolSAR) dostatočne rozvinuté, predpokladalo sa, že SAR nedokáže detegovať suchý sneh. Keďže detekcia suchého snehu je dôležitá pre aplikácie ako je odhad SWE (ekvivalentu vody v snehu) a iné hydrologické aplikácie, tak sa na predpovedanie rozsahu suchého snehu na základe rozsahu mokrého snehu používali rôzne empirické a topografické pravidlá. Tieto metódy sa však ukázali ako nepresné. V dôsledku toho sa preskúmal alternatívny prístup – technika PolSAR, na detekciu rozsahu mokrej a suchej snehovej pokrývky priamo zo snímok SAR. Základom tejto techniky je extrahovať charakteristiky geometrického rozptylu pozemných prvkov rozkladom prijatého SAR signálu. Spätný rozptyl z každého pozemného prvku sa skladá z rôznych jedinečných interakcií signál – prvok. Dekompozícia PolSAR preto ponúka možnosť odhaliť, ako konkrétny povrchový prvok odráža dopadajúci SAR signál a aké fyzikálne vlastnosti tento prvok môže mať. Napríklad zamrznuté koruny stromov v lese vedú k vysokej korelácii polarizácie v dôsledku povrchového spätného rozptylu, zatiaľ čo nízka korelácia vyplýva zo zasneženého povrchu zeme. Akonáhle sneh zvlhne, tak polarizácia opäť koreluje.

Tab. 11.2 Celkové porovnanie troch hlavných prístupov detekcie snehovej pokrývky zo SAR dát. **Tab. 11.2** Overall comparison of the three main approaches for snow cover detection from SAR data.

Source: Tsai et al., 2019a

Detection method	Backscatter	InSAR	PolSAR	
Základná teória	Koeficient spätného rozptylu sa znižuje, keď je sneh mokrý	Strata koherencie na zasneženom povrchu	Mechanizmy rozptylu suchého a mokrého snehu a povrchu sa správajú odlišne	
Minimálny počet SAR snímok	2	2	1	
Požiadavky na SAR snímky	ožiadavky na SAR Snímky s rovnakou snímky geometriou		Snímky s duálnou alebo 4-násobnou polarizáciou	
Zložitosť algoritmov	Nízka	Stredná	Vysoká	
Primárne analyzovaný komponent	Koeficient spätného rozptylu	Koherencia	Polarimetrické parametre	
Závislosť od lokálneho uhla dopadu	Vysoká	Stredná	Nízka	
Množstvo získaných informácií	Stredné	Nízke	Vysoké	
Šum v získaných informáciách	Vysoký	Nízky	Stredný	
Schopnosť zachytenia typu snehu				
Mokrý sneh	Áno	Nie	Áno	
Suchý sneh	Nie	Nie	Áno	
Sneh celkom	Nie	Áno	Áno	

11.7.3. Ice movement monitoring with RS

S pokračujúcou a zrýchľujúcou sa globálnou zmenou klímy sa výskum kryosféry ukázal ako jedna z kľúčových disciplín v štúdiách klimatických zmien. Zložky kryosféry (Obr. 11.44 Zložky kryosféry a ich časové rozpätie) sú vzhľadom na ich vysokú citlivosť aj na malé meteorologické zmeny považované za prirodzené indikátory klimatických zmien. Od konca 19. storočia sa priemerná kombinovaná teplota povrchu zeme a oceánu zvýšila o ~0,85 °C. V dôsledku toho sa rozsah arktického morského ľadu zmenšoval o 3,5 – 4,1 % za desaťročie, rozsah a hmotnosť takmer všetkých ľadovcov a ľadových štítov sa zmenšovali stále rastúcim tempom a priemerná globálna hladina morí vzrástla o približne 0,2 m. Meniaca sa kryosféra môže ešte ovplyvniť celé fyzické, biologické a socioekonomické prostredie. Jedným z najnebezpečnejších dôsledkov sú topiace sa ľadové masy, ktoré – popri tepelnej expanzii oceánskej vody – značne zvyšujú globálnu priemernú hladinu mora a ohrozujú nízko položené pobrežné populácie a ekosystémy vo všetkých priestorových mierkach.

Antarktický ľadový štít (Antartic Ice Sheet - AIS) sám o sebe obsahuje ~ 91 % globálnej ľadovej masy alebo ~ 57 m ekvivalentu hladiny mora, čo z neho robí najväčšieho potenciálneho prispievateľa ku globálnemu vzostupu hladiny mora. Na Obr. 11.56 sú znázornené hlavné mechanizmy ovplyvňujúce dynamiku pohybu ľadu na ľadovci v Antarktíde končiacom v oceáne, so schematicky znázorneným stúpaním cirkumpolárnych hlbokých vôd (CDW) a atmosférickým otepľovaním.



Obr. 11.56 Zobrazenie hlavných procesov pôsobiacich na ľadovec s ľadovým šelfom v Antarktíde. **Fig. 11.56** Representation of the main processes acting on the Antarctic ice shelf. Source: Dirscherl et al., 2020

Napriek lepšiemu pochopeniu hromadných zmien na Antarktický ľadový štít zostáva nejasné, do akej miery budú masové straty v budúcnosti pokračovať. Okrem toho nie sú dostatočne známe hnacie sily, ktoré spôsobujú dynamiku hmoty v AIS. Meranie rýchlosti ľadu má zásadný význam pri určovaní rýchlosti transportu ľadu z vnútra ľadovej pokrývky na jej okraj, pri analýze priestorového a časového vzoru dynamiky toku ľadu alebo pri skúmaní hnacích síl za zmenou toku ľadu.

Historické merania rýchlosti ľadu sa uskutočňovali pomocou pozemných zariadení, ako sú elektronické zariadenia na meranie vzdialenosti, teodolity alebo GNSS prijímače. Vzhľadom na obrovskú veľkosť AIS sú však bodové merania nereprezentatívne a časovo náročné. Vývoj technológií v DPZ spôsobil revolúciu v glaciológii a schopnosti monitorovať dynamiku ľadu pri bezprecedentnom priestorovom pokrytí. Zatiaľ čo prvé mapy rýchlosti ľadu na základe údajov DPZ boli vytvorené z optických snímok Landsat koncom osemdesiatych rokov, obmedzili sa na analýzy miestnej a regionálnej mierky a viditeľnosť povrchových prvkov počas denných akvizícií bez oblačnosti. So spustením radarových misií ako ERS-1/-2, resp. RADARSAT-1 v 90. rokoch technológia SAR vyvinula ako hlavná technika na monitorovanie pohybu ľadu. Schopnosť prevádzky SAR vo dne i v noci a nezávisle od meteorologických podmienok umožnila vynikajúce priestorové pokrytie a nepretržité celoročné monitorovanie Antarktídy. Stále sa zvyšujúce rádiometrické rozlíšenie senzora Landsat 8 umožnilo vygenerovať prvú jednosenzorovú ročnú cirkumantarktickú rýchlostnú mapu s plným pokrytím z 1 senzora.

Obr. 11.57 znázorňuje súčasný potenciál DPZ na monitorovanie dynamiky ľadu na výstupnom ľadovci končiacom v oceáne. Okrem možnosti merania zmien výšky alebo dynamiky odtrhujúceho sa čela ľadovca a pozemnej čiary počas potenciálneho ústupu ľadovca, umožňujú SAR dáta, LiDAR a optické údaje DPZ aj monitorovanie topenia povrchu, predfrontálnych podmienok morského ľadu a ľadovca alebo rýchlosti ľadu.



Obr. 11.57 Potenciál DPZ pre monitorovanie dynamiky ľadu na ľadovci s ľadovým šelfom v Antarktíde.

Fig. 11.57 The potential of remote sensing for monitoring ice dynamics on the Antarctic ice shelf. Source: Dirscherl et al., 2020

11.7.3.1. Optical RS

Všeobecná koncepcia merania rýchlosti povrchu ľadu z optických údajov DPZ je založená na sledovaní trvalých povrchových prvkov ľadovca (napr. trhliny, praskliny, rozsadliny) (sledovanie prvkov) alebo na krížovej korelácii celých snímkových vzorov (image matching) na po sebe nasledujúcich koregisterovaných satelitných snímkach toho istého miesta. Dnes sa optické merania rýchlosti ľadu zvyčajne vykonávajú pomocou image matching buď v priestorovej alebo vo frekvenčnej oblasti.

Image matching v priestorovej oblasti sa vykonáva pomocou normalizovanej krížovej korelácie (Normalized Cross-Correlation NCC). Táto metóda priamo využíva hodnoty intenzity snímky a porovnáva dve snímky na základe definovania malej snímkovej časti v referenčnej snímke, ktorú vyhľadáva vo väčšej oblasti druhej snímky. Správna zhoda medzi snímkovými časťami je vyjadrená ako vrchol korelačnej funkcie.

Na druhej strane, krížová korelácia obrazu vo frekvenčnej oblasti využíva Rýchle Fourierove transformácie (Fast Fourier Transforms - FFT), vďaka čomu je tento prístup obzvlášť rýchly. Napriek tomu nenormalizuje krížovú koreláciu, a preto je citlivá na meniace sa podmienky osvetlenia. Aby sa metóda stala invariantnou voči osvetleniu, čo je výhodné v prípade snehu a ľadu, môže byť rovnako aplikovaná na "orientačné snímky", t.j. reprezentácie snímok s komplexnými číslami orientácie gradientov intenzity v horizontálnom x a vertikálnom smere y; alebo sa môžu zanedbať hodnoty intenzity snímky zohľadnením iba fázových rozdielov vo Fourierovej oblasti.

11.7.3.2. Radar RS

Na odvodenie pohybu ľadu pomocou údajov SAR možno využiť techniky založené na fáze alebo na posune. Medzi metódy založené na fáze patrí diferenciálna interferometria (DInSAR) a interferometria s viacerými apertúrami (MAI), zatiaľ čo metódy založené na posune možno rozdeliť na sledovanie šumu, koherencie a intenzity. DInSAR a MAI sú založené na opakovanom interferometrickom SAR (InSAR) a využívajú fázový rozdiel medzi dvoma komplexnými snímkami SAR získanými v mierne odlišných uhloch a v odlišnom čase. Diferenciálny fázový člen vo všeobecnosti obsahuje topografickú zložku a zložku posunu. Na získanie posunov povrchu pomocou DInSAR je potrebné odstrániť topografický fázový člen. To je možné urobiť pomocou externého digitálneho výškového modelu DEM, alebo odvodením posunov povrchu a topografie pomocou dvoch párov InSAR snímok súčasne. Použitie jedného interferogramu poskytuje informácie o posune povrchu iba v smere priamej viditeľnosti radaru. Na určenie celkového vektora rýchlosti pohybu povrchu sú potrebné aspoň dva interferogramy z pretínajúcich sa orbít. Namiesto toho MAI využíva spracovanie splitbeam InSAR na vytvorenie interferogramov orientovaných "dopredu" a "dozadu". Porovnanie fázového rozdielu medzi interferogramami potom umožňuje odvodiť posun v smere azimutu.

Ak nie sú k dispozícii presné informácie o nadmorskej výške alebo ak nie je možné zachovať interferometrickú koherenciu, sledovanie SAR posunu je vhodným doplnkom k InSAR. Pri sledovaní SAR posunu umožňuje jeden pár SAR snímok odvodiť posuny povrchu v priečnom smere aj v smere azimutu. Pri sledovaní intenzity SAR sa priestorový posun meria krížovou koreláciou odlišných povrchových znakov (napr. trhlín) v časovej postupnosti snímok amplitúd signálu. Na druhej strane, sledovanie zrnitého šumu nevyžaduje viditeľnosť trvalých povrchových prvkov a plne sa spolieha na krížovú koreláciu koherentného zrnitého vzoru buď v údajoch detegovanej amplitúdy, alebo v komplexných obrazových údajoch. A nakoniec, sledovanie koherencie je založené na predpoklade degradácie koherencie v dôsledku chýb koregistrácie nad pohybujúcimi sa ľadovcami. Na odvodenie rýchlosti ľadu pomocou tohto prístupu je potrebné malé snímkové časti nad takýmito oblasťami s nízkou koherenciou previesť na interferogramy a koherenčné mapy a posúvať ich, kým sa nedosiahne maximálna koherencia.

Hlavné charakteristiky, obmedzenia, ako aj výhody a nevýhody optických a SAR techník merania rýchlosti ľadu sú zhrnuté v Tab. 11.3.

Všeobecný trend smeruje k využívaniu kombinácie optických a SAR dát. Viaceré vedecké práce však navrhujú aj kombináciu DINSAR s MAI, resp. sledovaním tvarov, koherencie, zrnitého šumu, intenzity.

Tab. 11.3 Hlavné charakteristiky SAR a optických techník pre monitorovanie ľadu. **Tab. 11.3** Main characteristics of SAR and optical techniques for ice monitoring. Source: Dirscherl et al., 2020

				SAR			Optical
Metóda	Fáza		Posun			Posun	
Technika	DInSAR		MAI	Koherencia	Zrnitý šum	Intenzita	Image matching
Presnosť	Zlomky jednej vlnc (mm-cm)	ovej dĺžky)	Zlomky jednej vlnovej dĺžky (cm)	Zlomky jedného pixelu (cm-m)	Zlomky jedného pixelu (cm-m)	Zlomky jedného pixelu (cm-m)	Zlomky jedného pixelu (cm-m)
Citlivosť na koherenciu	Áno (veľmi vys	soká)	Áno (veľmi vysoká)	Áno (stredná)	Áno (stredná)	Nie	Nie
Potreba dodatočných dát	DEM, Ground Cont	rol Points	DEM, Ground Control Points	DEM, Ground Control Points	DEM, Ground Control Points	DEM, Ground Control Points	DEM, Ground Control Points
Obvyklý interval opakovania	Dni		Dni	Dni – týždne	Dni – týždne	Dni – týždne – mesiace - roky	Dni – týždne – mesiace - roky
Potenciálne oblasti použitia	Pomalý pohyb Oblasti s nízkymi z) ľadu zrážkami	Pomalý pohyb ľadu Oblasti s nízkymi zrážkami	Rýchly pohyb ľadu Oblasti bez tvarov	Rýchly pohyb ľadu Oblasti bez tvarov Oblasti oddelené nesúvislými údajmi	Rýchly pohyb ľadu Okraje Šmykové zóny Plávajúci ľad	Rýchly pohyb ľadu Okraje Šmykové zóny Plávajúci ľad
Zložka pohybu	Priečny smer	3D	Azimut	Priečny smer, azimut	Priečny smer, azimut	Priečny smer, azimut	Priečny smer, azimut
Potrebný počet snímok	1	2+	1	1	1	1	7
Závislosť na osvetlení	Nie		Nie	Nie	Nie	Nie	Áno
Zdroje chýb / obmedzenia	Atmosféra Ionosféra Príliv a odliv Gravitačné prúdenie ľadu Šum v dátach Spracovanie SAR Geometria SAR Rýchly pohyb ľadu Pohyb kolmý na LOS Chyby DEM Objemový rozptyl		Atmosféra Ionosféra Príliv a odliv Gravitačné prúdenie ľadu Šum v dátach Spracovanie SAR Geometria SAR Rýchly pohyb ľadu Pohyb kolmý na azimut Objemový rozptyl	Atmosféra Ionosféra Šum v dátach	Atmosféra Ionosféra Šum v dátach Strmý terén Šmykové zóny Príliv a odliv Potreba korelovaného zrnitého vzoru	Šum v dátach Vysoké rýchlostné gradienty Viditeľnosť a stabilita	Šum v dátach Vysoké rýchlostné gradienty Viditeľnosť a stabilita Svetelné podmienky Svetelné podmienky

11.7.4. Applications of Ice monitoring

11.7.4.1. Measuring the thickness of polar sea ice with the CryoSat mission

Misia ESA CryoSat je zameraná na meranie hrúbky polárneho morského ľadu a monitorovanie zmien v ľadovej pokrývke, ktorá pokrýva Grónsko a Antarktídu (Obr. 11.58).



Obr. 11.58 Hrúbka arktického morského ľadu na základe údajov misie CryoSat. **Fig. 11.58** Arctic Sea ice thickness based on CryoSat data. Source: ©CPOM/UCL/ESA

Zmenšujúca sa ľadová pokrývka sa často spomína ako jedna z prvých obetí globálneho otepľovania. Keďže ľad hrá dôležitú úlohu pri regulácii klímy a hladiny morí, dôsledky zmeny klímy sú ďalekosiahle. Preto je dôležité presne pochopiť, ako ľadové polia Zeme reagujú na tieto zmeny – a do akej miery. Prvou satelitnou misiou v Európe, ktorá sa začala monitorovať túto problematiku, je CryoSat.

CryoSat bol prvou misiou Earth Explorer, ale pôvodná družica bola stratená v dôsledku zlyhania štartu v Októbri 2005. Následne bola postavená nová družica - označovaná aj ako CryoSat-2 - s viacerými vylepšeniami, ktorá bola vypustená 8. Apríla 2010.

Hlavným prístrojom na satelite je Synthetic Aperture Interferometric Radar Altimeter (SIRAL). Predchádzajúce radarové výškomery boli optimalizované pre operácie nad oceánom a pevninou, ale SIRAL je prvý senzor svojho druhu navrhnutý pre ľad, ktorý meria zmeny na okrajoch rozsiahlych ľadových štítov a plávajúceho ľadu v polárnych oceánoch.

Detailné dáta získané misiou CryoSat boli použité aj na vytvorenie mapy hrúbky morského ľadu. Vďaka údajom z Januára a Februára 2011 je možné vidieť hrúbku ľadu v blízkosti severného pólu.

Radarový výškomer dokáže nielen odhaliť drobné odchýlky vo výške ľadu, ale dokáže merať aj hladinu mora s vysokou presnosťou. Zároveň dokáže odhaliť a analyzovať aj malé, lokálne javy na povrchu oceánu. Výškové údaje získané z CryoSat majú potenciál mapovať morskú hladiny bližšie k pobrežiu a ešte lepšie možnosti na profilovanie povrchu pevniny a vnútrozemských vodných objektov, ako sú malé jazerá, rieky a ich prítoky.

11.7.4.2. Melting of glaciers

Radarové snímky Sentinel-1A zachytili ľadovec Jakobshavn v západnom Grónsku pred a po zrútení časti ľadovca vplyvom topenia, čo sa udialo medzi 14. a 16. Augustom 2015. RGB kompozit vo falošných farbách (27. Júla, 13. Augusta, 19. Augusta) farebne zobrazuje rôznu polohu čela ľadovca v príslušných dátumoch (Obr. 11.59).



Obr. 11.59 Odtrhnutie čela ľadovca Jakobshavn zachytené na snímkach Sentinel-1. **Fig. 11.59** Calving front of the Jakobshavn glacier as captured by Sentinel-1 images. Source: ©Copernicus Sentinel data (2015)/ESA

Pri porovnaní snímok urobených 27. Júla a 13. a 19. Augusta bolo nové čelo ľadovca posunuté o niekoľko kilometrov do vnútrozemia na miesto, ktoré sa zdá byť jeho najvýchodnejšou polohou od začiatku monitorovania v polovici 80. rokov 19. storočia.

Časový rad snímok naznačuje, že medzi 27. Júlom a 13. Augustom ľadovec postupoval na západ, kým topenie spôsobilo rýchly ústup čela ľadovca na jeho polohu 19. Augusta.

Odhaduje sa, že ľadovec stratil celkovú plochu 12,5 km². Za predpokladu, že ľad je hlboký asi 1400 m, to zodpovedá objemu 17,5 km kubických, čo by mohlo pokryť celý ostrov Manhattan vrstvou ľadu s hrúbkou asi 300 m.

História tohto odtrhnutia je zachytená aj na snímkach Sentinel-2A z 6. a 16. Augusta (Obr. 11.60). L'adovec Jakobshavn odčerpáva 6,5 % grónskeho ľadového príkrovu, čím vytvára približne 10 % jeho ľadovcov. To predstavuje približne 35 miliárd ton ľadu, ktoré sa každoročne odtrhnú.



Obr. 11.60 Odtrhnutie čela ľadovca Jakobshavn zachytené na snímkach Sentinel-2A. **Fig. 11.60** Calving front of the Jakobshavn glacier as captured by Sentinel-2A images. Source: ©Copernicus Sentinel data (2015)/ESA

L'adovce sú často také veľké, že nie je možné aby odplávali. Zostávajú, niekedy celé roky, prilepené na dne v plytších oblastiach fjordu, kým sa nakoniec neroztopia natoľko, aby sa rozptýlili, rozbili na kúsky alebo ich vytlačili ľadovce prichádzajúce zozadu. L'adovec Jakobshavn, ktorý sa študuje viac ako 250 rokov, pomohol rozvinúť chápanie dôležitosti ľadových prúdov a ľadovcov pri zmene klímy, glaciológii ľadovcov a ako ovplyvňujú hladinu mora.

11.7.4.3. Monitoring ice thickness in lakes

Ľad v jazerách na severe Aljašky počas zimných mesiacov klesá. Dvadsať rokov satelitných radarových snímok ukazuje, ako zmeny našej klímy ovplyvňujú prostredie vo vysokých zemepisných šírkach.

Zmeny teploty vzduchu a zimné zrážky za posledných päť desaťročí ovplyvnili načasovanie, trvanie a hrúbku ľadovej pokrývky na jazerách v Arktíde. V tejto oblasti majú teplejšie klimatické podmienky za následok tenšiu ľadovú pokrývku na plytkých jazerách a následne menšiu časť jazier zamŕzajúcich počas zimných mesiacov. Tieto zmeny ľadovej pokrývky ovplyvňujú miestnu a regionálnu klímu, dynamiku podzemného permafrostu a dostupnosť vody pre obytné a priemyselné využitie počas zimy. Menia tiež fyzikálne, tepelné a chemické vlastnosti vody, čím ovplyvňujú ekológiu, ktorá je na nich závislá.

