



# Letecký dálkový průzkum Země

teorie a příklady hodnocení  
terestrických ekosystémů

František Zemek a kol.



esf  
european  
social fund in the  
czech republic



EUROPEAN UNION



MINISTRY OF EDUCATION,  
YOUTH AND SPORTS



OP Education  
for Competitiveness

INVESTMENTS IN EDUCATION DEVELOPMENT

**LETECKÝ DÁLKOVÝ PRŮZKUM ZEMĚ  
TEORIE A PŘÍKLADY HODNOCENÍ  
TERESTRICKÝCH EKOSYSTÉMŮ**

FRANTIŠEK ZEMEK a kol.



**Recenzováno**

Siri-Jodha Singh Khalsa, Ph.D., Cires, Univ. of Colorado, Boulder, Colorado,  
USA

**Kolektiv autorů (řazeno abecedně)**

Jakub Brom, Miloš Cibulka, Tomáš Fabiánek, Jan Frouz, Jan Hanuš, Vlastimil Hanzl, Petra Hesslerová, Petr Hlavinka, Lucie Homolová, Růžena Janoutová, Vladimír Jirka, Jan Křen, Petr Lechner, Vojtěch Lukas, Martin Machala, Zbyněk Malenovský, Blahoslav Maršílek, Eliška Maršílková, Tomáš Mikita, Václav Nedbal, Jan Novotný, Marcela Pavlíková, Miroslav Píkl, Marek Pivovarník, Jan Pokorný, Jan Procházka, Fernando Rodriguez Moreno, Daniela Semerádová, Hana Vinciková, Olga Vindušková, František Zemek, Zdeněk Žalud

**Poděkování**

Předložená monografie je výsledkem projektu „Nejnovější technologie dálkového průzkumu Země ve službách výzkumu, vzdělání a aplikací pro rozvoj regionů“, Reg. č. CZ.1.07/2.4.00/31.0213.

**Grafická úprava a sazba** Jan Holešovský

**Obálku navrhla** Lucie Homolová

**Fotografie na obálce** Jan Hanuš

**Jazykové korektury** Jitka Khalsa, Jan Květ

**Knihu vydalo**

Centrum výzkumu globální změny AV ČR, v.v.i.  
Bělidla 986/4a, CZ-60300 Brno, ČR

**Tisk**

[www.knihovnicka.cz](http://www.knihovnicka.cz)

Tribun EU s.r.o., Cejl 892/32, CZ-602 00 Brno, ČR

Vydání první v počtu 150 ks výtisků a 150 CD, 155 stran

© Centrum výzkumu globální změny AV ČR, v.v.i.

ISBN: 978-80-87902-07-3

# **LETECKÝ DÁLKOVÝ PRŮZKUM ZEMĚ**

**TEORIE A PŘÍKLADY HODNOCENÍ  
TERESTRICKÝCH EKOSYSTÉMŮ**

**FRANTIŠEK ZEMEK a kol.**

Centrum výzkumu globální změny  
AV ČR, v.v.i.  
© 2014

# OBSAH

<b>Předmluva</b>	<b>9</b>
<b>Seznam zkratek</b>	<b>11</b>
<b>1 Teoretické základy dálkového průzkumu Země</b>	<b>15</b>
1.1 Historie dálkového průzkumu . . . . .	16
1.2 Základní principy dálkového průzkumu . . . . .	17
1.2.1 Elektromagnetické spektrum . . . . .	17
1.2.2 Zákony záření . . . . .	20
1.2.3 Průchod záření atmosférou . . . . .	22
1.2.4 Interakce záření s objekty zemského povrchu . . . . .	23
1.3 Optické a termální vlastnosti povrchů . . . . .	25
1.4 Principy leteckého DPZ . . . . .	27
<b>2 Hyperspektrální data</b>	<b>35</b>
2.1 Základní charakteristiky hyperspektrálních dat . . . . .	35
2.2 Přehled leteckých hyperspektrálních senzorů . . . . .	36
2.3 Základní předzpracování dat obrazové spektroskopie . . . . .	39
2.3.1 Radiometrické korekce . . . . .	39
2.3.2 Atmosférické korekce . . . . .	40
2.3.3 Geometrické korekce . . . . .	44
2.3.4 Hodnocení kvality provedených korekcí . . . . .	46
<b>3 Termální data</b>	<b>49</b>
3.1 Vlastnosti termálních dat . . . . .	50
3.1.1 Faktory určující tepelné vlastnosti objektu . . . . .	50
3.1.2 Teplotní projev povrchu jako výsledek energetických přeměn	51

3.1.3	Rovnice radiačního přenosu . . . . .	53
3.2	Přehled leteckých termálních přístrojů . . . . .	54
3.3	Korekce a kalibrace termálních dat . . . . .	57
3.3.1	Radiometrická kalibrace . . . . .	57
3.3.2	Atmosférické korekce . . . . .	58
<b>4</b>	<b>Letecké a pozemní laserové skenování</b>	<b>61</b>
4.1	Letecké laserové skenování . . . . .	62
4.1.1	Princip leteckého laserového skenování . . . . .	62
4.1.2	Skenovací parametry a vlastnosti LLS systémů . . . . .	64
4.1.3	Přesnost skenování . . . . .	64
4.2	Přehled leteckých laserových skenerů . . . . .	65
4.3	Pozemní laserové skenování . . . . .	66
4.4	Zpracování dat z leteckého laserového skenování . . . . .	67
4.4.1	Kalibrace . . . . .	67
4.4.2	Vyrovnání řad . . . . .	67
4.4.3	Filtrace a klasifikace . . . . .	68
4.4.4	Aplikace speciálních technik zpracování . . . . .	68
4.5	Digitální výškový model a jeho přesnost . . . . .	69
4.5.1	Definice pojmu . . . . .	69
4.5.2	Digitální výškové modely v České republice . . . . .	69
4.5.3	Posouzení přesnosti DEM . . . . .	70
<b>5</b>	<b>Monitoring kvality vody</b>	<b>73</b>
5.1	Úvod . . . . .	73
5.2	Materiál a metody . . . . .	75
5.2.1	Zájmová oblast . . . . .	75
5.2.2	Měření kvalitativních parametrů vody . . . . .	75
5.2.3	Měření spektrálních dat . . . . .	76
5.2.4	Mapování distribuce fytoplanktonu . . . . .	77
5.3	Výsledky a diskuse . . . . .	78
5.3.1	Spektrální odlišnosti laboratorně měřených vzorků řas a sinic	78
5.3.2	Distribuce řas a sinic ve vodní nádrži Brno . . . . .	78
5.4	Závěr . . . . .	81
<b>6</b>	<b>Mapování substrátů a nově vznikajících půd při rekultivaci výsypků</b>	<b>83</b>
6.1	Úvod . . . . .	83
6.2	Materiál a metodika . . . . .	85
6.2.1	Studované území . . . . .	85
6.2.2	Laboratorní chemické a ekotoxikologické charakteristiky substrátů . . . . .	86
6.2.3	Spektrální data . . . . .	86