Rozsah týchto zmien však doteraz nebol komplexne zdokumentovaný. V štúdii ESA o severnom svahu Aljašky boli režimy zamŕzania plytkých jazier zdokumentované pomocou radarových snímok zo satelitov ERS-1 a -2 (Obr. 11.61). Tento výskum identifikoval 22 % pokles alebo ľadu zamrznutého na dne jazera od roku 1991 do roku 2011. To zodpovedá celkovému stenčeniu ľadu o 21 – 38 cm. Najväčšia zmena bola pozorovaná počas neskorej zimy (apríl – máj) počas 20-ročného obdobia, ktorá sa od roku 1991 do roku 2005 postupne znižovala. Počas posledných šiestich rokov analýzy ľad zaznamenal prudší pokles, pričom najnižšiu hodnotu dosiahol v roku 2011.



Obr. 11.61 Detekcia plávajúceho ľadu (svetlomodrá farba) a pevného ľadu zamrznutého na dne jazera (tmavomodrá farba) v jazerách na severnom svahu Aljašky v roku 2011 pomocou satelitu ESA ERS-2.

Fig. 11.61 Detection of floating ice (light blue) and grounded ice (dark blue) in lakes on Alaska's North Slope in 2011 by ESA's ERS-2 satellite.

Source: ©Planetary Visions / University of Waterloo, Canada / ESA

11.7.4.4. Record global ice loss

Prieskum globálneho úbytku ľadu pomocou satelitných údajov zistil, že rýchlosť miznutia ľadu na celej planéte sa zrýchľuje. Zistenia tiež odhaľujú, že medzi rokmi 1994 a 2017 sa stratilo 28 biliónov ton ľadu – čo zodpovedá ľadovej vrstve s hrúbkou 100 metrov, ktorá pokrýva celé Spojené kráľovstvo.

Na základe údajov zo satelitov ESA ERS, Envisat a CryoSat, ako aj z misií Copernicus Sentinel-1 a Sentinel-2, bolo identifikované, že rýchlosť, ktorou Zem strácala ľad, sa za posledné tri desaťročia výrazne zvýšila, z 0.8 bilióna ton ročne v 90. rokoch na 1.3 bilióna ton ročne do roku 2017. Jeden bilión ton ľadu si možno predstaviť ako kocku ľadu s rozmermi 10x10x10 km, ktorá by bola vyššia ako Mount Everest (Obr. 11.62).



Obr. 11.62 Znázornenie 1 bilióna ton ľadu. **Fig. 11.62** Representation of 1 trillion tonnes of ice. Source: ©Planetary Visions

Ukazuje sa, že celkovo došlo k 65% nárastu miery straty ľadu v priebehu 23-ročného prieskumu. Bolo to spôsobené najmä prudkým nárastom strát z polárnych ľadovcov v Antarktíde a Grónsku. Topenie ľadu z ľadovcových štítov a ľadovcov zvyšuje hladinu morí, zvyšuje riziko záplav v pobrežných komunitách, čo má vážne dôsledky pre spoločnosť, hospodárstvo a životné prostredie. Výskum zahŕňal 215 000 horských ľadovcov rozmiestnených po celej planéte, polárne ľadové štíty v Grónsku a Antarktíde, ľadovcové šelfy plávajúce okolo Antarktídy a morský ľad unášaný v Severnom ľadovom a južnom oceáne.

Nárast úbytku ľadu vyvolal otepľovanie atmosféry a oceánov, ktoré sa od roku 1980 otepľovali o 0,26 °C a 0,12 °C za desaťročie. Počas obdobia prieskumu došlo k strate 7,6 bilióna ton arktického morského ľadu a úbytku 6,5 bilióna ton z antarktických ľadovcových šelfov, ktoré plávajú v polárnych oceánoch. Polovica všetkých strát bola spôsobená ľadom na súši – vrátane 6,1 bilióna ton z horských ľadovcov, 3,8 bilióna ton z grónskeho ľadového príkrovu a 2,5 bilióna ton z antarktického ľadového príkrovu. Tieto straty zvýšili globálnu hladinu morí o 35 milimetrov. Napriek tomu, že ľadovce ukladajú iba 1 % celkového objemu ľadu na Zemi, prispeli k takmer štvrtine globálnych strát ľadu počas skúmaného obdobia, pričom ľad strácajú všetky ľadovcové oblasti na svete (Obr. 11.63).



Obr. 11.63 Globálny úbytok ľadu v rokoch 1994 - 2017. **Fig. 11.63** Global ice lost between 1994–2017. Source: ©CPOM

References

Books

Lillesand, T.M., Kiefer, R.W. and Chipman, J.W. (2015). Remote sensing and image interpretation. Hoboken, N.J.: John Wiley & Sons, Inc. 770p. ISBN 978-1-118-34328-9.

Aalstad, K. (2019). Ensemble-based retrospective analysis of the seasonal snowpack (PhD). Department of Geosciences, Faculty of Mathematics and Natural Sciences, University of Oslo. pp. 1-328.

Baghdadi, N., & Zribi, M. (2016). Land Surface Remote Sensing in Continental Hydrology (Remote Sensing Observations of Continental Surfaces Set, Vol. 1, pp. 1–458). ISTE Press Ltd and Elsevier. ISBN 978-1-78548-104-8.

Lemke, P., Ren, J., Alley, R.B., Allison, I., Carrasco, J., Flato, G., Fujii, Y., Kaser, G., Mote, P., Thomas R.H., and Zhang, T. (2007). Observations: Changes in Snow, Ice and Frozen Ground. In: Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change [Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K.B. Averyt, M. Tignor and H.L. Miller (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.

Refice, A., D'Addabbo, A., & Capolongo, D. (2018). Flood Monitoring through Remote Sensing (Springer Remote Sensing/Photogrammetry, Vol. 1, pp. 1–213). Springer International Publishing AG. ISBN 978-3-319-63958-1.

Petropoulos, G. P., & Islam, T. (2018). Remote sensing of hydrometeorological hazards (Vol. 1, pp. 1–551). Crc Press, Taylor & Francis Group. ISBN 978-1498777582.

Schumann, G. J-P., Bates, P. D., Apel, H., & Aronica, G. T. (2018). Global Flood Hazard Applications in Modeling, Mapping, and Forecasting (Geophysical Monograph Series, pp. 1–254). American Geophysical Union and John Wiley & Sons, Inc. ISBN 978-1-119-21786-2.

Cazenave, A., Champollion, N., Benveniste, J., & Chen, J. (2016). Remote Sensing and Water Resources (Space Sciences Series of ISSI, Vol. 1, pp. 1–336). Springer International Publishing AG. ISBN 978-3-319-32448-7.

Lakshmi, V. (2017). Remote Sensing of Hydrological Extremes (Springer Remote Sensing/Photogrammetry, Vol. 1, pp. 1–255). Springer International Publishing AG. ISBN 978-3-319-43743-9.

Thenkabail, P.S. (2016). Remote sensing handbook. Vol. I-III. Boca Raton, Fl: Crc Press. 858p. ISBN 978-1-4822-1795-7.

Tedesco, M. (2015). Remote sensing of the cryosphere (Vol. 1, pp. 1–430). JohnWiley & Sons, Ltd. ISBN 978-1-118-36885-5.

Papers, manuals, reports

United Nations Institute for Training and Research. (2020). Preliminary Satellite Based Oil Spill Assessment Reef of Pointe d'Esny, Republic of Mauritius. In disasterscharter.org (pp. 1–5). UNITAR. https://disasterscharter.org/documents/10180/6736953/vap-767-1-product.pdf

Chawla, I., Karthikeyan, L., & Mishra, A. K. (2020). A review of remote sensing applications for water security: Quantity, quality, and extremes. Journal of Hydrology, 585, 124826. DOI: 10.1016/j.jhydrol.2020.124826.

Soriano-González, J., Angelats, E., Fernández-Tejedor, M., Diogene, J., & Alcaraz, C. (2019). First Results of Phytoplankton Spatial Dynamics in Two NW-Mediterranean Bays from Chlorophyll-a Estimates Using Sentinel 2: Potential Implications for Aquaculture. Remote Sensing, 11(15), 1756. DOI: 10.3390/rs11151756.

Buma, W. G., & Lee, S.-I. (2020). Evaluation of Sentinel-2 and Landsat 8 Images for Estimating Chlorophyll-a Concentrations in Lake Chad, Africa. Remote Sensing, 12(15), 2437. DOI: 10.3390/rs12152437.

Ansper, A., & Alikas, K. (2018). Retrieval of Chlorophyll a from Sentinel-2 MSI Data for the European Union Water Framework Directive Reporting Purposes. Remote Sensing, 11(1), 64. DOI: 10.3390/rs11010064.

Beck, R., Zhan, S., Liu, H., Tong, S., Yang, B., Xu, M., Ye, Z., Huang, Y., Shu, S., Wu, Q., Wang, S., Berling, K., Murray, A., Emery, E., Reif, M., Harwood, J., Young, J., Nietch, C., Macke, D., & Martin, M. (2016). Comparison of satellite reflectance algorithms for estimating chlorophyll-a in a temperate reservoir using coincident hyperspectral aircraft imagery and dense coincident surface observations. Remote Sensing of Environment, 178, 15–30. DOI: 10.1016/j.rse.2016.03.002.

Pereira-Sandoval, M., Urrego, E. P., Ruiz-Verdú, A., Tenjo, C., Delegido, J., Soria-Perpinyà, X., Vicente, E., & Soria, J. M. (2019). Calibration and validation of algorithms for the estimation of chlorophyll-a concentration and Secchi depth in inland waters with Sentinel-2. Limnetica, 38(1), 471–487. DOI: /10.23818/limn.38.27.

Delegido, J., Urrego, P., Vicente, E., Sòria-Perpinyà, X., Soria, J. M., Pereira-Sandoval, M., Ruiz-Verdú, A., Peña, R., & Moreno, J. (2019). Turbidez y profundidad de disco de Secchi con Sentinel-2 en embalses con diferente estado trófico en la Comunidad Valenciana. Revista de Teledetección, 54, 15. DOI: 10.4995/raet.2019.12603.

Rodrigues, G., Potes, M., Costa, M. J., Novais, M. H., Penha, A. M., Salgado, R., & Morais, M. M. (2020). Temporal and Spatial Variations of Secchi Depth and Diffuse Attenuation Coefficient from Sentinel-2 MSI over a Large Reservoir. Remote Sensing, 12(5), 768. DOI: 10.3390/rs12050768.

Chen, J., Zhu, W., Tian, Y. Q., Yu, Q., Zheng, Y., & Huang, L. (2017). Remote estimation of colored dissolved organic matter and chlorophyll-a in Lake Huron using Sentinel-2 measurements. Journal of Applied Remote Sensing, 11(03), 1. DOI: 10.1117/1.jrs.11.036007.

Kseňak, Ľ., Pukanská, K., Bartoš, K., & Blišťan, P. (2022). Assessment of the Usability of SAR and Optical Satellite Data for Monitoring Spatio-Temporal Changes in Surface Water: Bodrog River Case Study. Water, 14(3), 299. DOI: 10.3390/w14030299.

Amitrano, D., Di Martino, G., Iodice, A., Riccio, D., & Ruello, G. (2018). Unsupervised Rapid Flood Mapping Using Sentinel-1 GRD SAR Images. IEEE Transactions on Geoscience and Remote Sensing, 56(6), 3290–3299. DOI: v10.1109/tgrs.2018.2797536.

Li, Y., Martinis, S., Plank, S., & Ludwig, R. (2018). An automatic change detection approach for rapid flood mapping in Sentinel-1 SAR data. International Journal of Applied Earth Observation and Geoinformation, 73, 123–135. DOI: 10.1016/j.jag.2018.05.023.

Braun, A. (2021). Sentinel-1 Toolbox, Synergetic use of radar and optical data, Combination of Sentinel-1 and Sentinel-2 and application of analysis tools. In step.esa.int (pp. 1–30). SkyWatch Space Applications Inc.

Tavus, B., Kocaman, S., Nefeslioglu, H. A., & Gokceoglu, C. (2020). A Fusion Approach for Flood Mapping Using Sentinel-1 and Sentinel-2 Datasets. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLIII-B3-2020, 641–648. DOI: 10.5194/isprs-archives-XLIII-B3-2020-641-2020.

Kuntla, S. K. (2021). An era of Sentinels in flood management: Potential of Sentinel-1, -2, and -3 satellites for effective flood management. Open Geosciences, 13(1), 1616–1642. DOI: 10.1515/geo-2020-0325.

Wieland, M., & Martinis, S. (2020). Large-scale surface water change observed by Sentinel-2 during the 2018 drought in Germany. International Journal of Remote Sensing, 41(12), 4742–4756. DOI: 10.1080/01431161.2020.1723817.

Hu, X., Ren, H., Tansey, K., Zheng, Y., Ghent, D., Liu, X., & Yan, L. (2019). Agricultural drought monitoring using European Space Agency Sentinel 3A land surface temperature and normalized difference vegetation index imageries. Agricultural and Forest Meteorology, 279, 107707. DOI: 10.1016/j.agrformet.2019.107707.

Selj, G. K., & Mikkelsen, A. (2021). Spectral reflectance measurements of snow and snow covered objects: Experimental studies compared with mathematical models. 11865. DOI: 10.1117/12.2597953.

Louis, J., & L2A Team. (2021). S2 MPC Level-2A Algorithm Theoretical Basis Document (pp. 1–78). European Space Agency.

Mary, A., Dumont, M., Dedieu, J.-P. ., Durand, Y., Sirguey, P., Milhem, H., Mestre, O., Negi, H. S., Kokhanovsky, A. A., Lafaysse, M., & Morin, S. (2013). Intercomparison of retrieval algorithms for the specific surface area of snow from near-infrared satellite data in mountainous terrain, and comparison with the output of a semidistributed snowpack model. The Cryosphere, 7(2), 741–761. DOI: 10.5194/tc-7-741-2013.

Tsai, Y.-L. S., Dietz, A., Oppelt, N., & Kuenzer, C. (2019a). Remote Sensing of Snow Cover Using Spaceborne SAR: A Review. Remote Sensing, 11(12), 1456. DOI: 10.3390/rs11121456.

Nagler, T., Rott, H., Ripper, E., Bippus, G., & Hetzenecker, M. (2016). Advancements for Snowmelt Monitoring by Means of Sentinel-1 SAR. Remote Sensing, 8(4), 348. DOI: 10.3390/rs8040348.

Tsai, Y.-L. S., Dietz, A., Oppelt, N., & Kuenzer, C. (2019b). A Combination of PROBA-V/MODIS-based Products with Sentinel-1 SAR Data for Detecting Wet and Dry Snow Cover in Mountainous Areas. Remote Sensing, 11(16), 1904. DOI: 10.3390/rs11161904.

Schwaizer, G. (2018). SAR / Optical Applications to Ice and Snow. Presentation, ESA ECS Training Course on Earth Observation, Bratislava, Slovakia. 171p.

Dirscherl, M., Dietz, A. J., Dech, S., & Kuenzer, C. (2020). Remote sensing of ice motion in Antarctica – A review. Remote Sensing of Environment, 237, 111595. DOI: 10.1016/j.rse.2019.111595.

Hu, S., Qin, J., Ren, J., Zhao, H., Ren, J., & Hong, H. (2020). Automatic Extraction of Water Inundation Areas Using Sentinel-1 Data for Large Plain Areas. Remote Sensing, 12(2), 243. DOI: 10.3390/rs12020243.

De Groeve, T. (2010). Flood monitoring and mapping using passive microwave remote sensing in Namibia. Geomatics, Natural Hazards and Risk, 1(1), 19–35. DOI: 10.1080/19475701003648085.

Notti, D., Giordan, D., Caló, F., Pepe, A., Zucca, F., & Galve, J. P. (2018). Potential and Limitations of Open Satellite Data for Flood Mapping. Remote Sensing, 10(11), 1673. DOI: 10.3390/rs10111673. Wu, T., Zheng, W., Yin, W., & Zhang, H. (2020). Spatiotemporal Characteristics of Drought and Driving Factors Based on the GRACE-Derived Total Storage Deficit Index: A Case Study in Southwest China. Remote Sensing, 13(1), 79. DOI: 10.3390/rs13010079.

Marin, C., Bertoldi, G., Premier, V., Callegari, M., Brida, C., Hürkamp, K., Tschiersch, J., Zebisch, M., & Notarnicola, C. (2020). Use of Sentinel-1 radar observations to evaluate snowmelt dynamics in alpine regions. The Cryosphere, 14(3), 935–956. DOI: 10.5194/tc-14-935-2020.

Park, J., Forman, B. A., & Lievens, H. (2021). Prediction of Active Microwave Backscatter Over Snow-Covered Terrain Across Western Colorado Using a Land Surface Model and Support Vector Machine Regression. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 14, 2403–2417. DOI: 10.1109/jstars.2021.3053945.

Web sources

www.space4water.org www.esa.int/Applications

www.futurewater.eu

12

Applications of RS -Environment and Natural Disasters

The impact of disasters on the environment has worsened in recent decades. In addition, the number of reported disasters has increased dramatically, as have the costs to the global economy and the number of people affected by disasters. The causes of these disasters are manifold, and the impact can be found in the increasing vulnerability of societies, infrastructure and populations. In addition, extreme weather events have become more common and more severe.

The increasing incidence of natural and artificial disasters is leading to a growing demand for actual geographical information, in particular timely material on rapidly evolving events. This includes comprehensive, near real-time RS data that offer independent coverage of wide areas for a wide range of civil emergencies. Optical and radar satellite images serve as an important source of data in the event of a disaster. RS can provide data on various areas of disaster management, ranging from risk modelling and vulnerability analysis to early warning and damage assessment.

Optical RS data is very important for disaster management support as it can be used for almost all types of disasters and for all phases of disaster management. Thermal imagery offers excellent opportunities for automated extraction of anomalously high temperatures or hot spots caused by wildfires or information on volcanic eruptions. SAR systems can be used for flood mapping or measuring ground deformation before and during earthquakes or volcanic eruptions, especially if post-event imagery can be analysed together with archived reference imagery for change detection or interferometric coherence or displacement measurements.

This chapter is devoted to the general knowledge of natural disasters, their impact on the environment, and how they can be monitored using RS. A large part of the chapter is devoted to monitoring earthquakes, volcanic activity, and landslides.

· e esa

FBERG

12.2. Introduction

Vplyv živelných pohrôm na životné prostredie sa v posledných desaťročiach zhoršil. Okrem toho sa dramaticky zvýšil počet hlásených pohrôm, ako aj náklady pre globálnu ekonomiku, a počet pohromami postihnutých ľudí. Príčiny týchto pohrôm sú rozmanité a vplyv možno nájsť v rastúcej zraniteľnosti spoločností, infraštruktúry a obyvateľstva. Okrem toho sa stali bežnejšími a závažnejšími extrémne prejavy počasia. Na Obr. 12.1 sú znázornené škody spôsobené živelnými pohromami v roku 2021.



Obr. 12.1 Globálne škody spôsobené živelnými pohromami v roku 2021. **Fig. 12.1** Global damage caused by natural disasters in 2021. Source: Munich Re, NatCatSERVICE, 2022

Mapový prehliadač portálu Národného Úradu pre Oceán a Atmosféru (NOAA) a jeho Národných Centier pre Informácie o Životnom prostredí (NCEI) – ncei.noaa.gov/maps/hazards/ (Obr. 12.2) spracováva a archivuje údaje o cunami, zemetraseniach a sopkách na podporu výskumu, plánovania, reakcie a zmierňovania ich dopadov. Dlhodobé údaje, vrátane fotografií, je možné použiť na stanovenie histórie prírodných rizík a pomôcť pri zmierňovaní budúcich udalostí.

Rastúci výskyt prírodných a človekom spôsobených pohrôm vedie k rastúcemu dopytu po aktuálnych geografických informáciách, najmä včasných materiáloch o rýchlo sa vyvíjajúcich udalostiach. To zahŕňa komplexné údaje z DPZ takmer v reálnom čase, ktoré ponúkajú nezávislé pokrytie širokých oblastí pre široké spektrum civilných krízových situácií. Satelitné snímky môžu slúžiť ako zdroj informácií v prípade pohromy. V súlade s tým môže DPZ poskytnúť informácie o rôznych oblastiach manažmentu pohrôm, od modelovania rizík a analýzy zraniteľnosti až po včasné varovanie a hodnotenie škôd.

12 Applications of RS – Environment and Natural Disasters



Obr. 12.2 Mapový prehliadač výskytu prírodných rizík v minulosti až po súčasnosť. **Fig. 12.2** Natural hazards map viewer from the past to the present. Source: ncei.noaa.gov/maps/hazards

12.2.1. Types of disasters and their impact on the environment

Existuje niekoľko spôsobov klasifikácie typov pohrôm. Jednou zo spoločných klasifikácií sú živelné pohromy a pohromy spôsobené ľudskou činnosťou. Závažné geofyzikálne alebo klimatické udalosti, ako sú sopečné erupcie, záplavy, cyklóny a požiare, ktoré ohrozujú ľudí alebo majetok, sa nazývajú živelné pohromy. Pohromy spôsobené človekom sú udalosti, ktoré sú spôsobené ľudskou činnosťou (napríklad priemyselné chemické havárie a úniky ropy). Živelné pohromy, ktoré sú urýchlené ľudským vplyvom, sa niekedy nazývajú pohromy spôsobené ľudskou činnosťou. Okrem toho Centrum pre výskum epidemiológie katastrof (Centre for Research on the Epidemiology of Disasters - CRED) rozdeľuje kategóriu živelných pohrôm do šiestich podskupín, ktoré zase zahŕňajú 17 typov pohrôm a 33 podtypov (pozri Tab. 12.1). Kategória technologických pohrôm je rozdelená do troch podskupín, ktoré zase zahŕňajú 15 typov pohrôm (pozri Tab. 12.2). Okrem toho môžu byť pohromy kategorizované ako náhle (napr. zemetrasenie) alebo pomalé (napr. sucho) na základe ich začiatku.