6.2.4	Identifikace substrátů z leteckých hyperspektrálních dat . . . . .	87
6.2.5	Charakterizace fosilní organické hmoty pomocí infračervené spektrometrie . . . . .	87
6.3	Výsledky a diskuse . . . . .	88
6.3.1	Vztah laboratorně měřených spektrálních charakteristik jílových substrátů k jejich chemizmu a toxicitě . . . . .	88
6.3.2	Mapování jílových substrátů pomocí leteckých hyperspektrálních snímků a jeho použití k odhadu toxicity . . . . .	89
6.3.3	Můžeme pomocí infračervené spektrometrie odlišit recentní a fosilní organickou hmotu v půdách výsypek? . . . . .	91
6.4	Závěry . . . . .	94
<b>7</b>	<b>Aplikace DPZ v precizním zemědělství</b>	<b>95</b>
7.1	Mapování prostorové variability půdních vlastností . . . . .	97
7.2	Zjištování variability porostů dálkovým průzkumem . . . . .	99
7.3	Případová studie . . . . .	102
7.3.1	Data a metody . . . . .	102
7.3.2	Výsledky a diskuse . . . . .	104
7.4	Závěry . . . . .	107
<b>8</b>	<b>Mapování obsahu chlorofylu v lesních porostech</b>	<b>109</b>
8.1	Úvod . . . . .	109
8.2	Přehled metod DPZ pro odhad chlorofylu . . . . .	110
8.3	Odhad obsahu chlorofylu smrkových porostů z dat DPZ . . . . .	115
8.3.1	Popis lokality a terénních šetření . . . . .	116
8.3.2	Letecké snímkování . . . . .	117
8.3.3	Modely přenosu slunečního záření . . . . .	117
8.3.4	Metody odhadu chlorofylu . . . . .	117
8.3.5	Výsledky a diskuze . . . . .	120
8.4	Závěr . . . . .	123
<b>9</b>	<b>Využití leteckého laserového skenování v lesnictví</b>	<b>125</b>
9.1	Úvod . . . . .	125
9.2	Segmentace a klasifikace porostu . . . . .	127
9.3	Detekce a delineace jednotlivých stromů . . . . .	129
9.4	Určování inventarizačních veličin z dat LLS . . . . .	132
9.5	Výhled do budoucna . . . . .	134
<b>10</b>	<b>Denní dynamika povrchové teploty různých typů krajinného podkladu</b>	<b>137</b>
10.1	Úvod . . . . .	137
10.2	Cíle . . . . .	139
10.3	Metody . . . . .	140

10.3.1 Popis lokalit . . . . .	140
10.3.2 Měření povrchové teploty $T_s$ metodami dálkového průzkumu Země . . . . .	140
10.3.3 Meteorologická data . . . . .	141
10.3.4 Zpracování dat . . . . .	141
10.4 Výsledky a diskuse . . . . .	142
<b>Citovaná literatura</b>	<b>147</b>

# PŘEDMLUVA

Zrychlující se vývoj technologií dálkového průzkumu Země (DPZ) a družicových polohových systémů v posledních desetiletích vytváří mohutný potenciál pro jejich praktické uplatnění v mnoha odvětvích lidské činnosti, jako jsou aplikovaný výzkum, lesnictví, zemědělství, vodní hospodářství, územní plánování, apod. Zároveň se zvyšuje cenová dostupnost kvalitních dat DPZ. Avšak současné využití DPZ v České republice výrazně zaostává za nabízenými možnostmi. Jedním z hlavních důvodů tohoto stavu může být nedostatečné povědomí o tom, jaké vlastně jsou současné možnosti využití DPZ pro jednotlivé obory a koncové uživatele v praxi.

Monografie má být malým příspěvkem k překlenutí mezery mezi odborníky zabývajícími se rozvojem a využitím DPZ a možnými uživateli dat a produktů DPZ v jiných oborech. Cílem je rozšíření znalostní základny pro uplatňování nejnovějších přístupů DPZ v různých disciplínách.

Z velmi širokého rozsahu DPZ se zde dotýkáme jen úzkých, ale přesto snad nejdynamičtěji se rozvíjejících oblastí, spojených se získáváním dat o zemském povrchu z leteckých nosičů. Jsou to obrazová spektroskopie, laserové skenování a obrazová termografie. V kapitolách 1 až 4 představujeme ve velmi omezeném rozsahu základní fyzikální principy, z nichž tyto tři oblasti DPZ vycházejí. Cílem je především uvést čtenáře do teorie a pojmosloví v těchto oblastech. Dalším cílem je naznačit, jak zvolená kombinace dat získaných přístroji pracujícími na odlišných principech může být přínosná pro hodnocení různých aspektů zemského povrchu a jejich synergické účinky. Zatímco spektrální charakteristiky z úzkých pásem obrazové spektroskopie a termografie mohou poskytovat informace o fyzikálních, chemických nebo biochemických vlastnostech entit zemského povrchu, aktivní laserové skenování poskytuje informace o strukturálních a prostorových charakteristických objektů a území. Tato fúze dat a informace může významně přispět k přesnější charakteristice vlastností ekosystémů a možná i odhalení významných

příčinných souvislosti v jejich chování.

Dálkový průzkum Země je sám o sobě velmi interdisciplinární obor a bylo by velmi obtížné vyjmenovat všechny disciplíny, z nichž vychází, stejně tak jako všechny aplikace jeho uplatnění. Proto i tato monografie se vyznačuje interdisciplinárním charakterem. Základ knihy tvoří výsledky projektu, financovaného českým Ministerstvem školství, mládeže a tělovýchovy, s názvem „Nejnovější technologie dálkového průzkumu Země ve výzkumu a vzdělávání“ (zkratka HyDaP). Projekt byl formulován tak, aby se k jeho úspěšnému řešení setkaly dvě skupiny odborníků. První skupinu tvořili specialisté na DPZ z Centra výzkumu globální změny AV ČR. Druhá skupina sestávala z expertů zaměřených na různé aspekty posuzování ekosystémů, bez zkušeností nebo jen s omezenými zkušenostmi s využitím DPZ ve svých oborech. Šlo o odborníky z Biologického centra AV ČR v oboru půdní biologie a ukládání uhlíku v půdách, dále z firmy RAWAT consulting s.r.o. v oboru monitorování kvality vod otevřených vodních nádrží, z Jihočeské university v Českých Budějovicích a ENKI o.p.s. v oblasti tepelného a vodního režimu krajiny, rovněž i z Mendelovy univerzity v Brně v oborech lesnictví a precizního zemědělství. Kolegové z Vysokého učení technického v Brně přispěli v oblasti laserového skenování.

Případové studie v kapitolách 5 až 10 jsou výsledkem praktických aplikací leteckého DPZ ve všech uvedených oborech. Cíleně jsou řazeny podle námi posouzeného stupně složitosti hodnocených ekosystémů, počínaje vodou, přes půdy ke strukturně a funkčně složitějším systémům, jako jsou agroekosystémy, lesy a krajina.

Každou kapitolu také doprovází seznam základní doporučené literatury k danému tématu. Ze všech již zmíněných důvodů může být monografie užitečným zdrojem informací pro různé skupiny lidí, např. studenty začínající s dálkovým průzkumem Země, nebo chtějící vyzkoušet možnosti leteckého DPZ v jiných oborech. Tato druhá skupina může být rozšířena o výzkumné pracovníky a specialisty, kteří sledují a hodnotí různé typy terestrických ekosystémů nebo jejich části, a hledají novou inspiraci k interdisciplinárním přístupům při řešení svých úloh. Například tím, že chtějí rozšířit svá lokální měření a pozorování na rozlehlejší území, anebo jen smysluplně interpolovat bodové informace spojitým polem hodnot z daného území.

K monografii je přiloženo CD obsahující jednak několik souborů předem zpracovaných dat z leteckého hyperspetrálního a laserového skenování, jednak snímky obrazové spektroskopie. Jsou zde zároveň odkazy na software, v němž si může zájemce data otevřít, zjistit jejich povahu, a případně je využít k provedení vlastní úlohy.

**František Zemek**

Centrum výzkumu globální změny, AV ČR, v.v.i.

# SEZNAM ZKRATEK

(Český ekvivalent zkratky, popřípadě její vysvětlení je uvedeno v závorkách)

AAC	Autonomous Atmospheric Compensation (Název algoritmu korigující vliv atmosféry)
ABA	Area Based Approach (Plošně založený přístup odhadu porostních charakteristik)
AISA	Airborne Imaging Spectrometer for Application (Název leteckého obrazového spektrometru)
ANCB <sub>650–720</sub>	Area under continuum-removed curve Normalized to the Chlorophyll absorption Band depth between 650 and 720 nm (Název vegetačního indexu)
ANN	Artificial Neural Networks (Umělá neuronová síť)
APEX	Airborne Prism Experiment (Název leteckého obrazového spektrometru)
ATCOR	Atmospheric and Topographic CORrection (Software pro atmosférické a topografické korekce DPZ dat)
AUC	Area Under Curve (Integrální plocha pod křivkou)
AVIRIS	Airborne Visible InfraRed Imaging Spectrometer (Název leteckého obrazového spektrometru)
BBCH	Biologische Bundesanstalt, Bundesamt für Gartenbau und Chemische Industrie (Mezinárodní zkratka pro vyjádření fenologických fází zemědělských plodin)
BRDF	Bidirectional Reflectance Distribution Function (Distribuční funkce odraznosti v příchozím a odchozím směru paprsku)
C <sub>ab</sub>	Chlorofyl <i>a</i> , <i>b</i>
CAD	Computer-Aided Design (Počítačem podporované projektování)
CASI	Compact Airborne Spectrographic Imager (Název leteckého obrazového spektrometru)
CBD	Continuum removal Band Depth (Hloubka absorpčního pásu)
CHM	Canopy Height Model (Výškový model porostu)
CHRIS	Compact High Resolution Imaging Spectrometer (Název satelitního obrazového spektrometru)
CR	Continuum Removal (Metoda spektrální transformace)