Tab. 12.1 Klasifikácia živelných pohrôm.

Tab. 12.1 Classification of natural disasters.

Source: emdat.be/classification

Podskupiny živelných pohrôm					
Klimatické	Geofyzikálne	Hydrologické	Meteorologické	Biologické	Mimo-Zemské
Nebezpečenstvo spôsobené dlhodobými atmosférickými procesmi na strednej - až makroúrovni, ktoré sa pohybujú od sezónnej až po viacdekádovú premenlivosť klímy.	Nebezpečenstvo pochádzajúce z pevnej zeme. Tento pojem sa niekedy zamieňa s pojmom geologické nebezpečenstvo.	Nebezpečenstvo spôsobené výskytom, pohybom a distribúciou povrchovej a podpovrchovej sladkej a slanej vody.	Nebezpečenstvo spôsobené krátkodobými extrémnymi poveternostnými a atmosférickými podmienkami na mikro- až strednej úrovni, ktoré trvajú od niekoľkých minút do niekoľkých dní.	Nebezpečenstvo spôsobené vystavením živým organizmom a ich toxickým látkam (napr. jed, pleseň) alebo chorobám prenášaným rôznymi nosičmi.	Nebezpečenstvo spôsobené asteroidmi, meteoroidmi a kométami, ktoré prelietajú blízko Zeme, vstupujú do zemskej atmosféry a/alebo narážajú do Zeme, a zmenami medziplanetárnych podmienok.
Typy a podtypy živelných živelných pohrôm					
Sucho	Zemetrasenie	Povodeň	Búrka	Nehody zvierat	Náraz/Ráz
Náhle vyprázdnenie ľadovcového jazera	Otrasy zeme	Pobrežná povodeň	Extra-tropický cyklón	Invázia hmyzu	Výbuch vzduchu
Ničivý požiar	Cunami	Riečna povodeň	Tropický cyklón	Kobylky	Vesmírne počasie
Lesný požiar	Pohyb materiálu	Blesková povodeň	Konvekčná búrka	Saranče	Energetické častice
Požiar v krajine	Vulkanická činnosť	Povodeň v dôsledku ľadových zátarás	Extrémne teploty	Epidémia	Geomagnetická búrka
	Spad vulkanického popola	Zosuv pôdy	Studená vlna	Vírusové ochorenie	Rázová vlna
	Vulkanický bahenný prúd	Lavína (snehová, sutinová, bahenná, skalná)	Vlna horúčav	Bakteriálne ochorenie	
	Pyroklastický prúd	Pôsobenie vĺn	Ťažké zimné podmienky	Parazitické ochorenie	
	Lávový prúd	Extrémne vlny	Hmla	Plesňové ochorenie	
		Stojaté vlny		Priónové ochorenie	

Tab. 12.2 Klasifikácia technologických pohrôm. **Tab. 12.2** Classification of technological disasters. Source: emdat.be/classification

Podskupiny technologických pohrôm					
Priemyselné nehody	Dopravné nehody	Ostatné nehody			
-	Typy technologických pohrôm	า			
Únik chemikálií	Vzduch	Kolaps			
Kolaps	Cesta	Výbuch			
Výbuch	Železničná doprava	Požiar			
Požiar	Voda	Iné			
Únik plynu					
Otrava					
Radiačné žiarenie					
Únik ropy					

Pohromy, či už prírodné, alebo spôsobené ľudskou činnosťou, majú mnoho vplyvov. Dopady pohrôm majú napríklad ľudský a environmentálny rozmer. Program Spojených národov pre životné prostredie dospel k záveru, že environmentálne podmienky môžu zhoršiť vplyv pohrôm a naopak, katastrofy majú tendenciu mať vplyv na životné prostredie. Kniha The Impacts of Natural Disasters: A Framework for Loss Estimation (1999) podrobne rozoberá environmentálne vplyvy rôznych typov pohrôm. Upozorňujú na zaujímavý fakt, že zatiaľ čo väčšina environmentálnych vplyvov je negatívna, niektoré sú pozitívne. Napríklad povodne môžu pomôcť omladiť vegetáciu záplavových oblastí a sú dôležitými hybnými silami mnohých ekologických procesov v záplavových oblastiach. V Tab. 12.3 je uvedený výber environmentálnych vplyvov pre rôzne typy pohrôm.

Vplyv katastrof možno znížiť prostredníctvom správneho riadenia pohrôm. Proces riadenia pohrôm sa často interpretuje ako cyklus pozostávajúci zo štyroch hlavných fáz:

- 1. **zmierňovanie** (mitigation) minimalizácia následkov pohromy (napr. stavebné predpisy, analýzy zraniteľnosti),
- 2. **pripravenosť** (preparedness) plánovanie reakcie (napr. plány pripravenosti, varovné systémy),
- 3. **reakcia** (response) úsilie o minimalizáciu nebezpečenstiev spôsobených pohromou (napr. pátracie a záchranné akcie, pomoc pri mimoriadnych udalostiach),
- 4. **obnova** (recovery) návrat k normálnemu stavu (napr. obnova, prestavba, rekultivácia).

Tab. 12.3 Pohromy a ich vplyvy na životné prostredie. **Tab. 12.3** Disasters and their environmental impacts.

Source: Gähler, 2016

	ké	Sucho	Sucho vo všeobecnosti poškodzuje ekologické systémy: vyčerpanie vodných zdrojov, strata rastlín a živočíchov, zhoršenie kvality pôdy, požiare
	Klimatologic	Náhle vyprázdnenie ľadovcového jazera	Záplavy, ničenie rastlín, zosuv pôdy, erózia
		Lesný požiar	Úbytok rastlín a živočíchov, erózia, záplavy, zosuvy bahna, dlhodobý smog
hromy	fyzikálne	Zemetrasenie Pohyb hmoty	Dominantné straty spôsobené zemetraseniami a masovými pohybmi sú na stavbách a potenciálne aj na ľuďoch. Obe katastrofy však môžu mať za následok aj nepriaznivé environmentálne dôsledky: rastlinstvo a živočíšstvo poškodené otrasmi, posuny povrchu pôdy, zmeny v miestnych hydrologických systémoch.
	Geot	Vulkanická činnosť	Úbytok rastlín a živočíchov, znehodnotenie pôdy, znečistenie vzduchu a vody, dlhodobý smog.
Živelné po	logické	Záplavy	Veľké povodne majú rôzne účinky na ekosystémy riek a lužných oblastí: napr. negatívny vplyv na stromy, ak sú príliš dlho ponorené; znečistená voda preniká do záplavových oblastí a kontaminuje zavodnené vrstvy podzemnej vody; pozitívny vplyv ako omladenie lužnej vegetácie.
	ydrol	Zosuvy	Ničenie/úbytok rastlín, erózia, vyčerpávanie vodných zdrojov.
	Ĩ	Pôsobenie vĺn	Upravuje dynamiku pobrežných morských spoločenstiev napr. vplyv na štruktúru biologických spoločenstiev na skalnatých brehoch.
	Meteorologické	Búrky	Dominantné straty spôsobené búrkami sú na štruktúrach a potenciálne aj na ľuďoch. Vplyvy na životné prostredie sú: napr. zničenie rastlín, lesný požiar, blesková povodeň.
		Extrémne teploty	Lavína, topenie snehu, strata rastlín a živočíchov, bleskové povodne, záplavy, sucho, erózia, požiar.
		Hmla	Strata života rastlín a živočíchov, zníženie UV žiarenia, poškodenie zdravia ľudí, zvierat a vegetácie.
	ě	Únik chemikálií	Existuje niekoľko vplyvov na životné prostredie v závislosti od podrobného podtypu a rozmeru pohromy. Niektoré všeobecné vplyvy sú napríklad:
>	selr	Kolaps	Negatívne zdravotné dôsledky náhodného uvoľnenia toxínov,
Ê	Ę	Výbuch	strata rastlin a zvierat,
ř	Prie	Poziar Únik plypu	znecistenie vody/pody/vzducnu, škody pa zdraví ľudí zvierat a vegetácie
ő	_	Ofrava	ničenie rastlín.
ké.		Vzduch	erózia,
gic	'né	Cesta	záplavy,
0	Doprav	Železničná	hmla,
chne		doprava Voda	atď.
Te	, O	Kolans	
	atn	Výbuch	
	Ost	Požiar	

12.2.2. RS methods for disaster management

Dáta z optického DPZ sú veľmi dôležité pre podporu manažmentu pohrôm, pretože ich možno použiť takmer pre všetky typy pohrôm a pre všetky fázy manažmentu pohrôm. Používajú sa napríklad na plánovanie logistiky záchranných akcií v teréne bezprostredne po zemetrasení alebo cunami. Optické snímky sú ľahko pochopiteľné a interpretovateľné aj pre nešpecialistov, najmä ak sú interpretované ako RGB snímky v pravých farbách. Interpretácia RGB kompozitov vo falošných farbách však nie je intuitívna a vyžaduje odborné znalosti. Pre výber najvhodnejšieho dátového typu pre potreby konkrétnej katastrofickej situácie je veľmi dôležitá charakteristika senzora. Kľúčovými faktormi sú najmä časové a priestorové rozlíšenie. Napríklad na mapovanie zemetrasenia v mestskej oblasti sú najcennejšie optické údaje s priestorovým rozlíšením <0,5 metra. Najdôležitejším bodom pre použitie optických obrazov je ich dostupnosť. V dôsledku oblačnosti, oparu a iných atmosférických podmienok nie je vždy možné získať použiteľné optické snímky. Túto situáciu ešte zhoršujú niektoré katastrofy, ako sú požiare alebo silné búrky, ktoré sú charakterizované výraznejšou oblačnosťou a dymom.

Termálne snímky ponúkajú vynikajúce možnosti pre automatizovanú extrakciu anomálnych vysokých teplôt alebo horúcich miest spôsobených divokými požiarmi alebo informácií o sopečných erupciách. Avšak vzhľadom na skutočnosť, že energia klesá so zvyšujúcou sa vlnovou dĺžkou, tepelné vlnové dĺžky majú relatívne nízke úrovne energie a následne dáta termálneho obrazu majú nižšie priestorové rozlíšenie ako optické dáta.

Radarové senzory majú veľkú hodnotu pre úlohy rýchleho mapovania a analýzy, pretože umožňujú zobrazovanie na vlnových dĺžkach, ktoré sú takmer neovplyvnené atmosférickými poruchami, ako je dážď alebo oblačnosť. Väčšina moderných radarových senzorov so syntetickou apertúrou (SAR) je navrhnutá na získavanie údajov z prvkov s rôznym rozlíšením. Vo väčšine aplikácií sa používajú iba relatívne zmeny intenzity spätného rozptylu v rámci snímok. Napriek tomu je možné využiť intenzitu spätného rozptylu a fázu snímok SAR. S modernými satelitmi ako napr. Sentinel-1 je možné súčasne získavať dáta s viac ako jednou polarizáciou. Systémy SAR možno použiť na mapovanie záplav alebo na meranie zemských deformácií pred a počas zemetrasení alebo sopečných erupcií, najmä ak snímky po udalostiach možno analyzovať spoločne s archivovanými referenčnými snímkami pre detekciu zmien alebo interferometrickú koherenciu, alebo pre meranie posunov.

Typy dát DPZ a metódy spracovania snímok pre monitorovanie prírodných katastrof sú zhrnuté v Tab. 12.4.

Dostupnosť vhodných údajov s ohľadom na čas získania, pokrytie snímky, a priestorové, ako aj časové a spektrálne rozlíšenie sú dôležitým faktorom pre väčšinu aplikácií v kontexte katastrof. V súčasnosti existuje množstvo príkladov zvýrazňujúcich dôležitosť a potrebu rýchlej dostupnosti údajov DPZ, ako sú mapy hodnotenia škôd pri zemetraseniach, zosuvoch pôdy alebo záplavách. V oblasti riadenia katastrof sa využívajú údaje s vysokým priestorovým rozlíšením a techniky DPZ od modelovania rizík a analýzy zraniteľnosti až po včasné varovanie a hodnotenie škôd (Tab. 12.5).

Medzi hlavné dôvody pre drasticky zvýšený dopyt po rýchlej analýze satelitných údajov pre všetky druhy katastrof a fáz za posledné roky môžeme zahrnúť:

 dostupnosť optických snímok s veľmi vysokým rozlíšením (až 0,3 metra), ako aj radarových snímok (až 1 meter) z vesmíru za posledné roky výrazne vzrástla aj v civilnej sfére,
- záchranné zložky rýchlo získajú lepšie pochopenie toho, čo môžu tieto nové geoinformačné technológie priniesť do ich práce v oblastiach plánovania misií, logistiky, informovanosti o situácii a dokonca bezpečnosti misií,
- médiá a verejnosť zvyšujú dopyt po aktuálnych a pochopiteľných vizuálnych informáciách o oblastiach pohrôm a prebiehajúcich záchranných prácach.

Tab. 12.4 Typy DPZ údajov a techniky ich spracovania pre monitorovanie živelných pohrôm. **Tab. 12.4** Types of remote sensing data and processing techniques for monitoring natural disasters.

Source: Gähler, 2016

Typy dát	Príklady satelitov	Technika	Aplikácia
		Manuálna interpretácia	Škody na infraštruktúre a majetku v dôsledku záplav, zemetrasení, zosuvov pôdy atď.
ne)		Spektrálna klasifikácia	Miesto a rozsah záplav, zosuvy pôdy, vulkanický odpad, stopy po požiaroch
ektrál	Sentinel-2, Landsat,	Analýza semivariogramu, texturálne klasifikátory	Škody spôsobené zemetraseniami; lokalizácia zosuvov pôdy
Jultisp	Worldview, Pleiades, Quicknird, RapidEe, SPOT, ASTER	Prahovanie (vrátane indexov)	Miesto a rozsah záplav, zosuvy pôdy, vulkanický odpad, stopy po požiaroch
ické (n		Diferencovanie snímok	Miesto a rozsah záplav, zosuvy pôdy, vulkanický odpad, stopy po požiaroch
Opti		Zisťovanie zmien po klasifikácii	Miesto a rozsah záplav, zosuvy pôdy, vulkanický odpad, stopy po požiaroch
		Tvorba DEM	DEM sa používa ako doplnková informácia v rôznych štúdiách
álne	ASTER, MODIS, AVHRR	Split window	Teplota kráterového jazera, prúd lávy, predzvesť zemetrasenia, teplota a veľkosť ohniska požiaru
Term		Dvojpásmová	Teplota kráterového jazera, prúd lávy, predzvesť zemetrasenia, teplota a veľkosť ohniska požiaru
		Koherencia	Detekcia zmien v dôsledku zosuvu pôdy, záplav, požiaru atď.
	Sentinel-1,	Intenzita spätného rozptylu	Detekcia zmien v dôsledku zosuvu pôdy, záplav, požiaru atď.
-	Tandem-X, Cosmo-	Interferometria / Tvorba DEM	Detekcia zmien v dôsledku zosuvu pôdy, záplav, požiaru atď.
SAR	SkyMed, Radarsat-1/2, ERS-1/2, ALOS, ENVISAT	Diferenciálna interferometria	Deformácia povrchu v dôsledku sopečnej alebo tektonickej činnosti; rýchlosť a rozsah pomaly sa pohybujúcich zosuvov pôdy
		Polarimetria	Klasifikácia krajinnej pokrývky a detekcia zmien

Tab. 12.5 Aplikácie DPZ pre monitorovanie živelných pohrôm.

Tab. 12.5 Applications of remote sensing for natural disaster monitoring.

Source: Gähler, 2016

			Znižovanie rizika pohrôm	Pripravenosť, prevencia	Reakcia na núdzovú situáciu	Obnova, regenerácia
Živelné pohromy	iké	Sucho	Modelovanie rizík; analýza zraniteľnosti; plánovanie pôdohospodárstva a vodného hospodárstva	Predpoveď počasia; monitorovanie vegetácie; mapovanie potreby vody pre plodiny; včasné varovanie	Monitorovanie vegetácie; posúdenie škôd	Informovanie o zmierňovaní následkov sucha
	limatologic	Náhle vyprázdnenie ľadovcového jazera	Mapovanie oblastí náchylných na preliatie ľadovcových jazier; monitorovanie ľadovcov; vymedzenie záplavových oblastí; mapovanie využívania pôdy	Predpoveď počasia; monitorovanie ľadovcov, detekcia preliatia jazera; skoré varovanie	Mapovanie povodní; plánovanie evakuácie; posúdenie škody	Hodnotenie škôd; priestorové plánovanie
	x	Lesný požiar	Mapovanie oblastí náchylných na požiar; modelovanie rizika	Detekcia požiaru; predpovedanie šírenia/smeru požiaru; skoré varovanie	Koordinácia hasičského úsilia	Hodnotenie škôd
	he	Zemetrasenie	Hodnotenie stavebného fondu; mapovanie nebezpečenstiev	Meranie akumulácie napätia	Plánovanie trás pre pátranie a záchranu; hodnotenie škôd; plánovanie evakuácie; mapovanie deformácií	Hodnotenie škôd; identifikácia miest na obnovu
	ieofyzikál	Pohyb hmoty	Mapovanie nebezpečenstva	Meranie akumulácie napätia	Plánovanie trás pre pátranie a záchranu; hodnotenie škôd; plánovanie evakuácie; mapovanie deformácií	Hodnotenie škôd; identifikácia miest na obnovu
	Ŭ	Vulkanická činnosť	Modelovanie rizík; mapovanie nebezpečenstiev; digitálne výškové modely	Monitorovanie emisií; tepelné výstrahy	Mapovanie lávových prúdov; plánovanie evakuácie	Hodnotenie škôd; priestorové plánovanie
	ké	Záplavy	Mapovanie oblastí ohrozených záplavami; vytyčovanie záplavových oblastí; mapovanie využívania pôdy	Detekcia povodní; skoré varovanie; mapovanie zrážok	Mapovanie povodní; plánovanie evakuácie; posúdenie škody	Hodnotenie škôd; priestorové plánovanie
	/drologic	Zosuvy	Modelovanie rizík; mapovanie nebezpečenstiev; digitálne výškové modely	Monitorovanie zrážok a stability svahu	Mapovanie postihnutých oblastí; a stabilitu svahu	Hodnotenie škôd; územné plánovanie; navrhovanie postupov riadenia
	Ĩ	Pôsobenie vĺn	Modelovanie rizík; analýza zraniteľnosti	Detekcia pôsobenia vlny; skoré varovanie	Mapovanie postihnutých oblastí	Hodnotenie škôd; priestorové plánovanie
	gické	Búrky	Modelovanie rizík; analýza zraniteľnosti	Skoré varovanie; dlhodobé modelovanie klímy	ldentifikácia únikových ciest; predpovede búrok; monitorovanie cyklónov; hodnotenie vplyvu; krízové mapovanie	Hodnotenie škôd; priestorové plánovanie
	teorolo	Extrémne teploty	Modelovanie rizík; analýza zraniteľnosti	Predpoveď počasia; dlhodobé modelovanie klímy; skoré varovanie	Krízové mapovanie; plánovanie evakuácie; posúdenie škody	Hodnotenie škôd; priestorové plánovanie
	Β	Hmla	Modelovanie rizík; analýza zraniteľnosti	Predpoveď počasia; dlhodobé modelovanie klímy: skoré varovanie	Krízové mapovanie; plánovanie evakuácie; posúdenie škody	Hodnotenie škôd; priestorové plánovanie

12.3. Copernicus Emergency Management Service



Fig. 12.3 CEMS. Source: emergency.copernicus.eu

Služba Riadenia Núdzových Situácií Copernicus (CEMS) podporuje všetkých aktérov zapojených do riadenia živelných alebo človekom spôsobených pohrôm poskytovaním geopriestorových údajov a snímok na včasné a rýchle rozhodovanie. Systém CEMS neustále monitoruje Európu a celý svet a v reálnom čase vyhľadáva signály o blížiacej sa pohrome alebo dôkazy o tom, že k nej došlo. Služba okamžite informuje vnútroštátne orgány, alebo sa môže aktivovať na požiadanie, a poskytuje dáta vo forme máp, časových radov alebo iných relevantných informácií na lepšie riadenie rizika pohrôm. Produkty CEMS sa vytvárajú na základe satelitných, in-situ a modelových údajov.

Produkty CEMS zobrazujú informácie o katastrofickej udalosti v takom rozsahu, časovej osi a perspektíve, aké môžu poskytnúť len geopriestorové informácie. Produkty CEMS môžu skúmať zmeny v oblasti Zeme v priebehu niekoľkých dní, týždňov, mesiacov alebo rokov. To môže pomôcť orgánom presne určiť postihnuté oblasti identifikovaním zmien, napr. z jedného dňa na druhý. Vysoká úroveň podrobnosti umožňuje vizualizovať rozsah udalosti bez toho, aby bolo nutné cestovať do každej oblasti regiónu, čo šetrí čas a zdroje. Produkty sa môžu rýchlo zdieľať medzi všetkými zapojenými agentúrami, aby sa umožnili včasné a konzistentné reakčné opatrenia. Služba CEMS pozostáva z dvoch zložiek:

- Zložka mapovania na požiadanie môže podporovať všetky fázy cyklu núdzového manažmentu: pripravenosť, prevenciu, znižovanie rizika pohrôm, reakciu na núdzové situácie a obnovu. Tím Rapid Mapping vytvára na požiadanie mapy pre okamžité núdzové situácie. Tím Risk and Recovery ponúka informácie, ktoré pomôžu pri rozhodovaní o pripravenosti na pohromu a aktivitách po udalosti. Služba je plne funkčná od 1. Apríla 2012 a vykonáva ju Spoločné Výskumné Centrum (JRC) Európskej komisie.
- Zložka včasného varovania nepretržité predpovedanie pohrôm a informácie o monitorovaní, ktoré pomáhajú pri pripravenosti a núdzovej reakcii na povodne, suchá a požiare. Produkty nepretržitého monitorovania týchto komponentov slúžia aj ako základ pre plánovanie prevencie a obnovu počas pohromy.