ČÚZK	Český úřad zeměměřičský a katastrální
DART	Discrete Anisotropic Radiative Transfer model (Název modelu radiativního transferu na úrovni porostu)
DBH	Diameter Breast Height (Výčetní tloušťka stromu ve výšce 1,3 m nad zemí)
DEM	Digital Elevation Model (Digitální výškový model)
DLM	Dorsiventral Leaf radiative transfer Model (Název modelu radiativního transferu na úrovni listu)
DLR	Deutsches Zentrum für Luft- und Raumfahrt (Německá kosmická agentura)
DN	Digital Number (Digitální hodnota)
DPZ	Dálkový průzkum Země
DSM	Digital Surface Model (Digitální model povrchu)
DTM	Digital Terrain Model (Digitální model terénu)
EC	Electric Conductivity (Elektrická vodivost)
EM	Electro-Magnetic spectrum (Elektromagnetické spektrum)
EO-1	The Earth Observing-1 mission (Název satelitu)
ESA	European Space Agency (Evropská kosmická agentura)
FLI/PMI	Fluorescence Line Imager/Programmable Multispectral Imager (Název leteckého obrazového spektrometru)
FLIGHT	Forest LIGHT interaction model (Název modelu radiativního transferu na úrovni porostu)
FOH	Fosilní organická hmota
FOV	Field Of View (Zorný úhel senzoru)
FPA	Focal Plane Array (Ohniskové pole)
FTIR	Fourier Transform Infrared (Název termálního senzoru)
FWHM	Full Width Half Maximum (Charakteristika popisující šířku spektrálního pásma)
GCP	Ground Control Point (Vlícovací nebo kontrolní bod)
GIS	Geographic Information System (Geografický informační systém)
GNSS	Global Navigation Satellite System (Globální navigační satelitní systém)
GPS	Global Positioning System (Globální polohový systém)
Chl	Chlorofyl
ICT	Information and Computer Technologies (Informační a počítačové technologie)
IFOV	Instantaneous Field of View (Okamžitý zorný úhel senzoru)
IMU	Inertial Measurement Unit (Inerciální měřící jednotka)
IR	Infra-Red (Infračervené spektrum)
ISAC	In-Scene Atmospheric Corrections (Název algoritmu korigující vliv atmosféry)
ITD	Individual Tree Detection (Detekce jednotlivých stromů)
JPL	Jet Propulsion Laboratory (Název laboratoře NASA)
KIA	Kappa Index of Agreement (Statistický indikátor používaný pro ověření správnosti klasifikace obrazu)
LAI	Leaf Area Index (Index listové plochy)
LEAFMOD	Leaf Experimental Absorptivity Feasibility MODel (Název modelu radiativního transferu na úrovni listu)