Zložka včasného varovania je tvorená tromi systémami:

- Európsky systém varovania pred povodňami (EFAS), prostredníctvom ktorého sa poskytujú prehľady o prebiehajúcich a predpovedaných povodniach v Európe na obdobie až 10 dní vopred.
- Európsky informačný systém o lesných požiaroch (EFFIS) (Obr. 12.3), prostredníctvom ktorého sa poskytujú informácie v takmer reálnom čase a informácie z minulosti o lesných požiaroch a režimoch lesných požiarov v európskom, blízkovýchodnom a severoafrickom regióne.
- Európske stredisko pre monitorovanie sucha (EDO), ktoré poskytuje informácie týkajúce sa sucha a vydáva včasné varovania pre Európu.

12 Applications of RS – Environment and Natural Disasters



Obr. 12.4 Predpoveď EFFIS o zvýšenom nebezpečenstve lesných požiarov pre severozápadnú Európu v Apríli 2019.

Fig. 12.4 EFFIS forecast of increased wildfire danger for Northwest Europe in April 2019. Source: emergency.copernicus.eu/mapping/ems/copernicus-ems-monitors-impact-wildfiregermany

Doplnením predchádzajúcich troch uvedených systémov na globálnej úrovni sú Globálny systém varovania pred povodňami (*GloFAS*), Globálny informačný systém o prírodných požiaroch (*GWIS*) a Globálne stredisko pre monitorovanie sucha (*GDO*).

Každý komponent CEMS poskytuje verejné informácie špecifické pre ich aktivity prostredníctvom interaktívnych živých máp, správ alebo publikovaných máp z aktivácie služby. Niektoré informácie nie sú z bezpečnostných dôvodov sprístupnené verejnosti. Ako používať dostupné údaje CEMS:

• On-demand Mapping:

https://emergency.copernicus.eu/mapping/ems/how-use-service

• Floods EFAS video tutorials:

https://www.efas.eu/en/training

• GloFAS background:

https://www.globalfloods.eu/general-information/about-glofas/

• Fire EFFIS technical background:

http://effis.jrc.ec.europa.eu/about-effis/technical-background/

• Droughts EDO:

https://edo.jrc.ec.europa.eu

Detailnejšie informácie o CEMS je možné nájsť na:

https://emergency.copernicus.eu/index.html

Príručka pre používateľov služieb CEMS je dostupná na:

https://www.copernicus.eu/en/new-copernicus-emergency-management-userguide

12.4. Global Disaster Alert and Coordination System (GDACS)

GDACS je rámec spolupráce medzi Organizáciou Spojených národov a Európskou komisiou. Zahŕňa manažérov pre katastrofy a informačné systémy o pohromách na celom svete a jeho cieľom je vyplniť informačné a koordinačné medzery v prvej fáze po veľkých katastrofách. GDACS poskytuje prístup v reálnom čase k internetovým informačným systémom o katastrofách a súvisiacim koordinačným nástrojom.

Činnosti GDACS prezentuje a schvaľuje poradný výbor GDACS, ktorému v súčasnosti predsedá Spoločné výskumné centrum. Na výročných zasadnutiach poradnej skupiny GDACS sa zúčastňujú manažéri katastrof, vedci, odborníci na mapy, webmasteri a ďalší odborníci s cieľom definovať normy na výmenu informácií a stratégiu ďalšieho rozvoja súvisiacich nástrojov a služieb.

GDACS bol vytvorený v roku 2004 s cieľom riešiť značné nedostatky v zhromažďovaní a analýze informácií v počiatočnej fáze veľkých náhlych pohrôm (Obr. 12.5). V uplynulom desaťročí GDACS využíval kolektívne kapacity manažérov pre pohromy a informačné systémy na celom svete s cieľom uľahčiť medzinárodnú výmenu informácií a rozhodovanie. Výber a úroveň výstrahy pred živelnými pohromami v systéme GDACS je založený na automatických modeloch hodnotenia dopadov. Softvér GDACS nepretržite monitoruje alebo prijíma vedecké údaje o prírodných nebezpečenstvách s cieľom spustiť analytické modely. Informácie o polohe, sile a ďalších charakteristikách sa potom používajú na výpočet postihnutej oblasti a očakávaného vplyvu. Pre rôzne typy pohrôm sa používajú rôzne modely. Následne sa hodnotia potenciálne dôsledky udalosti výpočtom počtu obyvateľov v postihnutej oblasti a ich zraniteľnosti.



Obr. 12.5 Doterajšie dáta z GDACS. **Fig. 12.5** Data from GDACS. Source: gdacs.org/Knowledge/overview.aspx

V súčasnosti sa výstrahy GDACS vydávajú pre zemetrasenia a možné následné cunami, tropické cyklóny, záplavy a sopky. Pokiaľ ide o zemetrasenie, cunami a tropické cyklóny, všetky výpočty a hodnotenia sa vykonávajú automaticky, bez ľudského zásahu. Prebiehajú štúdie s cieľom zahrnúť do tohto zoznamu povodne a sopečné erupcie, ktoré sa v súčasnosti zavádzajú ručne. Výskum a vývoj prebieha nepretržite s cieľom zlepšiť globálne monitorovanie.

Integrovaná webová stránka GDACS ponúka tieto informačné systémy o pohromách a online koordinačné nástroje:

- Upozornenia na katastrofy GDACS, ktoré sa vydávajú a rozosielajú približne 25 000 odberateľom bezprostredne po náhlych pohromách. Automatické odhady a analýzu rizík - základ výstrah - poskytuje Spoločné výskumné centrum Európskej komisie (JRC).
- 2. Virtuálne OSOCC (On-Site Operations Coordination Centre) obmedzená online platforma na výmenu informácií v reálnom čase a spoluprácu medzi všetkými aktérmi v prvej fáze katastrofy. Aktualizácie informácií z postihnutej krajiny a od medzinárodných respondentov moderuje špecializovaný tím. Virtuálny OSOCC má približne 19 000 registrovaných používateľov a spravuje ho Úrad OSN pre koordináciu humanitárnych záležitostí (OCHA).
- 3. Mapy a satelitné snímky od rôznych poskytovateľov sa vo virtuálnom OSOCC zdieľajú prostredníctvom satelitného mapovacieho a koordinačného systému GDACS. Poskytuje komunikačnú a koordinačnú platformu, kde môžu organizácie monitorovať a informovať zainteresované strany o svojich ukončených, súčasných a budúcich mapovacích činnostiach počas núdzových situácií. Túto službu sprostredkúva Satelitné centrum OSN (UNOSAT) Inštitútu OSN pre vzdelávanie a výskum (UNITAR).

12.4.1.1. GDACS customers and its use

Mnohé vlády a organizácie reagujúce na katastrofy sa pri plánovaní medzinárodnej pomoci spoliehajú na výstrahy GDACS a automatické odhady dopadov a predplatili si VirtualOSOCC, aby mohli tento nástroj využívať na výmenu informácií a koordináciu v prvej fáze pohromy. Mnohé vlády a organizácie formalizovali používanie nástrojov a služieb GDACS vo svojich národných plánoch reakcie na pohromy, najmä jeho automatické výstrahy a odhady dopadov a VirtualOSOCC. Informácie systému GDACS sú otvorene prístupné prostredníctvom rozhraní platformy GDACS. Údaje a odhadovaný vplyv možno priamo integrovať do iných webových portálov alebo webových stránok prostredníctvom kanálov RSS alebo iných štandardných formátov.

Počas prvých dní po veľkých náhlych pohromách postihnutá krajina a veľké množstvo medzinárodných aktérov zhromažďujú a analyzujú informácie, aby mohli naplánovať svoju reakciu. Táto činnosť sa zvyčajne vykonáva súčasne s rôznou rýchlosťou, relevantnosťou a presnosťou, pričom sa využívajú viaceré informačné kanály a uplatňujú rôzne postupy. Počas počiatočnej fázy plánovania je výmena informácií medzi medzinárodnými subjektmi, ktoré reagujú, zvyčajne malá alebo žiadna. Rozhodnutia sú často založené na nejednotných informáciách, nepresných zdrojoch alebo predpokladoch. Plánovaná alebo mobilizovaná pomoc iných organizácií sa berie do úvahy len zriedka. To má často za následok duplicitu, medzery, prekrývanie alebo dokonca nevhodnú reakciu, ktorá je občas spojená s vysokými nákladmi. Cieľom služieb GDACS je uľahčiť výmenu informácií medzi všetkými aktérmi na podporu rozhodovania a koordinácie. Služby GDACS vychádzajú zo spoločných znalostí manažérov pre katastrofy na celom svete a zo spoločnej kapacity všetkých príslušných informačných systémov pre katastrofy.

GDACS v súčasnosti ponúka **webový mapový portál** (Obr. 12.6) a súčasne aj **mobilnú** aplikáciu (Obr. 12.7).

12 Applications of RS – Environment and Natural Disasters



Fig. 12.6 Map portal GDACS.

Source: www.gdacs.org/default.aspx



Obr. 12.7 Mobilná aplikácia GDACS. **Fig. 12.7** Mobile App GDACS. Source: gdacs.org/About/app.aspx

12.5. Use of RS for earthquake monitoring

Zemetrasenia sú dôsledkom náhleho uvoľnenia akumulácie napätia v zemskej kôre v dôsledku napätí spôsobených tektonickými hnacími silami pohybu platní a stavby horstiev (Obr. 12.8). Zemetrasenia vytvárajú dva hlavné súbory merateľných fyzikálnych javov. Po prvé, seizmické vlny sa šíria zo zdroja zemetrasenia, vyžarujú smerom von a možno ich globálne merať seizmometrami. Práve tieto vlny sú zdrojom otrasov zeme, ktoré tvoria hlavnú časť nebezpečenstva pre budovy pri veľkých zemetraseniach. Po druhé, k trvalému posunu zemského povrchu dochádza v dôsledku zmeny akumulovanej elastickej energie, ktorá je výsledkom náhleho sklznutia po povrchu zlomu (čo samo osebe môže predstavovať priame nebezpečenstvo, ak sa infraštruktúra nachádza v oblasti zlomu). Tento statický posun vedie v dlhodobom horizonte (po mnohých zemetrasných cykloch) k trvalej deformácii zemskej kôry, prispôsobeniu sa posúvaniu platní a blokov kôry, ako aj k rastu geologických štruktúr a pohorí. Práve druhý z týchto prejavov zemetrasenia (trvalé statické posuny) je zvyčajne viditeľné pre systémy DPZ. Hlavným cieľom monitorovania pomocou techník DPZ je rozpoznanie nebezpečenstva spojeného so seizmickým otrasom rozšírením analýzy posunov zeme po zemetrasení a dlhodobejšieho relatívneho interseizmického posunu kôry vedúcich k zemetraseniam. Identifikácia miesta a rýchlosti deformácie zemskej kôry je dôležitá pre obmedzenie potenciálnych zdrojov porúch seizmických otrasov, ktoré predstavujú nebezpečenstvo. Okrem primárneho nebezpečenstva otrasov patria medzi sekundárne nebezpečenstvá zemetrasením vyvolané cunami, zosuvy pôdy, vulkanická činnosť, ako aj ďalšie, s nimi spojené udalosti, ako sú požiare a záplavy, ktoré môžu vzniknúť po prvotnom zemetrasení.



Obr. 12.8 Tektonické zemetrasenie. **Fig. 12.8** Tectonic earthquake. Source: ©Agata Nowicka/Marlena Agency for Caltech Science Exchange

12 Applications of RS – Environment and Natural Disasters

DPZ môže zohrávať dôležitú úlohu pri charakterizácii zdrojov seizmického nebezpečenstva, ako aj expozície osôb a majetku a fyzického prostredia potenciálnej katastrofy. DPZ preto môže prispieť k pochopeniu nebezpečenstiev katastrofy, najmä tam, kde sa obyvateľstvo, infraštruktúra a stavby nachádzajú vzhľadom na zdroje takéhoto nebezpečenstva. Okrem toho môže DPZ podporiť zlepšenie pripravenosti na katastrofy v prípade zemetrasení, aby mohla nastať efektívnejšia reakcia a obnova zvýraznením regiónov vystavených nebezpečenstvu zemetrasenia. DPZ sa v súčasnosti podieľa na všetkých aspektoch cyklu znižovania rizika katastrof a s nadchádzajúcim pokrokom má potenciál prispieť ešte viac, najmä pri identifikácii nebezpečenstva v oblastiach s napätím v zemskej kôre (Obr. 12.9).



Obr. 12.9 Využitie údajov zo satelitov SAR, optických a GNSS, ktoré v súčasnosti prispievajú informáciami k rôznym aspektom cyklu riadenia katastrof v rámci zemetrasení. **Fig. 12.9** The use of SAR, optical and GNSS satellite data currently contributing information to various aspects of the earthquake disaster management cycle. Source: Elliott, 2020

12.5.1. Application of RS

Okrem využitia technológií pozorovania Zeme treba najprv spomenúť aj ostatné technológie, ktoré majú významný príspevok k monitorovaniu zemetrasení – GNSS, letecké mapovanie, geochemické datovanie krajinných prvkov, a tak isto terénne práce. Aby bolo možné plne porozumieť komplexným tektonickým problémom, je často potrebné skombinovať súbor vyššie uvedených techník s technikami DPZ. Seizmologické meranie majú globálne pokrytie pre stredne silné a väčšie zemetrasenia a môžu poskytnúť časovú vzorku s vysokým rozlíšením potrebnú na sledovanie rýchleho vývoja zemetrasenia v priebehu niekoľkých sekúnd, čo nie je možné pomocou statických meraní z opakovaných preletov satelitov za rádovo niekoľko dní. Seizmológia bola po väčšinu 20. storočia hlavným nástrojom na skúmanie zemetrasení, najmä v odľahlých oblastiach, kde nie je ľahké vykonávať terénne pozorovania. Celosvetová štandardná sieť seizmografov bola nainštalovaná začiatkom 60. rokov 20. storočia a umožnila rutinné určovanie miest, mechanizmov a magnitúd zemetrasení. Merania GNSS poskytujú globálny model súčasných pohybov dosiek a globálny model deformácie zemskej kôry, aj keď s relatívne malým priestorovým rozlíšením pre väčšinu častí sveta. Terénne a letecké pozorovania môžu poskytnúť oveľa lepšie identifikovanie zlomov a zlomových štruktúr v miestnom meradle, čo možno použiť na overenie satelitných pozorovaní. Terénne pozorovania možno použiť na štúdium dlhodobejšieho vývoja zlomových zón a tektonickej krajiny počas viacerých cyklov zemetrasení datovaním prvkov v krajine, ktoré boli zmenené tektonickými procesmi.

Zemetrasenia predstavujú čoraz väčšie nebezpečenstvo pre rastúcu populáciu. Satelitné pozorovania ponúkajú potenciál na pokrytie širokého územia (v rozsahu 100 - 1 000 km) po katastrofe; pri najväčších udalostiach sa často využíva Medzinárodná charta o vesmíre a veľkých katastrofách, aby sa vládam a humanitárnym agentúram rýchlo poskytli nevyhnutné snímky. Snímky získané po zemetrasení môžu byť užitočné pri mapovaní zosuvov pôdy, zaplavení nízko položených pobrežných oblastí cunami, hodnotení škôd na budovách a aktualizácii modelov seizmických zdrojov zemetrasenia na zlepšenie odhadov otrasov zeme. Nedávne pokroky sa dosiahli aj pri využívaní mapovania koherencie pomocou satelitov SAR na sledovanie zrútenia budov, ktoré nemusí byť ľahko viditeľné na optických snímkach ak dôjde ku kolapsu budov prevažne vo vertikálnom smere. Využívanie satelitných údajov pri reakcii na katastrofy však má určité oneskorenie, keďže často trvá niekoľko dní alebo dokonca týždňov, kým satelity nasnímajú určitú časť zemegule. Táto možnosť opätovného snímania je výrazným obmedzujúcim faktorom pre InSAR, ktorý si vyžaduje vhodné snímky získané pred a po udalosti v identických konfiguráciách. Použitie optických satelitov je obmedzené na denné bezoblačné podmienky, čo môže spôsobiť ťažkosti napríklad pri mapovaní zosuvov v horských oblastiach. S rastúcim počtom satelitov a tiež existenciou konštelácií s viacerými satelitmi sa však toto oneskorenie znižuje, najmä v prípade optických satelitov s vysokým rozlíšením, ktoré môžu mať veľmi flexibilnú geometriu zobrazenia.

Vedecká reakcia na mapovanie zemetrasení má dlhú históriu, pričom zemetrasenie v Kalifornii v roku 1906 bolo prvým zemetrasením, ktoré sa skúmalo geodeticky na základe opätovného merania vytvorenej triangulačnej siete. Od prvého použitia InSAR na meranie koseizmickej deformácie pri zemetrasení v Landers v Kalifornii v roku 1992 počet zemetrasení skúmaných pomocou InSAR presiahol 100. Údaje InSAR sú schopné poskytnúť diaľkové merania subaerálnych koseizmických posunov zemského povrchu s veľmi vysokým priestorovým rozlíšením (~10 m) zo zemetrasení zemskej kôry (<50 km) strednej veľkosti, pričom pozorovania sa obmedzujú na kontinentálne zemetrasenia a

len na najväčšie udalosti v subdukčnej zóne, ktoré majú za následok významnú (>1 cm) deformáciu na pobreží.

12.5.1.1. Modelling deformations

Cieľom identifikovania oblastí posunov pri zemetrasení a modelovania sklzu na zlomoch pod povrchom (Obr. 12.10) je lepšie pochopiť mechaniku zemetrasení a seizmické nebezpečenstvo a odvodiť, ako vývoj a rast geologických štruktúr súvisí s deformáciami pozorovanými pri jednotlivých zemetraseniach. Tektonická geodézia umožnila vývoj modelov opisujúcich vývoj sklzu v priebehu zemetrasného cyklu a poskytuje pozorovania, ktoré možno použiť na prepojenie reologických vlastností v laboratórnych experimentoch trenia s reálnymi zlomovými systémami.





Fig. 12.10 Application of remote sensing to model and interpret earthquake faults and fault geometry and their slip distributions. Satellite interferometry provides high-resolution measurements of surface displacements over large areas. Source: Elliott, 2020

Merania InSAR sú doplnkom k seizmologickému monitorovaniu zemetrasení: aj keď neobsahujú historické údaje o pohyboch daného zlomu, poskytujú priestorové dáta s oveľa vyšším rozlíšením o charaktere pohybov pri plytkých zemetraseniach, ako aj schopnosť obsiahnuť komplikovanejšiu segmentáciu zlomov a často sa interpretujú spoločne so seizmologickými údajmi. Nevýhodou InSAR je temporálne rozlíšenie týchto dát, čo má za následok, že niektoré postseizmické deformácie sú zachytené spolu s koseizmickým signálom. Tento problém by sa mal eliminovať s kratšími časmi opakovaných preletov pri čoraz väčšom počte radarových satelitných misií.

Keďže merania InSAR zobrazujú posun zemského povrchu (vzhľadom na určitú predpokladanú neporušenú oblasť), sú užitočné pri určovaní konkrétneho zlomu, pri ktorom došlo k pohybu v hĺbke pod povrchom. Nemusí to byť vždy jednoznačne identifikovateľné, nakoľko viaceré porušenia môžu byť lokalizované iba pod povrchom a nedosiahnu až na povrch. Určenie priestorového rozloženia takýchto prejavov zemetrasení je dôležité, pretože identifikuje ktoré časti zlomu zlyhali a boli porušené, a ktoré nie. Na základe toho je potom možné vypočítať prenos napätia na okolité zlomy a identifikovať oblasti zlomového systému, ktoré sa tým priblížili k danej poruche. Citlivosť na diskontinuity vo fázových meraniach, ktoré sú prítomné v údajoch InSAR, umožňuje mapovanie malých posunov v iných zlomových systémoch mimo hlavného zlomu, čo umožňuje identifikovať predtým nezmapované zlomy vyvolané zemetrasením.

12.5.1.2. Fault display on the fracture

V prípade väčších a plytších zemetrasení, ktoré majú za následok decimetrové pohyby zemského povrchu, je možné odvodiť oblasti horizontálnych posunov z optických stereo-dvojíc snímok (Obr. 12.11). Dosiahne sa to pomocou metódy subpixelovej korelácie. Takéto oblasti horizontálnych posunov sa môžu použiť aj na meranie dlhodobejších tektonických pohybov.



Obr. 12.11 Vytvorenie DEM na základe dvojice optických satelitných snímok a jeho využitie pre monitorovanie dôsledkov zemetrasení.

Fig. 12.11 Generation of a DEM based on a pair of optical satellite images and its use for earthquake impact monitoring.