LIBERTY	Leaf Incorporating Biochemistry Exhibiting Reflectance and Transmittance Yields (Název modelu radiativního transferu na úrovni listu)
LLS	Letecké laserové skenování
LST	Land Surface Temperature (Povrchová teplota)
LUE	Light Use Efficiency (Účinnost využití slunečního záření)
LUT	Look-Up table (Vyhledávací či kódovací tabulka)
MERIS	Medium Resolution Imaging Spectrometer (Název satelitního obrazového spektrometru)
MIR	Mid Infra-Red (Střední infračervené spektrum)
MODIS	MODerate-resolution Imaging Spectroradiometer (Název satelitního obrazového spektrometru)
MODTRAN	MODerate resolution atmospheric TRANsmission (Název modelu atmosféry)
NASA	National Aeronautics and Space Administration (Národní úřad pro letectví a kosmonautiku USA)
NDVI	Normalized Difference Vegetation Index (Název vegetačního indexu)
NIR	Near Infra-Red (Blízké infračervené spektrum)
OBIA	Object-Based Image Analysis (Objektově založená analýza obrazu)
OSAVI	Optimized Soil-Adjusted Vegetation Index (Název vegetačního indexu)
PARGE	PARametric Geocoding – orthorectification for airborne scanner data (Software pro georeferencování DPZ dat)
Pc	Phycocyanin (Fykocyanin)
PRF	Pulse Repetition Frequency (Frekvence opakování pulzu)
PRI	Photochemical Reflectance Index (Název vegetačního indexu)
PROBA	PRoject for On-Board Autonomy (Název satelitu)
PROSPECT	A model of leaf optical PROPERTIES SPECTra (Název modelu radiativního transferu na úrovni listu)
RAMI	RAdiation transfer Model Intercomparison (Mezinárodní iniciativa porovnávající modely radiativního transferu)
REIP	Red-Edge Inflection Point (Indikátoru odpovídající vlnové délce inflexního bodu spektrální křivky v obvyklém rozmezí mezi 675 a 760 nm)
RMSE	Root Mean Square Error (Střední kvadratická chyba odhadu)
ROI	Region Of Interest (Zájmová oblast)
ROSIS	Reflective Optics System Imaging Spectrometer (Název leteckého obrazového spektrometru)
RPOH	Recentní půdní organická hmota
RTE	Radiative Transfer Equation (Rovnice radiativního transferu)
RTM	Radiative Transfer Model (Model radiativního transferu, tj. model přenosu záření v listu nebo porostu)
SAIL	Scattering by Arbitrarily Inclined Leaves (Název modelu radiativního transferu na úrovni porostu)
SAM	Spectral Angle Mapper (Název metody klasifikace obrazu)
SASI	Shortwave Airborne Spectrographic Imager (Název leteckého obrazového spektrometru)
SLOP	Stochastic model for Leaf Optical Properties (Název modelu radiativního transferu na úrovni listu)

SNR	Signal-to-Noise Ratio (Poměr signálu a šumu)
SPOT	Satellite Pour l'Observation de la Terre (Název satelitu)
SWIR	Short Wave Infra-Red (Krátkovlnné infračervené spektrum)
TCARI	Transformed Chlorophyll Absorption in Reflectance Index (Název vegetačního indexu)
TIR	Thermal Infra-Red (Termální infračervené spektrum)
TWI	Topographic Wetness Index (Topografický vlhkostní index)
UAV	Unmanned Aerial Vehicle (Bezpilotní letoun)
USGS	United States Geological Survey (Název americké vládní vědecko-výzkumné agentury zkoumající přírodní podmínky v USA)
UTM	Universal Transverse Mercator coordinate system (Název souřadnicového systému)
UV	Ultra-Violet (Ultrafialové spektrum)
VI	Vegetační index
VIS	Viditelné spektrum
VNIR	Visible and Near Infra-Red (Viditelné a blízké infračervené spektrum)
WBI	Water Band Index (Název spektrálního indexu)
ZABAGED	Základní báze geografických dat

# 1

## TEORETICKÉ ZÁKLADY DÁLKOVÉHO PRŮZKUMU ZEMĚ

*Lucie Homolová, Marek Pivovarník a František Zemek*

Dálkový průzkum v nejširším slova smyslu můžeme definovat jako sběr informací o objektech zájmu bez přímého kontaktu s nimi. Například oči čtenáře provádí dálkový průzkum ve chvíli, kdy čtou tento text. Přesněji technicky řečeno, oči měří světlo odražené od potištěného papíru a mozek, náš zabudovaný počítač, překládá snímaný obraz na písmena, z nichž skládá slova a věty. V této knize budeme hovořit o dálkovém průzkumu, jako o interdisciplinárním vědecko-technologickém oboru, který se zabývá měřením a analýzou odraženého či vyzářeného elektromagnetické (EM) záření od zemského povrchu. Hlavním úkolem dálkového průzkumu Země (DPZ) je tak odvodit různé vlastnosti zemského povrchu na základě analýz dat odrazivosti či emisivity. Zaměříme se na digitální dálkový průzkum Země z leteckých nosičů, konkrétně na tři technologie: hyperspektrální dálkový průzkum (obrazová spektroskopie), laserové skenování a termální dálkový průzkum (obrazová termografie).