Source: Elliott, 2020

Informácie o topografii povrchu sa získavajú z dvojíc optických alebo SAR satelitných snímok prostredníctvom vytvorenia DEM (Obr. 12.12). Pri tejto technike sa využíva stereoskopický efekt, ktorý sa dosahuje pri snímaní povrchu z dvoch rôznych pozícií na obežnej dráhe. Najnovšie satelitné systémy dokážu zhotoviť viacero snímok na tej istej orbitálnej dráhe. To umožňuje vytvárať stereofotografické a tristereofotografické snímky, ako napríklad pri panchromatických snímkach Pleaides 50 cm, z ktorých je možné odvodiť DEM v podobnej kvalite ako je možné získať z LiDAR-ových dát.



Obr. 12.12 Príklady DEM topografie epicentrálnej oblasti zemetrasenia odvodených z radarových (ľavý stĺpec a-c) a optických stereosnímok (pravý stĺpec d-f) zobrazených ako tieňovaný reliéf osvetlený z juhovýchodu.

Fig. 12.12 Examples of DEM topography of the epicentral earthquake area derived from radar (left columns a-c) and optical stereo images (right columns d-f) shown as hillshaded relief illuminated from the southeast.

Source: Elliott et al., 2020

Dáta odvodené z DEM sa potom môžu použiť na získanie kvantitatívnych informácií o krajine a tektonike. Mapy terénnych útvarov a topografických prvkov pomáhajú pri interpretácii povrchových prvkov a identifikujú miesta, kde zlomové systémy zasahujú na povrch. Rozdielom DEM z obdobia pred zemetrasením a DEM získaných po zemetrasení je možné určiť výškovú zmenu vyplývajúcu z koseizmickej deformácie, čím sa zvýrazní množstvo aktívnych zlomových štruktúr, ktoré môžu byť zapojené do tektonickej poruchy. Navyše, aj samotné optické snímky možno použiť na odhad oblasti horizontálnych posunov pomocou techník optickej korelácie, ktoré sú založené na odhade posunu prvkov v rámci snímok v dôsledku pohybu zeme. Takto možno rýchlo odhadnúť povrchovú stopu poruchy, ako aj stupeň deformácie mimo poruchy. Optické snímky sa tak isto môžu kombinovať s meraniami InSAR na odvodenie trojzložkového poľa posunov a použiť aj pri modelovaní sklzu zlomu (Obr. 12.13). Merania pohybu povrchu technikami DPZ poskytujú nenahraditeľné údaje o troch zložkách posunov ak nie sú k dispozícii merania GNSS, keďže merania InSAR sú zvyčajne najcitlivejšie na vertikálny pohyb, zatiaľ čo z optických snímok vieme získať horizontálne zložky pohybu.



Obr. 12.13 Trojrozmerné pole posunov zemetrasenia v Čína v roku 2018 získané krížovou koreláciou údajov SAR.

Fig. 12.13 Three-dimensional displacement field of the 2018 China earthquake obtained by crosscorrelation of SAR data.

Source: Elliott et al., 2020

Cieľom pri súčasných satelitoch s vysokým temporálnym a priestorovým rozlíšením je lepšie pochopenie seizmotektonických procesov pri poruchách v dôsledku zemetrasení pre určenie seizmického potenciálu tektonických zlomových systémov, ako aj pre mapovanie kolapsu budov a infraštruktúry, resp. predpovedanie sekundárneho nebezpečenstva ako sú zosuvy pôdy bezprostredne po zemetrasení. Dostupnosť veľkého množstva dát DPZ s vysokým rozlíšením už zásadne zmenila spôsob, akým vedecká komunita reaguje na veľké zemetrasenia. Údaje z pozorovania Zeme v súčasnosti zohrávajú kľúčovú úlohu aj pri odhade a pochopení veľkoplošných deformácií a dlhodobého seizmického nebezpečenstva v desaťročnom až tisícročnom horizonte.

12.5.2. Mapping the 2019 California earthquakes with the

Copernicus S-1 and 2 missions

Južnú Kaliforniu zasiahli v júli 2019 krátko po sebe (4. júla a 6. júla) dve silné zemetrasenie s magnitúdou 6.4 a 7.1; čo predstavovali najsilnejšie zemetrasenia od roku 1999 (Obr. 12.14). Táto séria zemetrasení sa odohrala v odľahlejšej časti Kalifornie, čo obmedzilo negatívne účinky v obývaných oblastiach.



Obr. 12.14 Zemetrasenia v Kalifornii, júl 2019. **Fig. 12.14** Earthquakes in California, July 2019. Source: PacificTWC (2019). Earthquakes of California: 1989 - 2019. https://www.youtube.com/watch?v=qYgz1OCbeu8

Vzhľadom na krátku frekvenciu opakovaných preletov satelitov Sentinel-1 a -2 sa pred a počas tohto zemetrasenia získal väčší počet snímok, čo ponúklo cenné dáta na monitorovanie deformácie zeme a mapovanie zlomov, ktoré sa podieľali na zemetrasení. V kombinácii s inými typmi údajov (napr. seizmickými) možno odvodiť model poškodenia zemetrasenia, ktorý vedcom pomôže pochopiť mechanizmus zemetrasení a kalifornský zlomový systém. Komplexná analýza vychádzala z radarových snímok Copernicus Sentinel-1 a optických snímok Copernicus Sentinel-2 z obdobia pred a po sekvencii zemetrasení.

Zo snímok Sentinel-1 boli odvodené interferogramy, ktoré poskytli meranie deformácie zeme na základe fázového rozdielu elektromagnetických vĺn vysielaných satelitom medzi dvoma snímaniami (Obr. 12.15). Ako už bolo uvedené, táto technika je citlivá najmä na vertikálne pohyby zeme a za optimálnych podmienok poskytuje merania deformácie s milimetrovou presnosťou. Táto analýza bola vykonaná na platforme ESA Geohazards Exploitation Platform (GEP) s použitím SNAP Toolboxu ESA a procesora DIAPASON CNES s radarovými snímkami Copernicus Sentinel-1.



Obr. 12.15 Posuny vypočítané z radarových snímok Sentinel-1 pred a po zemetrasení (vľavo) a odvodené gradienty posunu (vpravo). Na mape gradientov sú hlavné zlomové trhliny znázornené ako hrubé tmavé línie.

Fig. 12.15 Displacements determined from Sentinel-1 radar images before and after the earthquake (left) and derived displacement gradients (right). On the gradient map, the main fault ruptures are shown as thick dark lines.

Source: ©Dr. Sotiris Valkaniotis, Geodynamic Institute NOA & Corinth Rift Laboratory; Contains modified Copernicus Sentinel-1 data (2019)

Na extrakciu horizontálnej deformácie terénu sa vypočítala aj subpixelová korelácia optických snímok z misie Copernicus Sentinel-2 (Obr. 12.16). Princíp tejto metódy spočíva v detekcii rovnakého pixelu na snímke získanej pred zemetrasením a po ňom a v meraní horizontálneho posunu medzi týmito dvoma polohami.



Obr. 12.16 Horizontálny posun určený z korelácie snímok Sentinel-2 pred a po zemetrasení. Červená/žltá farba ukazuje posun smerom na sever a modrá smerom na juh. Čierne línie znázorňujú zlomové trhliny mapované pomocou snímok Sentinel-1 a -2. **Fig. 12.16** Horizontal displacement determined from the correlation of Sentinel-2 images before and after the earthquake. The red/yellow colour shows the northward shift and the blue colour shows the southward shift. Black lines show fault ruptures mapped by Sentinel-1 and -2 images. Source: ©Dr. Sotiris Valkaniotis, Geodynamic Institute NOA & Corinth Rift Laboratory; Contains modified Copernicus Sentinel-1 data (2019)

Výsledky ukazujú jasný posun pri optickom aj radarovom spracovaní s horizontálnym posunom 1 až 1,5 m a vertikálnym pohybom menším ako 1 meter. Povrchové trhliny boli identifikované a mapované pomocou interferogramov a odvodených produktov (napr. gradient), optických ofsetov a analýzy detekcie zmien na optických snímkach. Všetky tieto súbory údajov sú navzájom konzistentné a ukazujú komplexný vzor ko-seizmických povrchových porúch s orientáciou SZ-JV a SV-JZ. To ilustruje schopnosť dvoch nezávislých satelitných misií programu Copernicus: presné pozorovanie vzoru pohybu terénu s doplnkovými informáciami z každého satelitného senzora je kľúčovým pre oblasť monitorovania geohazardov.

12.5.3. Earthquake mapping on a fault in France

V Novembri 2019 zasiahlo región Auvergne-Rhône-Alpes vo Francúzsku zemetrasenie, čo je pre túto oblasť neobvyklé. Pre pochopenie povahy seizmického zlomu a pre zmapovanie jeho polohy boli použité satelitné snímky misie Sentinel-1.

Kombináciou snímok získaných pred zemetrasením a po ňom sa na základe zmien na zemi, ktoré nastali medzi dvoma dátumami snímania, vytvoril na kombinovanej snímke interferogram (Obr. 12.17), ktoré vedcom umožňil kvantifikovať pohyb zeme (Obr. 12.18). Záznam zo satelitu Sentinel-1 bol získaný 12. novembra, jeden deň po udalosti, a následne spracovaný na platforme ESA Geohazards Exploitation Platform (GEP).



Obr. 12.17 Interferogram zo snímok Sentinel-1 pre zemetrasenie vo Franczúsku v roku 2019, identifikujúci sériu zlomov v oblasti západne od mesta Le Teil. **Fig. 12.17** Interferogram from Sentinel-1 images for the 2019 earthquake in France, identifying a series of faults in the area west of Le Teil. Source: ©contains modified Copernicus Sentinel data (2019), processed by ESA

Hoci sa v regióne nachádza niekoľko zlomov vyznačených na geologických mapách, o žiadnom z nich nebolo známe, že by bol seizmicky aktívny. Interferogram identifikoval sériu zlomov v oblasti západne od mesta Le Teil a umožnil vedcom identifikovať zlom, ktorý bol príčinou zemetrasenia. Pri satelitnom pozorovaní sa tiež nameral posun zeme, ktorý zodpovedá zdvihu až o 8 cm v južnej časti zlomu.



Obr. 12.18 Veľkosť posunov identifikovaná na základe snímok S-1 pre zemetrasenie vo Franczúsku 2019.

Fig. 12.18 Displacement magnitude identified from S-1 imagery for the 2019 France earthquake. Source: ©contains modified Copernicus Sentinel data (2019), processed by BRGM

12.5.4. New look at the 2016 Italy earthquake thanks to Sentinel-1

24. augusta 2016 zasiahlo stredné Taliansko zemetrasenie, ktoré si vyžiadalo najmenej 290 obetí a spôsobilo rozsiahle škody. Taliansky polostrov je náchylný na zemetrasenia z dôvodu pretrvávajúcej kolízie africkej a eurázijskej tektonickej dosky. Pod Apeninským pohorím spôsobuje regionálna kolízia ohýbanie a ponáranie africkej dosky pod Tyrrhénske more a zároveň jej ústup na severovýchod. Ústup dosky je hlavným procesom, ktorý spôsobuje súčasné tektonické procesy spôsobujúce zemetrasenia ako je toto a zemetrasenie v roku 2009, ktoré zničilo talianske mesto L'Aquila.

Na základe snímok Sentinel-1 pred a po udalosti bolo možné kvantifikovať pohyb zeme vo vertikálnom aj východno-západnom smere kombináciou radarových snímok získaných počas letu satelitov z juhu na sever aj zo severu na juh. Bolo zistené, že hlavný model deformácie vykazuje poklesy dosahujúce približne 20 cm v oblasti Accumoli a bočné pohyby až do 16 cm (Obr. 12.19).

Vedci z talianskeho Národného inštitútu pre geofyziku a vulkanizmus zároveň skombinovali radarové snímky Sentinel-1 nad stredným Talianskom z obdobia pred a po zemetrasení, aby vypočítali polohu, geometriu a veľkosť sklzu na zdrojovom zlome (Obr. 12.20). Skĺznutie je rozložené najmä v dvoch oblastiach s veľkosťou približne 1 m. Seizmicita po otrasoch (čierne bodky) zreteľne obklopuje tieto oblasti a uvoľňuje zvyšné napätie pozdĺž zlomu. Červená hviezda predstavuje polohu hlavného otrasu. Zelené hviezdy označujú najvyššie dotrasy sekvencie (M > 4,3).



Obr. 12.19 Interferogram na základe dvoch snímok Sentinel-1 ukazujúci zmeny, ku ktorým došlo počase zemetrasenia. Sedem interferometrických pásov zodpovedá približne 20 cm deformácii. **Fig. 12.19** Interferogram based on two Sentinel-1 images showing the changes that occurred after the earthquake. The seven interferometric fringes correspond to approx. 20 cm of deformation. Source: ©Contains modified Copernicus Sentinel data (2016)/ESA/ CNR-IREA



Obr. 12.20 Zdrojový zlom zemetrasenia v Taliansku v roku 2016. **Fig. 12.20** Source fault of the 2016 earthquake in Italy. Source: ©Contains modified Copernicus Sentinel data (2016)/ESA/INGV, CC BY-SA 3.0 IGO

12.6. Application of RS for monitoring volcanic activity

Sopečné erupcie predstavujú riziko pre život a živobytie miestnych obyvateľov tým, že poškodzujú infraštruktúru a vytláčajú z danej oblasti obyvateľstvo a môžu mať globálne dopady narušením klímy, ekonomickej činnosti a leteckej dopravy. Nebezpečenstvo erupcie zahŕňa okrem iného oblaky popola, sopečné bomby, pyroklastické prúdy, prúdy lávy, bahenné prúdy, lavíny sutín a zemetrasenia vyvolané vulkanickou činnosťou. Na celom svete existuje ~ 1 400 aktívnych a potenciálne aktívnych sopiek na zemskom povrchu a odhaduje sa, že 800 miliónov ľudí žije do 100 km a asi 30 miliónov ľudí do 10 km od týchto sopiek (Obr. 12.21). To zodpovedá dosahu nebezpečenstva spojeného s veľkými sopečnými erupciami, a aj malé až stredne veľké erupcie by mohli postihnúť ľudí žijúcich vo vzdialenosti do 10 km.



Obr. 12.21 Svetová mapa s polohou najvýznamnejších vulkánov. **Fig. 12.21** World map with the location of major volcanoes. Source: www.geographypods.com/volcanoes.html

Mnohým (ale nie všetkým) sopečným erupciám predchádza určitá forma nepokoja, vrátane zvýšenej seizmickej aktivity, deformácie zeme, emisií plynov a tepelných anomálií (Obr. 12.22). Dlhodobé monitorovanie je najlepším prostriedkom na rozpoznanie týchto príznakov a určenie, či sú anomálne, najmä ak naznačujú blížiacu sa erupciu alebo meniace sa nebezpečenstvá počas erupcie. Aby sa však dalo určiť, či je aktivita anomálna, musí sa stanoviť základná úroveň bežného správania. Okrem toho sa sopečný nepokoj neprejavuje vždy rovnakým spôsobom, resp. nie vždy vedie k erupcii, a preto by sa táto činnosť mala monitorovať pomocou viacerých techník (Obr. 12.22).



Obr. 12.22 Aktivity vyplývajúce zo sopečného nepokoja a spôsoby ich monitorovania. **Fig. 12.22** Activities arising from volcanic unrest and how to monitor them. Source: left - Poland & Anderson, 2020; right - www.nsta.org/science-scope

V prípade minulých vulkanických erupcií poskytli multidisciplinárne pozemné merania seizmickej aktivity, deformácie pôdy, emisií plynov/aerosolov a tepelných anomálií kľúčové informácie na sledovanie vulkanických nepokojov. Ukázalo sa, že zlepšené prístrojové vybavenie zlepšuje predpovedanie erupcií aj priradenie úrovne výstrahy počas vulkanických krízových situácií. Podľa údajov z roku 2015, pozemné monitorovacie nástroje sú dostupné na menej ako polovici sopiek považovaných za potenciálne aktívne. Spomedzi týchto pozemne monitorovaných sopiek mnohé nemajú dostatok prístrojového vybavenia potrebného na poskytovanie multidisciplinárnych informácií, a to z dôvodu nedostatku zdrojov, nedostatočného prístupu v odľahlých lokalitách a nebezpečenstva spojeného s blízkosťou aktívnej sopky. Zlepšiť monitorovanie je možné využitím dostupných satelitných zdrojov, ktoré môžu poskytnúť informácie o deformácii zeme, emisiách plynov a aerosólov a tepelných anomáliách na všetkých ~ 1400 sopkách.

V rámci aplikácií DPZ existujú tri základné oblasti, kde satelitné dáta umožňujú nahliadnuť do procesov prebiehajúcich vo vulkanickom systéme (Tab. 12.6):

- Emisie SO₂ odrážajú hmotnosť a relatívnu hĺbku uvoľňovania magmy, priepustnosť prívodného komína, a môžu sa použiť na identifikovanie dopĺňania magmy.
- Termálne údaje sa môžu použiť na identifikáciu vulkanogénneho ohrevu, ktorého zmeny súvisia s prederupčnou aktivitou. Počas eurpcie sa termálne dáta môžu použiť na odhad rýchlosti vytekania lávy a v niektorých prípadoch aj na predpovedanie konca efuzívnej erupcie.
- InSAR dáta môžu poskytnúť informácie o deformáciách pred, počas, a po erupcii. Snímky so SAR amplitúdou sú tiež vhodné na hodnotenie zmien morfólogie sopky v čase.

Napriek tomuto potenciálu existujú aj obmedzenia pri využívaní DPZ na štúdium sopiek na globálnej úrovni. Limitné hodnoty pre detekciu vulkanického nepokoja sú obmedzené jeho veľkosťou, priestorovým a temporálnym rozlíšením údajov DPZ, rovnako ako citlivosťou senzora (t.j. schopnosť detegovať nepatrné zmeny nad hodnotami z okolitého pozadia).

Tab. 12.6 Satelitné senzory pre monitorovanie sopečnej činnosti.Tab. 12.6 Satellite sensors for monitoring volcanic activity.Source: Poland & Anderson, 2020

Použitie	Senzor	Označenie
	Infrared Atmospheric Sounding Instrument	IASI
e SO ₂	Total Ozone Mapping Spectrometer	TOMS
Emisi	Total Ozone Mapping Spectrometer-Earth Probe	TOMS_EP
	Ozone Monitoring Instrument	ОМІ
nálne laje	Advanced Spaceborne Thermal Emission and Reflection Radiometer	ASTER
Tern úd	Moderate Resolution Imaging Spectroradiometer	MODIS
	European Remote-Sensing Satellite	ERS-1/ERS-2
	RADARSAT	RSAT-1/RSAT-2
	Advanced Land Observation Satellite	ALOS-1/ALOS-2
nácie	Environmental Satellite	ENVISAT
Deforn	Constellation of Small Satellites for the Mediterranean basin Observation (COSMO)-SkyMed	CSK-1 - CSK-4
	Sentinel	Sentinel-1A / Sentinel-1B
	TerraSAR-X	TSX
	TanDEM-X	TDX

12.6.1. Monitoring volcanic activity using DinSAR and Short

Baseline Subset

Sopka Taal na Filipínach zaznamenala v polovici Januára 2020 veľkú erupciu (Obr. 12.23). Deformácia väčšej kaldery a jej okolia sa analyzovala pomocou diferenciálnej interferometrie SAR (DinSAR) niekoľko dní pred erupciou a po nej. Samostatná analýza deformácie vnútorného kužeľa sopky sa uskutočnila počas šiestich mesiacov tesne pred erupciou v januári 2020. Analýza sa uskutočnila pomocou techniky "*Short Baseline Subset (SBAS)*".

Sopka Taal sa nachádza 50 km od filipínskeho mesta Manila. 12. Januára 2020 došlo k sérii freatických erupcií, sprevádzaných rastúcou seizmickou činnosťou. Sopka Taal je výsledkom poslednej erupčnej fázy komplexnej sopečnej kaldery; ktorá je rozdelená na minimálne dve oblasti. Niektorí odborníci sa domnievajú, že kaldera vznikla v dôsledku jednej udalosti, zatiaľ čo iní odborníci sa domnievajú, že táto komplexná sopečná štruktúra je výsledkom spojenia dvoch dávnych sopečných kalder. Podľa výskumníkov z United States Geological Survey je súčasná morfológia sopky pozostatkom niekoľkých dávnych stratovulkánov. Vo vnútri súčasného krátera sa nachádza malé jazero, ktoré bolo v priebehu storočí modifikované.



Obr. 12.23 Erupcia sopky Taal, Filipíny, január 2020. **Fig. 12.23** Taal volcano (Philippines) eruption in January 2020. Source: Contains modified Copernicus Sentinel data (2020), processed by ESA, CC BY-SA 3.0 IGO; electroverse.net/high-level-eruption-at-taal-volcano-philippines

Vzhľadom na tektonickú zložitosť tejto sopky a rozsiahlu oblasť, ktorú pokrýva sopečná kaldera, boli použité dve techniky diferenciálnej interferometrie. Najprv sa na analýzu väčšej kaldery a jej okolia použila konvenčná technika diferenciálnej interferometrie (DinSAR). Táto analýza sa uskutočnila s použitím dvoch radarových snímok misie Sentinel-1 z 11. a 17. Januára 2020; pred erupciou a po erupcii. Na Obr. 12.24 je znázornený výsledný diferenčný interferogram. Na základe toho bolo možné zistiť dôkazy o raste alebo vyzdvihnutí hlavnej sopečnej kaldery, ktorá ohraničuje aktívnejšiu

časť sopky Taal na ostrove vo vnútri kaldery. Na obrázku je tak isto znázornená poloha epicentier zemetrasení v čase erupcie a oblasti, v korých boli následne vykonané terénne merania a zistené vytvorené zlomy.



Fig. 12.24 Differential interferogram (DinSAR) based on Sentinel-1 images for the period 11-01-2020 to 17-01-2020. Blue points represent seismic epicenters; black triangles represent new faults recorded before, after and during the volcanic eruption phase.