První kapitola představuje teoretické základy DPZ v kostce. Podklady ke kapitole jsou založeny na knihách Lillesand & Kiefer (2000) a Campbell & Wynne (2011). Zájemce o detailnější výklad jednotlivých témat odkazujeme právě na ně.

## 1.1 Historie dálkového průzkumu

Za počátek dálkového průzkumu lze považovat Aristotelův popis jednoduchého optického zařízení ze 4. stol. př. n. l., které vedlo k rozvoji fotografie, tzv „kamera obscura“ (z lat. temná komora). Avšak moderní dějiny DPZ začínají právě až s vynálezem fotografie. První pokusy zaznamenat obraz reality na fotopapír jsou datovány od počátku 19. století. Nicméně ony první, primitivní fotografie byly pořízeny na zemi. Teprve v roce 1858 vzlétl balón Gaspera Felixe Tournachona z něhož byla vyfocena první letecká fotografie Paříže. Vynález letadla v roce 1910 byl dalším zásadním milníkem (přehled viz Tabulka 1.1) v historii DPZ, kdy se fotoaparáty přesunuly na letecké nosiče. Jenom pro zajímavost, snad nejkurióznějším nosičem fotoaparátu byla na začátku 20. století letka cvičených holubů operující na území Německa.

Barevná fotografie byla vyvinuta v 30. letech 20. století a další výrazný rozvoj DPZ technologií pochopitelně souvisel s vojenstvím a dvěma světovými válkami. První přinesla rutinní letecké snímkování sloužící k průzkumu velkých území. Druhá posunula sféru zájmu DPZ za hranice viditelné části elektromagnetického spektra do blízké infračervené (NIR z angl. near infra-red) a mikrovlnné oblasti. Ruku v ruce se závody ve zbrojení mezi Ruskem a USA a jejich vesmírnými programy se dostaly automatické kamery také na oběžnou dráhu Země. Vůbec první fotografie Země z vesmíru byly pořízeny v roce 1964, kdy USA vypustili původně německou balistickou raketu V-2, která nesla i automatickou kameru. První satelitní systémy sbírající data o zemském povrchu na pravidelné bázi fungují od 60. let 20. století. Jednalo se především o meteorologické satelity, např. americký program TIROS z roku 1960 byl v roce 1978 vylepšen a přejmenován na satelity NOAA, které do dnes poskytují data pro předpověď počasí. Propracovanější družicové systémy, které poskytují data v lepším prostorovém i spektrálním rozlišení než meteorologické satelity, jsou v oběhu od 70. let minulého století (např. do dnešní doby fungující program Landsat).

Prvotní obrázky pořízené meteorologickými družicemi nebo během dalších misí pochopitelně vzbudily další zájem o satelitní DPZ a přivedly americkou kosmickou agenturu NASA k přípravě koncepčního řešení v podobě série satelitů monitorujících zdroje surovin (Earth Resources Technology Satellites = ERTS). Tento vesmírný program byl spuštěn v roce 1967 a do dnešní doby zahrnuje osm postupně vypouštěných družic. Po přejmenování v roce 1975 je známější jako program Landsat. První družice Landsatu byla vypuštěna 23. července 1972. V současnosti je na oběžné dráze v provozu poslední satelit této řady, Landsat 8. Multispektrální skenery na palubě Landsatu v současné době poskytují data v panchromatickém a multispektrálním módu (11 spektrálních kanálů) a se středním prostorovým rozlišením (15 až 100 metrů). Data ze série Landsat poskytují unikátní časovou řadu a jsou využívány v řadě vědeckých studií a praktických aplikací (Cohen & Goward, 2004; Hansen & Loveland, 2012).