Source: un-spider.org/use-dinsar-and-sbas-monitor-activity-taal-volcano; ©Philippine Institute of Volcanology and Seismology

Taktiež bola vykonaná multitemporálna analýza SBAS (Short Baseline Subset) na kuželi aktívnej sopky vo vnútri kaldery pomocou radarových snímok pokrývajúcich obdobie od júla 2019 do januára 2019. Táto analýza sa vykonala s 18 snímkami Sentinel-1 získanými počas vzostupnej dráhy satelitu. Na odstránenie existujúcej topografie bol použitý digitálny výškový model SRTM (s rozlíšením 90 m). Takto bolo možné zistiť dôkazy o vyzdvihovaní a klesaní počas prederupčnej fázy (Obr. 12.25), čo sú procesy, ktoré možno zistiť v aktívnych sopkách pred ich erupciou.

Deformácie bolo možné detegovať len v niekoľkých oblastiach kužeľa. Vegetačný kryt na celom kuželi bol jedným z faktorov, ktorý bránil koherencii všetkých pixelov na všetkých radarových snímkach. Tento vegetačný kryt obmedzil schopnosť identifikovať ďalšie oblasti, v ktorých došlo k pozitívnej (zdvih) alebo negatívnej (pokles) deformácii. Tieto oblasti, v ktorých nebolo možné zistiť deformáciu, sú na obrázku znázornené pixelmi sivej farby.

12 Applications of RS – Environment and Natural Disasters



Obr. 12.25 Multitemporálna analýza SBAS pre sopku Taal pred erupciou v Januári 2020 na základe snímok Sentinel-1.

Fig. 12.25 Multitemporal SBAS analysis for Taal volcano before eruption in January 2020 based on Sentinel-1 imagery.

Source: un-spider.org/use-dinsar-and-sbas-monitor-activity-taal-volcano; ©Philippine Institute of Volcanology and Seismology

Podobne ako v prípade iných aktívnych sopiek, aj v tomto prípade sa ukázala sila vysokej periodicity opakovaných výstupov zo satelitov Sentinel-1. Táto vysoká periodicita umožňuje, aby sa jej satelitné snímky používali s metodikami DinSAR a SBAS v aplikáciách včasného varovania v prípade sopečnej činnosti.

12.6.2. Satellite monitoring of the volcanic activity of Mount Etna

volcano

Etna sa nachádza na východnom pobreží Sicílie a je jednou z najaktívnejších sopiek na svete. K jej erupciám dochádza na vrchole, kde sa nachádzajú štyri krátery: Voragine a Bocca Nuova, ktoré vznikli v roku 1945, resp. 1928, severovýchodný kráter, najvyšší bod Etny (3330 m.n.m.) a juhovýchodný kráter, ktorý bol v poslednom čase najaktívnejší zo všetkých štyroch.

Od Februára 2021 sa v juhovýchodnom kráteri vytvorila séria intenzívnych lávových fontán (Obr. 12.26). V priebehu nasledujúcich týždňov sopka produkovala lávové fontány siahajúce až do výšky 1,5 km. Tieto explózie patria medzi najvyššie pozorované v juhovýchodnom kráteri za posledné desaťročia. V minulosti boli lávové fontány dosahujúce rovnakú výšku pozorované len v kráteri Voragine v decembri 2015 - s lávovými fontánami vysokými viac ako 2 000 m. Pre monitorovanie prebiehajúcej aktivity v krátery boli spracované snímky misie Copernicus Sentinel-2 a Sentinel-3 s použitím krátkovlnného infračerveného pásma.



Obr. 12.26 Erupcia sopky Etna z 23. Februára 2021. **Fig. 12.26** The eruption of Mount Etna from February 23, 2021. Source: ©contains modified Copernicus Sentinel data (2021), processed by ESA; ©AP Photo/Salvatore Allegra

Atmosférické senzory na satelitoch môžu tiež identifikovať plyny a aerosóly uvoľnené erupciou, ako aj kvantifikovať ich širší vplyv na životné prostredie. Na Obr. 12.27, ktorý zachytila družica Copernicus Sentinel-5P, sú viditeľné koncentrácie oxidu siričitého smerujúce na juh k Líbyi. Oxid siričitý sa uvoľňuje zo sopky, keď je magma relatívne blízko povrchu.

Tyrthenian Sea Hount Etha TUNI SIA LIBYA Sam

12 Applications of RS – Environment and Natural Disasters

Obr. 12.27 Koncentrácia oxidu siričitého z 24. Marca 2021 po vulkanickej aktivite sopky Etna. **Fig. 12.27** Sulphur dioxide concentration from 24 March 2021 after the volcanic activity of Mount Etna.

Source: ©contains modified Copernicus Sentinel data (2021), processed by ESA

Pomocou techník InSAR, aplikovateľných aj na snímky Copernicus Sentinel-1, je možné získať kľúčové informácie na pochopenie toho, ako sa povrch sopky deformuje počas vzostupu, uskladňovania a erupcie magmy. Ako už bolo uvedené, zmeny v deformácii povrchu, ako je klesanie, vydúvanie a stúpanie, sú ukazovateľmi rôznych štádií sopečnej činnosti, ktoré môžu vyústiť do erupcií. Presné monitorovanie deformácie povrchu sopky alebo jej "dýchania" môže viesť k predpovediam erupcií.

Údaje Copernicus Sentinel-1 A a -B sú využívané observatóriom INGV Etna v Katánii na Sicílii pre monitorovanie vývoja deformácií podložia Etny spolu s multiparametrickým monitorovacím systémom INGV (GNSS, náklonomerné a deformačné stanice). Dynamiku tejto sopky charakterizuje superpozícia účinkov pohybov magmy v rámci sopečnej štruktúry (buď vo vrcholových kráteroch, alebo pod úbočiami) a miestnej tektoniky (zlomy a pretrvávajúce pohyby v rámci úbočí). Epizódy lávových fontán, ktoré sa začali 16. Februára 2021, sprevádzala silná deflácia celej sopky, ktorá jednoznačne súvisela s vyvrhnutou magmou (Obr. 12.28).



Obr. 12.28 Interferogram z dát Sentinel-1A a -B zobrazujúci pokles sopky Etna medzi 23. Decembrom 2020 a 27. Februárom 2021.

Fig. 12.28 Interferogram from Sentinel-1A and -B data showing the deflation of Mount Etna between 23 December 2020 and 27 February 2021.

Source: ©Contains modified Copernicus Sentinel data (2021)/ processed by INGV

Medzi ďalšie aplikácie patrí monitorovanie sopečných mrakov na základe optických meraní, od ultrafialového žiarenia až po tepelné infračervené žiarenie. Prítomnosť týchto oblakov v atmosfére ovplyvňuje kvalitu ovzdušia, životné prostredie, klímu, ľudské zdravie a môže byť mimoriadne nebezpečná pre bezpečnosť leteckej dopravy.

Detekcia a vyhľadávanie vulkanických častíc a oxidu siričitého (SO²) sú preto dôležité na zmiernenie rizika, ako aj na získanie poznatkov o mechanizmoch, ktoré spôsobujú erupcie. Najmä tepelné infračervené pásma SLSTR (Sea and Land Surface Temperature Radiometer) sondy Copernicus Sentinel-3 sa môžu využívať na denné aj nočné monitorovanie vulkanického popola a ľadových častíc, zatiaľ čo UV pásma TROPOMI sondy Copernicus Sentinel-5P sa využívajú na získavanie koncentrácie SO².

Na snímke SLSTR (Obr. 12.29) je zobrazená detekcia častíc popola a ľadu, na základe snímky z 7. Marca 2021. Vo vrchnej časti je znázornený rozdiel v teplote jasu - Brightness Temperature Difference (BTD) vypočítaný ako rozdiel medzi teplotami jasu dvoch pásiem SLSTR. Tento postup využíva rozdielnu spektrálnu absorpciu medzi popolom a ľadom, ktorá vedie k záporným, resp. kladným hodnotám BTD v prípade popola a ľadu. V spodnej časti sú znázornené získané početnosti popola (vľavo) a ľadu (vpravo).



12 Applications of RS – Environment and Natural Disasters

Obr. 12.29 Identifikácia popola a ľadu nad sopkou Etna z dát satelitu Sentinel-3. **Fig. 12.29** Identification of ash and ice over Mount Etna from Sentinel-3 data. Source: ©Contains modified Copernicus Sentinel data (2021)/ processed by INGV

Na ďalšom obrázku (Obr. 12.30) je znázornená detekcia údajov o SO² zo senzora TROPOMI Sentinel-5P z niekoľkých sopečných aktivít na Etne. Vysoká citlivosť TROPOMI výrazne zvyšuje možnosť odhaliť predtým nezistiteľný oxid siričitý.



Obr. 12.30 Monitorovanie oxidu siričitého v atmosfére po sopečných aktivitách sopky Etna na základe dát Sentinel-5P.

Fig. 12.30 Monitoring sulphur dioxide in the atmosphere after the volcanic activity of Mount Etna based on Sentinel-5P data.

Source: ©Contains modified Copernicus Sentinel data (2021)/ processed by INGV

12.7. Application of RS for landslide monitoring

V posledných rokoch sa geologické nebezpečenstvá (sutinové prúdy a zosuvy pôdy) stávajú častejšími a škodlivejšími v dôsledku globálnej zmeny klímy, zemetrasení a zrýchlenej urbanizácie. Zosuvy pôdy sú všadeprítomným nebezpečenstvom v suchozemskom prostredí so svahovitým terénom, ktoré si väčšinou vyžiadajú aj ľudské obete v mestských sídlach, pozdĺž dopravných koridorov a v miestach vidieckeho priemyslu. Podľa Globálnej databázy smrteľných zosuvov pôdy (Global Fatal Landslide Database - GFLD) zahynulo v období od januára 2004 do decembra 2016 pri 4862 rôznych zosuvoch pôdy celkovo 55 997 ľudí. Ako je znázornené na Obr. 12.31 a 12.32, priestorové rozloženie zosuvov je jednoznačne heterogénne, pričom dominantnú geografickú oblasť predstavuje Ázia (75 % zosuvov). Značný počet zosuvov sa vyskytuje pozdĺž himalájskeho oblúka, v štátoch naprieč Indiou a JV Čínou, v krajinách Laos, Bangladéš a Mjanmarsko, na ostrovoch ktoré tvoria Indonéziu a Filipíny, a v Turecku, Iráne a v európskych Alpách.



Obr. 12.31 Počet smrteľných zosuvov pôdy vyvolaných inak ako seizmicky medzi rokmi 2004 - 2016. **Fig. 12.31** Number of fatal non-seismically induced landslides between 2004-2016 by country. Source: Froude & Petley, 2018



Obr. 12.32 Počet smrteľných zosuvov pôdy medzi rokmi 2004 – 2016 podľa typu zosuvu. **Fig. 12.32** Number of fatal landslides between 2004-2016 by landslide type. Source: Froude & Petley, 2018; sources: Esri, Garmin, USGS, NPS

Zosuvy pôdy sa vyskytujú v rôznych prostrediach, ktoré sa vyznačujú buď strmým alebo miernym sklonom svahu, od pohorí po pobrežné útesy a dokonca aj pod vodou. Z geologického hľadiska sú známymi príčinami zosuvov zvetrané horniny, puklinové alebo spojené horninové materiály, kontrastné zemné materiály a nízka súdržnosť horniny. Morfologicky všetky formy erózie (ako je riečna, vodná, ľadovcová, a erózia vyvolaná vlnami) pozdĺž svahu môžu spôsobiť zosuvy pôdy a iné typy prúdenia hornín, pričom usadzovanie a zvetrávanie sú tiež hlavnými príčinami zosuvov pôdy. Gravitácia je primárnou hnacou silou zosuvu pôdy. V mnohých prípadoch je zosuv pôdy vyvolaný špecifickou udalosťou (ako sú silné dažde, zemetrasenie, sopečná erupcia, sklon svahu kvôli vybudovaniu cesty alebo iné ľudské aktivity odhaľujúce povrch zeme). Základná klasifikácia zosuvov podľa British Geological Survey (BCS) je uvedená na Obr. 12.32.

Včasné predpovede a varovania sú nevyhnutné pre zníženie škôd na majetku a straty na životoch. Je nevyhnutné dobre porozumieť tomu, čo spôsobuje zosuvy pôdy a ako môžu ľudia buď pomôcť predchádzať ich vzniku, alebo sa im jednoducho vyhnúť, keď už k nim dôjde. Použitím satelitných snímok v kombinácii s údajmi geografického informačného systému a terénnymi štúdiami je možné stanoviť vzťah medzi geomorfologickými podmienkami, v ktorých sa minulé udalosti odohrali, a očakávanými budúcimi podmienkami. Techniky DPZ majú široké uplatnenie na zhromažďovanie údajov o činiteľoch ako je geomorfológia, geológia, využitie krajiny/krajinná pokrývka a hydrogeológia, a môžu tiež pomôcť odhaliť zmeny krajiny, faktory, ktoré spustili zosuv pôdy, a proces regenerácie alebo obnovy. Nástroje GIS sa potom používajú na zhromažďovanie, ukladanie, manipuláciu, zobrazovanie a analýzu týchto rozsiahlych, priestorovo orientovaných údajov, pretože s nimi môžu rýchlo a efektívne pracovať.

Ucelené a kvalitné mapy zosuvov sú jedným z kľúčových prvkov hodnotenia rizika zosuvov. Cieľom detekcie a mapovania zosuvov je určenie polohy, veľkosti, hraníc, dátumu vzniku a typu a ďalších súvisiacich informácií o pohyboch masy, vrátane zdrojovej oblasti a vytlačenej masy. Prvky zosuvu možno identifikovať priamo vizuálnou interpretáciou morfologických foriem (pomocou techník DPZ) alebo nepriamo interpretáciou prvkov na leteckých snímkach alebo satelitných snímkach týkajúcich sa zosuvu (napr. odlišný vegetačný kryt). Časopriestorová analýza globálnych záznamov zosuvov poskytuje dôležité informácie na skúmanie spúšťacích faktorov, analýzu mechanizmov výskytu a predpovedanie časopriestorovej dynamiky zosuvov.



Obr. 12.33 Klasifikácia zosuvov vytvorená British Geological Survey podľa Hungr et al., 2014. **Fig. 12.33** Landslide classification created by the British Geological Survey (by Hungr et al., 2014). Source: Taylor et al., 2018

12.7.1. Landslides in Slovakia

Podľa dokumentu Koncepcia geologického výskumu a geologického prieskumu územia Slovenskej republiky z roku 2017 je potrebné venovať zvýšenú pozornosť svahovým deformáciám s nutným zameriavaním sa hlavne na dlhodobejší monitoring svahových deformácií na najnebezpečnejších lokalitách, kde boli ohrozené životy a zdravie obyvateľov, aby sa získali základné údaje pre potreby sanácie porušených území. Hlavným cieľom podľa tejto koncepcie je sanácia havarijných zosuvov a iných geodynamických javov ohrozujúcich životy, majetok obyvateľov, a majetok štátu a samospráv.

Podľa dokumentu Stratégia adaptácie Slovenskej republiky na nepriaznivé dôsledky zmeny klímy z roku 2018 je hlavným cieľom aktualizovanej adaptačnej stratégie je zvýšenie odolnosti a zlepšenie pripravenosti Slovenskej republiky čeliť nepriaznivým dôsledkom zmeny klímy a ustanovenie inštitucionálneho rámca a koordinačného mechanizmu na zabezpečenie účinnej implementácie adaptačných opatrení na všetkých úrovniach a vo všetkých oblastiach. Z hľadiska adaptácie na nepriaznivé dôsledky zmeny klímy sa za kľúčové oblasti považuje aj horninové prostredie a geológia. Z toho dôvodu bolo navrhnuté, aby boli urbanizované a záujmové územia potenciálne náchylné na svahové pohyby stabilizované, t.j. upraviť tvar svahu, vodný režim (povrchové a hĺbkové odvodnenie zosuvného územia) a zabezpečiť náročné technické stabilizačné opatrenia a vegetačné spevnenia.

Svahové deformácie, ktoré sú najvýznamnejším geologickým hazardom, zaberali v roku 2020 celkovo plochu 2 557,5 km² rozlohy SR. V rámci Čiastkového monitorovacieho systému - Geologické faktory ŽP pokračoval monitoring svahových pohybov na 23 najaktívnejších lokalitách. V rámci Operačného programu Kvalita životného prostredia (OP KŽP) bolo sanovaných 7 lokalít s celkovou rozlohou 91,98 ha. Mapa svahových deformácií SR, spracovaná podľa údajov ŠGÚDŠ, je uvedená na Obr. 12.34.



Obr. 12.34 Mapa svahových deformácií SR. **Fig. 12.34** Map of slope deformations in Slovakia. Source: enviroportal.sk/indicator/detail?id=341

V dôsledku nepriaznivých klimatických pomerov došlo v poslednom desaťročí vo viacerých častiach Slovenska k aktivizácii, resp. reaktivácii viac ako 700 zosuvov, ktoré v mnohých prípadoch priamo ohrozili životy a majetok obyvateľov a vyžiadali si vyhlásenie mimoriadnej situácie. V rámci štátneho Programu monitorovania sa v roku 2020 vykonávalo monitorovanie troch základných typov svahových pohybov – zosúvanie (12 lokalít), plazenie (4 lokality) a náznaky aktivizácie rútivých pohybov (6 lokalít). Samostatnou špecifickou skupinou hodnotenia stability prostredia je lokalita stabilizačného násypu v Handlovej. Na území SR boli v rámci projektu OP KŽP – Monitoring zosuvných deformácií – monitorované i ďalšie socio-ekonomicky významné zosuvné územia. Rozmiestnenie monitorovaných lokalít svahových deformácií je znázornené na Obr. 12.35.



Obr. 12.35 Mapa rozmiestnenia monitorovaných lokalít svahových deformácií na území SR. **Fig. 12.35** Map of the distribution of monitored sites of slope deformations on the territory of SR. Source: enviroportal.sk/indicator/detail?id=341

Na ŠGÚDŠ bol vytvorený informačný systém - Zosuvy a iné svahové deformácie, ktorého databázu v súčasnosti tvorí viac ako 1500 monitorovacích objektov a viac ako 2,5 mil. nameraných údajov na 61 zosuvných lokalitách.

12.7.2. RS technologies for landslide monitoring

Napriek niekoľkým desaťročiam výskumu je detekcia zosuvov stále náročnou úlohou kvôli širokej škále veľkostí, tvarov a morfológií, ktoré tieto udalosti môžu mať, a kvôli variabilite oblastí, kde môžu nastať. V dôsledku toho sa v minulosti testovalo široké spektrum metód DPZ, ktoré sa v poslednom čase kombinujú v rôznych mierkach s použitím multiplatformových metód. Príťažlivosť multiplatformového DPZ – od vesmírnych, vzdušných až po pozemné senzory – pramení v možnosti prekonávať rôzne typy prekážok pri monitorovaní zosuvov (pobrežné zosuvy pôdy, sutinové prúdy v horských oblastiach, padajúce kamene a bahenné prúdy v periglaciálnych prostrediach, a pod.). Okrem toho, možnosť doplňujúcich techník a metód na získavanie údajov v rôznych prostrediach je hlavným prínosom pre štúdie zosuvov so získavaním údajov v reálnom čase, a takmer v reálnom čase pre prakticky akékoľvek miesto na svete, najmä s rastúcim dopytom po podrobných a presných mapách zosuvov a údajov o nich po celom svete. Spomedzi všetkých dostupných metód a údajov však môže byť ťažké vybrať najvhodnejší prístup pre konkrétny typ zosuvu. A výber najvhodnejšieho prístupu môže závisieť od dostupnosti študovaných oblastí, ich geografického kontextu, orientácie (najmä pre satelity), vegetačného krytu, rýchlosti zosuvu pôdy, jeho rozsahu, a ďalších morfologických a geografických parametrov.

Hlavnou výhodou techník DPZ je rozmanitosť ich použitia, a teda aj v rôznych kontextoch monitorovania zosuvov pôdy. DPZ je použiteľné od zosuvov na strmých

svahoch až po subhorizontálne deformácie; od extrémne rýchlych po pomalé pohyby; v nasýtených a nenasýtených materiáloch; v uzavretých strmých kanáloch až po zosuvy na otvorených svahoch. Ďalší zdroj variability pochádza z prostredia, v ktorom sa vyskytujú zosuvy pôdy a s nimi spojené nebezpečenstvá.

Jednou z hlavných hybných síl pozorovania zosuvov je hodnotenie a riadenie rizík nebezpečenstva a katastrof, pre ktoré je nevyhnutné definovať priestorový a časový vývoj zosuvov, najmä ak sa nestabilita vyskytuje v blízkosti sídiel a infraštruktúry (napr. ciest, mostov...) a narúša ekosystémy. Aj jeden prístup DPZ môže byť účinný na zodpovedanie viacerých vedeckých otázok. Techniky DPZ na hodnotenie zosuvov možno klasifikovať podľa rozsahu pozorovania, od vesmírnych technológií - jednotlivé satelity alebo série satelitov, leteckých technológií - lietadlá a drony - až po pozemné a blízke technológie - pozemné laserové skenery - ručné kamery. Množstvo systémov na pozorovanie Zeme (pozemných, leteckých a satelitných) je v súčasnosti natoľko rozvinuté, že je možné vyhodnocovať zosuvy prakticky kdekoľvek na svete, s akoukoľvek frekvenciou, kvantifikovať sezónnosť kinematiky, ako aj dlhodobé zákonitosti pohybu povrchu pomocou techník obrazovej korelácie. Výskumníci a odborníci z praxe tak majú okamžitý prístup k snímkam a dátam.

Za posledných 30 rokov sa vďaka mnohým misiám satelitov na pozorovanie Zeme podarilo zabezpečiť nepretržité archívy optických snímok (napr. Landsat 1-8 ~ 1972, SPOT 1-7 ~ 1986, Ikonos 1999/2015, RapidEye ~ 2008, Sentinel ~ 2014) a radarových snímok (napr. ERS 1991/2001, JERS 1992/1998, Envisat 2002/2012, TerraSAR-X ~ 2008, Sentinel-1 ~ 2014). Satelity na pozorovanie Zeme sa vo veľkej miere využívajú na krízové riadenie a najmä na monitorovanie a hodnotenie zosuvov a s tým súvisiace otázky (napr. identifikácia nebezpečenstva, priestorové vymedzenie rozšírenia, odhad objemu, meranie posunov, a pod.). Záujem o satelitné snímky možno vysvetliť dostupnosťou mnohých údajov s otvorenými zdrojmi s vysokým rozlíšením snímok a pravidelnou aktualizáciou informácií.

Priestorové a spektrálne rozlíšenie satelitných systémov je rôzne. V dôsledku toho bude výber najvhodnejšieho systému na hodnotenie zosuvov do veľkej miery závisieť od vedeckého účelu a požadovaného rozsahu analýzy. Napríklad na evidenciu a detekciu zosuvov je vhodnejšie použiť optické údaje s veľmi vysokým rozlíšením (VHR, 0 - 5 m) a vysokým rozlíšením (5 - 20 m) s možnosťou Pan-sharpeningu alebo vylepšiť historické a nedávne satelitné snímky pomocou algoritmov superrozlíšenia a VHR ortofotosnímok. Na dôkladná evidencia je však niekedy potrebné kombinovať zdroje snímok z dôvodu neúplného priestorového pokrytia, multitemporálnych snímok a historickej evidencie. Cieľom časových radov satelitných snímok je odhaliť príklady zosuvov z minulosti, ktoré môžu byť premodelované antropogénnou činnosťou alebo postupne zakryté vegetáciou. K dispozícii je v súčasnosti množstvo archívov a archívnych dát. Na vizualizáciu a vykonávanie jednoduchých rádiometrických analýz rôznych údajov DPZ je možné bezplatne využívať niekoľko počítačových online platforiem, ako sú Google Earth Engine, Google Earth, platforma EOS pre snímky z pozorovania Zeme, alebo Sentinel Hub. Na týchto platformách je možné zobraziť aj radarové snímky, ktoré majú široké využitie na monitorovanie zosuvov. Na detekciu a kvantifikáciu deformácií povrchu sú totiž radary so syntetickou apertúrou s interferometrickým prístupom (t. j. kozmický InSAR a pozemný InSAR) alebo neinterferometrický prístup s porovnávaním obrazov (GBSAR) užitočnejšie ako analýza optických snímok s 3 pásmami alebo multispektrálnych snímok so 4 až 12 pásmami. Realizovateľnosť tohto postupu však veľmi závisí od orientácie a veľkosti zosuvu. Okrem toho sa na meranie deformácie povrchu bežne používa aj technika offsetu koreláciou panchromatických snímok a snímok s radarovou amplitúdou, ktorá dopĺňa InSAR.
12.7.3. RS data for landslide detection and registration

Pri hodnotení rizík existujú dve hlavné otázky: (1) identifikácia nebezpečenstva a (2) jeho mapovanie. Obe sú nevyhnutné na to, aby sa zabránilo vystaveniu osôb a objektov nebezpečenstvu. V kontexte krízového riadenia je často odhalenie zosuvov pôdy v konkrétnych oblastiach pod časovým tlakom, aby bolo možné pomôcť ľuďom a viesť záchranné operácie. Evidenčné mapy sú užitočným nástrojom pre orgány na riadenie rizík a na získanie poznatkov o rozšírení nebezpečenstva. Väčšinou sú však k dispozícii len pre obmedzené oblasti. Okrem toho by sa takáto evidencia mala pravidelne aktualizovať a dopĺňať o historické databázy, aby sa zohľadnilo geografické rozloženie minulých a nedávnych zosuvov v rôznych časových obdobiach (miesto iniciácie a rozšírenia nebezpečenstva, vek, a pod.). Pravidelná evidencia môže byť tiež komplikovaná a vyžadovať si veľké úsilie, najmä v prípade neprístupných vysokohorských oblastí. Sú však nevyhnutné pre mapovanie náchylnosti na zosuv a zmierňovanie rizík.

Pri evidencii zosuvov založenej na terénnom prieskume je cieľom identifikovať a vymedziť zosuvy, ale terénne prístupy sú časovo náročné a môžu byť prácne a zdĺhavé v prípade veľkých oblastí a najmä vtedy, keď je oblasť neprístupná alebo pokrytá hustou vegetáciou. Okrem toho, na pravidelnú aktualizáciu sú terénne rekognoskačné prístupy takmer nemožné, najmä po výskyte nebezpečenstva vysokej intenzity. Preto sú letecká a satelitná analýza údajov vhodnou alternatívou na skúmanie zosuvov, najmä na veľkých územiach (> 200 km²). Pomocou údajov diaľkového prieskumu Zeme môžu časové sekvencie snímok presne indikovať spektrálne zmeny založené na zmenách fyzikálnych podmienok povrchu a vyvolané spustením zosuvu. Využívanie leteckých a satelitných údajov tak postupne doplnilo terénne prieskumy zjednodušeným získavaním snímok s viacerými rozlíšeniami (multispektrálne alebo panchromatické, radarové) a modelov (digitálny model terénu DTM, digitálny výškový model DEM, digitálny model povrchu DSM) so zvyšujúcim sa stupňom rozlíšenia.

12.7.3.1. Data pre-processing

Príprava dát pozostáva z extrakcie metrických údajov zo satelitných snímok (prípadne aj leteckých) a z DEM. Údaje z predspracovania sú užitočné na:

- identifikáciu zosuvov, evidenciu na základe vizuálnej interpretácie snímok alebo na základe klasifikácie snímok,
- mapovanie náchylnosti na zosuvy s vytvorením geopriestorových údajov na definovanie podmieňujúcich faktorov spustenia zosuvu,
- porovnávanie snímok na charakterizáciu kinematiky zosuvu.

Zdôrazňujú sa dva rôzne typy predbežného spracovania. Jeden, zameraný na rádiometrické informácie na vytvorenie ďalších geopriestorových rastrových vrstiev, je založený najmä na optických satelitných snímkach.

Druhý zohľadňuje priestorové vzťahy pixelov a je zameraný na rádiometrické informácie na vytvorenie ďalších geopriestorových rastrových vrstiev. Táto analýza je založená najmä na optických satelitných snímkach. Druhý typ predbežného spracovania zohľadňuje priestorový vzťah pixelov a je založený najmä na analýze DEM.

Rádiometrická analýza

Rádiometrická analýza optických snímok pozostáva najmä z výpočtov indexov na rozlíšenie plôch pokrytých vegetáciou od odkrytých holých pôd a na zistenie anomálií vo vegetačnom kryte (Obr. 12.36). Na uľahčenie rozlišovania medzi vegetáciou a holou pôdou možno vypočítať niekoľko spektrálnych indexov, ale na modelovanie alebo detekciu zosuvov sa väčšina vedeckých prác, ktoré zohľadňujú rádiometrickú analýzu, spolieha na satelitné snímky na výpočet normalizovaného diferenčného vegetačného indexu (NDVI).



Obr. 12.36 Príklady rádiometrických, priestorových a texturálnych ukazovateľov vypočítaných pre analýzu zosuvov z UAV odvodeného DSM a multispektrálnej snímky (snímka Pléiades, 30. septembra 2017) nad ostrovom Kjúšu (Japonsko). **A** RGB snímka z UAV; **B** RGB snímka Plejády (2 m); **C** panchromaticky zaostrená RGB snímka Plejády (0,5 m); **D** index NDVI; **E** index ATSAVI; **F** index SAVI; **G** lokálny model reliéfu pomocou low-pass filtra; **H** krivosť; **I** otvorenosť priestoru. **Fig. 12.36** Examples of radiometric, spatial, and textural indices calculated for landslide analysis from UAV-derived DSM and multispectral imagery (Pléiades image, 30 September 2017) over Kyushu Island (Japan). **A** RGB UAV image; **B** RGB image of the Pleiades (2 m); **C** panchromatically sharpened RGB image of the Pleiades (0.5 m); **D** NDVI index; **E** ATSAVI index; **F** SAVI index; **G** local relief model using a low-pass filter; **H** curvature; **I** openness of space. Source: Lissak et al., 2020

Priestorová analýza

Priestorová analýza snímok spočíva v štúdiu priestorových vzťahov pixelov na snímke s cieľom získať poznatky o:

- 1. topografických a morfometrických charakteristikách,
- 2. hydrologickom prostredí,
- 3. textúre a drsnosti terénu.

Na získanie poznatkov o geografickom kontexte skúmanej oblasti sa zvyčajne počíta niekoľko vlastností a veličín založených na štatistických metódach a filtrovaní. Z odvodeného DEM sa systematicky počítajú niektoré konvenčné veličiny, ako napríklad sklon, nadmorská výška, zakrivenie. Hlavné informácie o veličinách odvodených z DEM používaných na detekciu zosuvov pomocou topografických metrík zahŕňajú napr. otvorenosť, drsnosť, morfologický sklon, zakrivenie; a pomocou hydromorfologických metrík napr. Stream Power Index SPI na meranie eróznej sily toku, Topographic Wetness Index-TWI na meranie stupňa akumulácie vody v lokalite. Štatistické metódy zamerané na analýzu textúry možno využiť aj na zohľadnenie priestorových vzťahov pixelov a zdôraznenie vlastností reliéfu.

12.7.3.2. Data interpretation

Pod interpretáciou satelitných snímok rozumieme prístupy bežne používané na identifikáciu minulých a nedávnych masových pohybov. Na základe morfologických vlastností krajiny a viditeľných "anomálií" môže byť vizuálna interpretácia snímok rýchlejšia ako pozemný terénny prieskum na identifikáciu zosuvov. Napriek tomu má pozemný prieskum význam v druhom kroku procesu evidencie zosuv pre overenie správnosti interpretácie zo satelitných dát. Kvalita vizuálnej interpretácie však veľmi závisí od zložitosti terénu, vegetačného krytu a od postupov získavania údajov. Použitie výškového modelu získaného pomocou LiDAR technológie pomáha identifikovať nedostatočne pokryté prvky v prípade oblastí s hustou vegetáciou. Ukazovatele odvodené z DEM, ako napr. hodnoty sklonu, aspekt, drsnosť, orientácia, otvorenosť, sa určujú pre zvýraznenie morfologických vlastností vyvolaných zosuvmi a pre extrahovanie hraníc ohrozenia.

12.7.3.3. Application of NDVI

V niektorých špecifických kontextoch môžu byť morfologické zmeny vyvolané spustením zosuvu spojené so zmenami pôdneho krytu. Podľa tvrdenia, že región je charakterizovaný relatívne konzistentnou vegetačnou pokrývkou medzi dvoma rokmi, môže byť riešením na zisťovanie výskytu zosuvov multitemporálny optický prístup DPZ založený na rádiometrickej analýze s hodnotami NDVI. V prípade evidencie veľkých plôch je väčšina štúdií založená na snímkach po zosuve, pretože hlavné zmeny v charakteristike spektrálnej odrazivosti sú spojené s povrchom zosuvového územia. Na systematické časopriestorové mapovanie zosuvov sa zdá byť účinný prístup založený na priebehu hodnôt NDVI v čase. Index NDVI možno generovať v rôznych časových intervaloch (niekoľko dní, počas jedného roka alebo bitemporálne) na identifikáciu zosuvov po udalosti alebo na definovanie modelov vývoja opakovane akívnych zosuvov. Pred spájaním hodnôt NDVI a zosuvu pôdy by sa však mali zohľadniť aj rozdiely vo fenologických stavoch spôsobené sezónnym vývojom vegetačného krytu.

Hodnoty NDVI môžu byť užitočným indikátorom na zisťovanie zosuvov v rôznych prostrediach. Napríklad tundra je vo väčšine oblastí Arktídy charakterizovaná vegetačným krytom. Akékoľvek narušenie prostredia vedie k odstráneniu vegetácie a pôda je potom obnažená. Hromadné pohyby pôdy sú v týchto oblastiach časté, častejšie ako v iných regiónoch sveta (zdokumentovaných bolo niekoľko desiatok tisíc). Ich výskyt je podmienený permafrostom, a preto sú citlivé na zmeny teploty. Očakáva sa, že postupné zvyšovanie priemernej letnej teploty vzduchu v dôsledku zmeny klímy vyvolá špecificky retrogresívne zosuvy v dôsledku topenia. Približne 22 % severnej pologule je na základe nedávneho prehľadu podložených permafrostom. Takéto masové pohyby sú výrazným príkladom potreby postupov automatického mapovania.

12.7.3.4. Identification of landslides using Machine Learning

Identifikácia zosuvov na účely hodnotenia a riadenia rizík je možná prostredníctvom vizuálnej interpretácie údajov z viacerých zdrojov. Hoci je táto technika účinná, je časovo náročná (najmä v prípade veľkých oblastí). V dôsledku toho sa mnohé štúdie zameriavajú na automatizáciu alebo poloautomatizáciu metód detekcie. Na tento účel môžu byť užitočné prístupy strojového učenia (Machine Learning - ML) a hlbokého učenia (Deep Learning - DL). Kým do začiatku roku 2000 sa tieto prístupy na hodnotenie zosuvov využívali len málo, dnes sa vyvíjajú na rôzne aplikácie: predpovedanie spustenia zosuvu, predpovedanie posunu zosuvu, detekcia zosuvu.

Na detekciu zosuvov možno použiť dve základné metódy. Prvou a najčastejšie používanou technikou je snímková analýza založená na pixeloch - Pixel-Based Image Analysis (PBIA). Táto technika považuje obrazové pixely za základné jednotky analýzy. Druhou technikou je snímková analýza založená na objektov - Object-Based Image Analysis (OBIA). Táto technika je založená na vytváraní obrazových objektov alebo segmentov používaných na analýzu snímky.

V metódach založených na pixeloch sa každý pixel klasifikuje bez ohľadu na susedné pixely a všetky pixely sa považujú za navzájom priestorovo nezávislé. V dôsledku toho môžu byť metódy založené na pixeloch citlivé na šum, najmä pri snímkach s veľmi vysokým rozlíšením (VHR). Príklad analýzy zosuvov na základe pixelov je na Obr. 12.37.



Obr. 12.37 Výsledky analýzy zosuvov na základe pixelov pre veľké územie pomocou viacerých klasifikačných algoritmov.

Fig. 12.37 Results of pixel-based image analysis of landslides for a large area using multiple classification algorithms.

Source: Dias et al., 2021

Objektový prístup je dobrou alternatívou na detekciu zosuvov z rôznych zdrojov údajov (ako aj optických údajov s veľmi vysokým rozlíšením). Táto technika je založená na 2 krokoch: segmentácii obrazu (Obr. 12.38) a klasifikácii obrazu (Obr. 12.39). Segmentácia obrazu spočíva v rozdelení rôznych pixelov do skupín na homogénne objekty alebo oblasti, pričom sa zohľadňuje ich podobnosť medzi susedmi. Existuje niekoľko algoritmov segmentácie. Objekty sa spájajú alebo rozlišujú podľa troch parametrov: farby, mierky a tvaru. Pre lepšiu segmentáciu je možné do procesu integrovať apriórne topografické informácie (napr. morfológiu zosuvu z analýzy DEM s lokalizáciou hlavného svahu, nánosov, sekundárnych svahov, a pod.), čo môže výrazne ovplyvniť výsledok segmentácie. Ako vstupné vrstvy na vytvorenie obrazových objektov možno použiť podklady ortofotomáp alebo multispektrálnych snímok, prípadne iné vrstvy (napr. nadmorská výška, sklon, zakrivenie, atď.).

12 Applications of RS – Environment and Natural Disasters



Obr. 12.38 a) lokalizácia zosuvu na RGB snímke; b) výsledok segmentácie snímky. **Fig. 12.38** a) the location of a landslide in the RGB image; b) the result of image segmentation. Source: Amatya et al., 2021



Obr. 12.39 Klasifikácia zosuvov na základe výsledkov segmentácie. **Fig. 12.39** Classification of landslides based on segmentation results. Source: Amatya et al., 2021

Metódy strojového učenia (ML) sú účinné na klasifikáciu snímok a detekciu zosuvov na základe rôznych metód ML a klasifikátorov využívajúcich algoritmy riadenej a neriadenej klasifikácie (pozri Kapitola 5). Automatická detekcia zosuvov pomocou ML závisí od použitého algoritmu, trénovacích vzoriek (pre riadenú klasifikáciu) a validačných údajov. Zatiaľ čo v prístupoch založených na pixeloch sa každému pixelu priradí trieda podľa spektrálnych informácií, v prístupoch založených na objektoch sa každý segment alebo objekt klasifikuje podľa spektrálnych, geometrických, kontextových a texturálnych informácií o objekte na snímke. Všetky uvedené klasifikácie uvedené nižšie sa môžu použiť na riadenú klasifikáciu založenú na pixeloch alebo objektoch. Napriek dobrým výsledkom pri metódach založených na objektoch stále prevládajú metódy založené na pixeloch. Prístupy založené na pixeloch môžu poskytnúť výsledky s niekoľkými nesprávne klasifikovanými pixelmi, najmä pri údajoch s vysokou spektrálnou varianciou v snímkach s vysokým rozlíšením, a ak je klasifikácia zameraná len na spektrálne charakteristiky. Základné metódy a dáta použité pre detekciu zosuvov sú zhrnuté na Obr. 12.40.



Obr. 12.40 Základné typy metód a dát používaných pre detekciu zosuvov. **Fig. 12.40** Basic types of methods and data used for landslide detection. Source: Lissak et al., 2020

Ďalšia skupina klasifikačných algoritmov využíva umelé neurónové siete (ANN). Cieľ spočíva v možnosti ANN s hlbokými vrstvami automaticky vypočítať efektívne priestorové znaky a klasifikovať ich v jednom rámci. Spomedzi ANN poskytuje architektúra hlbokého učenia možnosť spoločne optimalizovať niekoľko súvisiacich úloh, pričom sa uvažuje o viacvrstvovom spracovaní v modeli.

12.7.3.5. SAR and optical cross-correlation for measuring landslide

kinematics

Na kvantifikáciu deformácie povrchu sa radarové snímky s amplitúdou často kombinujú s optickými snímkami. V mnohých geofyzikálnych štúdiách sa ukázalo, že ide o doplnkovú metódu k InSAR. Použitie krížovej korelácie optických satelitných snímok na meranie posunov zemského povrchu prvýkrát koncipoval Robert Crippen (1992) a použil ju na meranie pohybu zosuvov z údajov družice SPOT. Základom metódy je, že satelitné snímky získané v rôznom čase sa môžu prevzorkovať na rovnakú geometriu s použitím DEM. Zvyškové posuny, ktoré zostávajú v rámci prevzorkovaných snímok, môžu byť potom spôsobené pohybom terénu. V rámci poľa posunov môžu určite existovať aj iné (negeofyzikálne) zvyškové skreslenia. Tie môžu byť spôsobené nesprávnym nastavením CCD, chvením satelitu, pohybom snímača pri náklone, sklone a odklone. Teoreticky sa tieto posledné skreslenia dajú modelovať a odstrániť. Posuny sa bežne počítajú diferenciáciou fázy Fourierovej transformácie vypočítanej na podmnožine obrazov pomocou pohyblivého okna. Korelačný vrchol sa potom interpoluje, aby sa dosiahla subpixelová presnosť. Je všeobecne dokázané, že táto metodika môže byť presná až na 1/10 veľkosti pixelu.

V poslednom čase sa na identifikáciu zosuvov vo veľkej miere využíva technika **diferenciálna interferometria SAR** (*DInSAR*). DInSAR vypočítava interferenčný vzor spôsobený fázovým rozdielom medzi dvoma radarovými snímkami získanými v rôznych časoch (Obr. 12.41). Snímky SAR sú ovplyvnené časovou a geometrickou dekoreláciou v dôsledku nesúbežných akvizícií, ktoré sa môžu ľahko vyskytnúť pri monitorovaní

deformácie zosuvov. Okrem toho nie je možné vypočítať reálny fázový rozdiel, ak príslušné pixely na snímkach SAR nemajú dostatočnú hodnotu koherencie. Interferometria s trvalým rozptylom (**Persistent Scatterer Interferometry** - *PSInSAR*) môže tieto obmedzenia prekonať identifikáciou spoľahlivých a stabilných prírodných odrážačov (koherentných cieľov), ktoré sú koherentné počas dlhých časových intervalov a umožňujú sub-milimetrovú presnosť odhadu relatívnej rýchlosti cieľa pozdĺž smeru LOS.





Source: Piroton et al., 2020

Interferometria s trvalým rozptylom (Obr. 12.42 a Obr. 12.43) si vyžaduje veľký súbor snímok SAR získaných nad rovnakou oblasťou. Prostredníctvom vhodných postupov spracovania a analýzy údajov poskytujú lepšie výsledky monitorovania deformácií v porovnaní s výsledkami DInSAR, a to z hľadiska presnosti aj spoľahlivosti.



Obr. 12.42 InSAR zobrazujúci prvotné deformácie vedúce k zosuvu pôdy v Číne v 2017. Fialový polygón vymedzuje oblasť so zrýchľujúci sa trendmi posunov.
Fig. 12.42 InSAR showing the initial deformation leading to a landslide in China in 2017. The purple polygon defines the area with accelerating displacement trends.
Source: Carlà et al., 2019



Obr. 12.43 InSAR Norway - bezplatná a otvorená celoštátna webová mapovacia služba pre údaje InSAR a sledovanie nestabilných svahov.

Fig. 12.43 InSAR Norway - a free and open national web-based mapping service for InSAR data and monitoring of unstable slopes (blogs.egu.eu; insar.ngu.no). Source: blogs.egu.eu; insar.ngu.no

12 Applications of RS – Environment and Natural Disasters

V radarovej oblasti možno na meranie polí posunov zemského povrchu v dôsledku gravitačných pohybov použiť údaje radaru so syntetickou apertúrou SAR spolu s metódou subpixelového offsetu. Vo viacerých štúdiách sa na detekciu pohybu zosuvov ukázala ako užitočná metóda subpixelovej korelácie SAR, označovaná aj ako "offset-tracking" (Obr. 12.44 a Obr. 12.45). Táto metóda využíva informácie o amplitúde SAR signálu. V súčasnosti možno nové generácie optických a radarových satelitov s lepšou časovou frekvenciou použiť spolu s metódou subpixelového offsetu na detekciu rýchlostných polí zosuvov v priestore a analýzu časových radov.



Azimuth offset = 0.7 pixel

Obr. 12.44 Detekcia posunov pomocou metódy offset-tracking; (a) pôvodná poloha pixelu; (b) posun v smere azimutu; (c) posun v šikmom smere.

Fig. 12.44 Displacement detection using the offset-tracking method; (a) original pixel position; (b) offset in azimuth direction; (c) offset in slant range direction. Source: Xu et al., 2020

12 Applications of RS – Environment and Natural Disasters



Obr. 12.45 Výsledok spojenia metód DinSAR a offset-tracking pre monitorovanie poklesov. **Fig. 12.45** Result of combining DinSAR and offset-tracking methods for subsidence monitoring. Source: Xu et al., 2020

12.7.4. Monitoring landslides in the Alps with Sentinel-1

Ľadovec Aletsch, najväčší v Alpách, ustupuje v priemere o 50 m ročne (Obr. 12.46). Priľahlé skalné horniny, ktoré boli predtým obmedzené ľadovou masou, sa postupne uvoľňujú, čím vznikajú svahové nestability. Z tohto dôvodu je región Aletsch jedinečným miestom, kde môžu vedci skúmať, ako zmeny v ľadovci ovplyvňujú dlhodobý a krátkodobý vývoj stability skalných svahov.



Obr. 12.46 (a) ľadovec Aletsch v roku 2017; (b) – (e) Simulácie ústupu ľadovca až do roku 2100. **Fig. 12.46** (a) Aletsch Glacier in 2017; (b) - (e) Glacier retreat simulations up to 2100. Source: Jouvet & Huss, 2019

V roku 2013 boli pri ľadovci umiestnené pozemné prístroje na sledovanie postupných zmien, ku ktorým dochádza na svahu s plochou 2 km² juhovýchodne od ľadovca. V období od septembra do októbra 2016 došlo na svahu k abnormálnemu zrýchleniu. Deformácia vytvorila niekoľko hlbokých trhlín a skalných porúch, ktoré sťažili prístup k turistickým chodníkom navštevovaným turistami a ovplyvnili stanicu lanovky nachádzajúcu sa v blízkosti hrebeňa svahu.

Na ďalšie skúmanie rozsahu zosuvu boli radarové snímky Sentinel-1 z obdobia od augusta do novembra 2016 analyzované pomocou platformy ESA Geohazards Exploitation Platform (GEP) s cieľom vytvoriť mapu rýchlosti nestabilnej oblasti. Satelitné údaje tiež pomohli vedcom definovať najaktívnejšie oblasti a určiť miesta na umiestnenie ďalších prístrojov na zemi (Obr. 12.47).



Obr. 12.47 Deformácie svahu pri ľadovci Aletsch pozorované satelitom Sentinel-1 od Augusta do Novembra 2016. Biele a červené body predstavujú umelé terče na bodové sledovanie pohybu pomocou robotizovaných totálnych staníc (RTS1 a RTS2).

Fig. 12.47 Slope deformation at Aletsch Glacier observed by Sentinel-1 satellite from August to November 2016. The white and red dots represent artificial targets for point motion tracking by robotic total stations (RTS1 and RTS2).

Source: Contains modified Copernicus Sentinel data (2016), processed by Geohazards-TEP

12.7.5. Monitoring landslides in California with Sentinel-1

20 Mája 2017 došlo na časti kalifornskej diaľnice pozdĺž pobrežia Tichého oceánu k zosuvu a zasypaniu cesty viac ako miliónom ton zeminy a skál (Obr. 12.48). Okrem toho, že zosuv zatarasil diaľnicu, tak k pobrežiu sa zosunulo približne 5 hektárov pôdy. Radarové dáta S-1 ukázali, že pôda, ktorá sa zosunula, sa pohybovala už 2 roky pred tým.



Obr. 12.48 Letecká snímka USGS zosuvu v Kalifornii z 27. mája 2017. **Fig. 12.48** USGS air photo of the Mud Creek landslide in California, taken on May 27, 2017. Source: www.weathernationtv.com/news/drought-deluge-turned-stable-california-landslideinto-disaster-in-2017

Radarové údaje boli spracované pomocou Small Baseline Subset interferometrickej metódy, čo je technika umožňujúca odhalenie a monitorovanie pohybov na rozsiahlych územiach s vysokou citlivosťou. Na Obr. 12.49 znázorňujú červené body miesta, v ktorých došlo k pohybu zeme v smere od satelitu s rýchlosťou viac ako 70 mm za rok. Zelené body predstavujú stabilnú pôdu v okolitej oblasti.



Obr. 12.49 Zosuv pôdy na kalifornskej diaľnici monitorovaný pomocou Sentinel-1. **Fig. 12.49** Landslide on California's Highway monitored by Sentinel-1. Source: contains modified Copernicus Sentinel data (2015–17), processed by Norut

12.7.6. Using Sentinel-2 time series to monitor slope movements

Väčšina vedeckých prác bola donedávna zameraná na zisťovanie svahových pohybov pomocou techník SAR, prípadne optický DPZ so snímkami s vysokým priestorovým rozlíšením. Hoci techniky SAR majú schopnosť zisťovať deformácie povrchu v milimetrovom rozsahu, sú účinné pri menších posunoch svahu a často ich ovplyvňujú nepriaznivé podmienky, ako je hustá vegetácia a strmá topografia. Bohužiaľ, mnohé katastrofické zosuvy sa vyskytujú v odľahlých oblastiach pokrytých vegetáciou s veľmi výraznou topografiou (Obr. 12.50) a použitie techník SAR na skúmanie potenciálnych svahových pohybov vo veľkom regióne by bolo náročné až nemožné. V iných prácach monitorujúcich svahové posuny na povrchu zosuvov sa používajú snímky s veľmi vysokým priestorovým rozlíšením. Tieto snímky si vyžadujú veľmi presnú koregistráciu a pri sledovaní pohybu svahu sa spoliehajú na nevegetačné prvky terénu. Okrem toho pokrývajú obmedzenú oblasť a ich použitie na časté pozorovanie vo veľkých regiónoch je veľmi nákladné.



Obr. 12.50 Zosuvy pôdy v odľahlých oblastiach s výraznou topografiou. **Fig. 12.50** Landslide in challenging conditions. Source: Kornei, 2019

Zisťovanie pohybov svahu pred zosuvom pomocou voľne dostupných optických satelitných snímok so stredným až vysokým priestorovým rozlíšením, ako sú súbory údajov Landsat a Sentinel-2, bolo donedávna iba málo používané. Výhodou týchto optických snímok je, že majú viac spektrálnych informácií a sú veľmi citlivé na zachytenie narušenia vegetácie spôsobeného zosuvmi pôdy. V jednej z prvých prác využívajúcich snímky Sentinel-2 bola použitá technika Cosi-Corr na detekciu prekurzorov pred vznikom zosuvu vo francúzskych Alpách. Technika Cosi-Corr porovnáva dve snímky na vytvorenie deformácie pôdy. Vyžaduje, aby oba snímky mali krátky časový interval, aby boli korelované, a aby medzi oboma snímkami došlo k veľkým posunom. Neistoty sa výrazne zvyšujú so zväčšovaním časového intervalu a metóda Cosi-Corr má problémy pri zisťovaní pomalých pohybov počas dlhých období. Príklad svahového zosuvu zachyteného na snímke Sentinel-2 pre odľahlú oblasť v Číne je znázornený na Obr. 12.51.



Obr. 12.51 Sentinel-2 snímky a fotografické snímky zosuvu v Číne; RGB kompozit vo falošných farbách (a) pred zosuvom a (b) po zosuve.

Fig. 12.51 Sentinel-2 images and photographic images of the landslide in China; false colour RGB composite (a) before the landslide and (b) after the landslide. Source: Yang et al., 2019

Na detekciu svahových pohybov zo snímok S-2 je možné aplikovať tri postupy:

- 1. Zostavenie časového radu NDVI a klasifikácia potenciálnych stôp po zosuvoch;
- 2. Určenie prahových hodnôt pre extrakciu týchto stôp zo všetkých snímok S-2;
- 3. Analyzovanie pohybu svahu pomocou stôp identifikovaných po zosuvoch, a pomocou časových radov NDVI snímok (Obr. 12.52).



Obr. 12.52 (a) výsledné zmeny v NDVI zo snímok Sentinel-2; (b) snímka z 30 Júla 2016; (c) snímka z 30 Júla 2017; (d) snímka z 25 Júla 2018.

Fig. 12.52 (a) resulting changes in NDVI from Sentinel-2 imagery; (b) image from 30 July 2016; (c) image from 30 July 2017; (d) image from 25 July 2018. Source: Yang et al., 2019

Túto techniku môže ovplyvniť niekoľko ďalších faktorov, ako je veľkosť zosuvu, podnebie a terénne podmienky. Vzhľadom na priestorové rozlíšenie 10 m ktoré má Sentinel-2, nie je možné zistiť zosuvy menšie ako jeden pixel s rozmermi 10 × 10 m. S týmto rozlíšením je táto technika účinnejšia na monitorovanie veľkých zosuvov. Ak sa vegetácia narušená pohybom svahu obnoví rýchlejšie ako cyklus pozorovania, pre túto techniku by bolo ťažké detegovať svahový pohyb. Napríklad v regiónoch, ktoré sú často pokryté silnou oblačnosťou, snehom alebo inými nepriaznivými podmienkami, by boli použiteľné intervaly pozorovania optických snímok Sentinel-2 oveľa dlhšie. Ak by sa vegetácia narušená pohybom svahu počas dvoch pozorovaní obnovila na úroveň pred narušením, táto technika by mohla zlyhať. Ak je vegetácia príliš hustá (napr. husto zalesnené územie), tak informácia o narušenej vegetácii pohybom svahu môže byť skrytá. V takom prípade by táto technika nemohla byť použiteľná.

Hoci zmeny rastlinných druhov, zmeny pôdneho krytu, dlhodobé trendy zmien vegetácie a iné faktory môžu spôsobiť zmeny vegetácie, ich priestorové a časové zákonitosti sa líšia od zmien spôsobených pohybom svahu pred zosuvom. Zosuvy sú pohyby pôdy po svahu poháňané gravitáciou a tento proces je jedinečný. Zmeny vegetácie spôsobené pohybom svahu úzko súvisia s geomorfnými vlastnosťami.

Application of RS for monitoring the impacts of mining activities

Pre monitorovanie dôsledkov banskej činnosti technikami DPZ pozri Kapitola 9.6.

Applications of RS for monitoring forest fires

Pre monitorovanie požiarov technikami DPZ pozri Kapitola 10.4.

Applications of RS for monitoring floods

Pre monitorovanie povodní technikami DPZ pozri Kapitola 11.4.

Applications of RS for monitoring droughts

Pre monitorovanie sucha technikami DPZ pozri Kapitola 11.5.

References

Books

National Research Council 1999. The Impacts of Natural Disasters: A Framework for Loss Estimation. Washington, DC: The National Academies Press. 81p. DOI: /10.17226/6425.

Gähler, M. (2016). Remote Sensing for Natural or Man-made Disasters and Environmental Changes. In M. Marghany (Ed.), Environmental Applications of Remote Sensing (p. 418). IntechOpen Limited. DOI: 10.5772/62183.

Ray, R., Lazzari, M., & Olutimehin, T. (2020). Remote Sensing Approaches and Related Techniques to Map and Study Landslides. In R. Ray & M. Lazzari (Eds.), Landslides - Investigation and Monitoring (pp. 1–222). IntechOpen Limited. DOI: 10.5772/intechopen.93681.

Barra, A., Monserrat, O., Crosetto, M., Cuevas-Gonzalez, M., Devanthéry, N., Luzi, G., & Crippa, B. (2017). Sentinel-1 Data Analysis for Landslide Detection and Mapping: First Experiences in Italy and Spain. In M. Mikoš, Ž. Arbanas, Y. Yin, & K. Sassa (Eds.), Advancing Culture of Living with Landslides (pp. 1–613). Springer International Publishing AG. DOI 10.1007/978-3-319-53487-9_23.

Papers, manuals, reports

Elliott, J. R. (2020). Earth Observation for the Assessment of Earthquake Hazard, Risk and Disaster Management. Surveys in Geophysics, 41(6), 1323–1354. DOI: 10.1007/s10712-020-09606-4.

Elliott, J. R., Walters, R. J., & Wright, T. J. (2016). The role of space-based observation in understanding and responding to active tectonics and earthquakes. Nature Communications, 7(1), 1–16. DOI: 10.1038/ncomms13844.

Earthquakes from space: Earth observation for quantifying earthquake risks. (2017). International Journal of Remote Sensing, 38(sup1), 80–99. DOI: 10.1080/01431161.2018.1423741.

Elliott, J. R., de Michele, M., & Gupta, H. K. (2020). Earth Observation for Crustal Tectonics and Earthquake Hazards. Surveys in Geophysics, 41(6), 1355–1389. DOI: 10.1007/s10712-020-09608-2.

Poland, M. P., & Anderson, K. R. (2020). Partly Cloudy With a Chance of Lava Flows: Forecasting Volcanic Eruptions in the Twenty-First Century. Journal of Geophysical Research: Solid Earth, 125(1). DOI: 10.1029/2018jb016974.

Froude, M. J., & Petley, D. N. (2018). Global fatal landslide occurrence from 2004 to 2016. Natural Hazards and Earth System Sciences, 18(8), 2161–2181. DOI: 10.5194/nhess-18-2161-2018.

Hungr, O., Leroueil, S., & Picarelli, L. (2014). The Varnes classification of landslide types, an update. Landslides, 11(2), 167–194. DOI: 10.1007/s10346-013-0436-y.

Taylor, F. E., Malamud, B. D., Witt, A., & Guzzetti, F. (2018). Landslide shape, ellipticity and length-to-width ratios. Earth Surface Processes and Landforms, 43(15), 3164–3189. DOI: 10.1002/esp.4479.

Lissak, C., Bartsch, A., De Michele, M., Gomez, C., Maquaire, O., Raucoules, D., & Roulland, T. (2020). Remote Sensing for Assessing Landslides and Associated Hazards. Surveys in Geophysics, 41(6), 1391–1435. DOI: 10.1007/s10712-020-09609-1.

Xu, X., Ma, C., Lian, D., & Zhao, D. (2020). Inversion and Analysis of Mining Subsidence by Integrating DInSAR, Offset Tracking, and PIM Technology. Journal of Sensors, 2020, 1–15. DOI: 10.1155/2020/4136837.

Jouvet, G., & Huss, M. (2019). Future retreat of Great Aletsch Glacier. Journal of Glaciology, 65(253), 869–872. DOI: 10.1017/jog.2019.52.

Piroton, V., Schlögel, R., Barbier, C., & Havenith, H.-B. (2020). Monitoring the Recent Activity of Landslides in the Mailuu-Suu Valley (Kyrgyzstan) Using Radar and Optical Remote Sensing Techniques. Geosciences, 10(5), 164. DOI: 10.3390/geosciences10050164.

Crosetto, M., Monserrat, O., Cuevas-González, M., Devanthéry, N., & Crippa, B. (2016). Persistent Scatterer Interferometry: A review. ISPRS Journal of Photogrammetry and Remote Sensing, 115, 78–89. DOI: 10.1016/j.isprsjprs.2015.10.011.

Chorbanzadeh, O., Didehban, K., Rasouli, H., Kamran, K. V., Feizizadeh, B., & Blaschke, T. (2020). An Application of Sentinel-1, Sentinel-2, and GNSS Data for Landslide Susceptibility Mapping. ISPRS International Journal of Geo-Information, 9(10), 561. DOI: 10.3390/ijgi9100561.

Yang, W., Wang, Y., Sun, S., Wang, Y., & Ma, C. (2019). Using Sentinel-2 time series to detect slope movement before the Jinsha River landslide. Landslides, 16(7), 1313–1324. DOI: 10.1007/s10346-019-01178-8.

Zhong, C., Liu, Y., Gao, P., Chen, W., Li, H., Hou, Y., Nuremanguli, T., & Ma, H. (2019). Landslide mapping with remote sensing: challenges and opportunities. International Journal of Remote Sensing, 41(4), 1555–1581. DOI: 10.1080/01431161.2019.1672904.

Mohan, A., Singh, A. K., Kumar, B., & Dwivedi, R. (2020). Review on remote sensing methods for landslide detection using machine and deep learning. Transactions on Emerging Telecommunications Technologies, 32(7). DOI: 10.1002/ett.3998.

Lacroix, P., Bièvre, G., Pathier, E., Kniess, U., & Jongmans, D. (2018). Use of Sentinel-2 images for the detection of precursory motions before landslide failures. Remote Sensing of Environment, 215, 507–516. DOI: 10.1016/j.rse.2018.03.042.

Pritchard, M. E., Biggs, J., Wauthier, C., Sansosti, E., Arnold, D. W. D., Delgado, F., Ebmeier, S. K., Henderson, S. T., Stephens, K., Cooper, C., Wnuk, K., Amelung, F., Aguilar, V., Mothes, P., Macedo, O., Lara, L. E., Poland, M. P., & Zoffoli, S. (2018). Towards coordinated regional multi-satellite InSAR volcano observations: results from the Latin America pilot project. Journal of Applied Volcanology, 7(1). DOI: 10.1186/s13617-018-0074-0.

Reath, K., Pritchard, M., Poland, M., Delgado, F., Carn, S., Coppola, D., Andrews, B., Ebmeier, S. K., Rumpf, E., Henderson, S., Baker, S., Lundgren, P., Wright, R., Biggs, J., Lopez, T., Wauthier, C., Moruzzi, S., Alcott, A., Wessels, R., & Griswold, J. (2019). Thermal, Deformation, and Degassing Remote Sensing Time Series (CE 2000–2017) at the 47 most Active Volcanoes in Latin America: Implications for Volcanic Systems. Journal of Geophysical Research: Solid Earth, 124(1), 195–218. DOI: 10.1029/2018jb016199.

Dias, H. C., Sandre, L. H., Alarcón, D. A. S., Grohmann, C. H., & Quintanilha, J. A. (2021). Landslide recognition using SVM, Random Forest, and Maximum Likelihood classifiers on high-resolution satellite images: A case study of Itaóca, southeastern Brazil. Brazilian Journal of Geology, 51(4), 1–10. DOI: 10.1590/2317-4889202120200105.

Amatya, P., Kirschbaum, D., Stanley, T., & Tanyas, H. (2021). Landslide mapping using object-based image analysis and open source tools. Engineering Geology, 282, 106000. DOI: 10.1016/j.enggeo.2021.106000.

Carlà, T., Intrieri, E., Raspini, F., Bardi, F., Farina, P., Ferretti, A., Colombo, D., Novali, F., & Casagli, N. (2019). Perspectives on the prediction of catastrophic slope failures from satellite InSAR. Scientific Reports, 9(1). DOI: 10.1038/s41598-019-50792-y.

Kornei, K. (2019). The landslide laboratory. Science, 366(6468), 938–940. DOI: 10.1126/science.366.6468.938

Web sources

www.enviroportal.sk earthdata.nasa.gov www.eos.com www.ncei.noaa.gov/maps/hazards www.gdacs.org activations.emergency.copernicus.eu



WITH THE SUPPORT OF



Earth observation with ESA missions Diaľkový prieskum Zeme misiami ESA

doc. Ing. Katarína Pukanská, PhD., Ing. Karol Bartoš, PhD., Ing. Ľubomír Kseňak, PhD.

> Vydavateľ: © TU v Košiciach, Vydanie: prvé Košice 2022

ISBN 978-80-553-4166-8

ACKNOWLEDGEMEN

"Funded by the Slovak Republic throug an ESA Contract under the PECS (Plan for European Cooperating States) and by grant projects of Ministry of Education of the Slovak Republic VEGA No. 1/0340/22 and KEGA No. 055TUKE-4/2021."

eesa

University textbook Earth Observation with ESA Missions is a textbook written primarily for students of the Faculty of Mining, Ecology, Process Control and Geotechnologies, the Technical University of Košice, in the field of study geodesy and geoinformatics. The textbook reflects the current needs and possibilities of education in these disciplines in higher education studies of the 1st and 2nd level of higher education.

This course has been developed in the framework of the international project entitled University Course Earth Observation with ESA Missions within the framework of the activity Plan for European Cooperating States (PECS) launched by the European Space Agency ESA under the fifth call, Part E - Educational Activities.

The main objective of this course is to teach university students in the field of remote sensing, but more importantly, to get them interested in working in this field. The course curriculum allows students to acquire the latest knowledge in the use of space technologies offered by ESA and prepare them for future professional careers in these fields."

The text of the book is prepared in a combination of Slovak and English, with chapter titles, abstracts and figure titles in English.