Obecně můžeme popsat vývoj DPZ technologie v osmdesátých letech minulého

století jako rozkvět na poli satelitních i leteckých systémů snímajících oceány i vnitrozemí, nalézajících uplatnění v meteorologii i mnoha dalších oborech. V osmdesátých letech také započal rozvoj nové technologie, leteckého hyperspektrálního (HS) průzkumu, známého také jako obrazová spektroskopie. První skenery, které dokáží snímat data v desítkách až stovkách spektrálních kanalů, byly k dispozici od přelomu 80. a 90. let a vývoj v této oblasti vedl též k prvním HS snímkům z oběžné dráhy prostřednictvím družicových systémů Hyperion MODIS a MERIS. V současnosti představují hyperspektrální data vrchol technologie pro svou mimořádnou radiometrickou kvalitu a velmi vysoké spektrální rozlišení v řádu jednotek nebo dokonce desetin nanometrů.

Aktivní technologie laserového skenování (LiDAR – z anglického Light Detection And Ranging) je známá od šedesátých let 20. století a pracuje na obdobných principech jako radarové technologie. Nicméně její praktické použití k leteckému mapování struktur na zemském povrchu začalo být myslitelné až na přelomu let 80. a 90. v kontextu vývoje technologií přesné družicové či letecké navigace. První letecké laserové skenery z počátku devadesátých let byly schopné vyslat a přijmout 2 až 25 tisíc pulzů za vteřinu. Z dnešního pohledu je takové množství úsměrně malé, avšak zpracování takto objemných dat stimulovalo vývoj programových nástrojů v prostředí CAD a GIS, které se muselo přizpůsobit práci s velkoobjemovým mračnem bodů. V současnosti existují stovky laserových systémů, které jsou schopny vyslat a přijmout až 400 000 pulzů za vteřinu, zaznamenat několik odrazů v rámci jednoho pulzu nebo dokonce kompletní průběh odražené vlny (Baltsavias, 1999). Problematika laserového skenování je detailněji popsána v Kapitole 4.

Výrazné pokroky v oblasti termálního dálkového průzkumu lze v souvislosti s vývojem nových detektorů rovněž datovat do období druhé světové války. Avšak pro civilní účely byla tato technologie uvolněna až v 60. letech minulého století. První vícekanálový termální skener (TIMS) byl vyvinutý v NASA JPL v 80. letech a termální senzor na družicovém nosiči se poprvé objevil v roce 1978 (Landsat 3). V současnosti jsou připravovány dvě satelitní mise pro globální pokrytí vícekanálovými termálními daty, konkrétně Sentinel-3 Evropské kosmické agentury a americký projekt NASA HyspIRI. Podrobněji se problematikou termálního DPZ zabývá Kapitola 3.

## 1.2 Základní principy dálkového průzkumu

### 1.2.1 Elektromagnetické spektrum

Nejpřirozenějším a každému člověku zjevným zdrojem elektromagnetického (EM) záření je Slunce. Nicméně každý objekt taktéž vyzařuje EM záření, je-li jeho teplota vyšší než absolutní nula. Základní myšlenkou dálkového průzkumu je odvozování vlastností objektů na zemském povrchu právě na základě záznamu jejich odraženého nebo vyzářeného záření.

**Tabulka 1.1** Milníky historie dálkového průzkumu (více na webové stránce <http://www.geog.ucsb.edu/~jeff/115a/remotesensinghistory.html> nebo v Stoney (2005)).

Období	Milníky historie
≈ 1827	Joseph Niepce pořídil z okna první snímek venkovské krajiny, jehož zpracování zabralo 8 hodin práce za plného světla.
1858	Gaspard Felix Tournachon, zvaný „Nadar“ použil horkovzdušný balón, se kterým vystoupal do výšky 80 m a pořídil tak první letecký snímek Paříže.
1858	Skotský fyzik James Clerk Maxwell popsál principy aditivního míchání barev, címž stimuloval pozdější vznik barevné fotografie.
1909	Wilbur Wright pořídil filmařskou kamerou první letecké snímky z letadla nad územím Centocelli v Itálii.
10. léta 20. stol.	První světová válka na čas nastartovala zájem o leteckou fotografii, který po skončení války opět opadl.
20.–30. léta 20. stol.	Objevuje se první nevojenské využití letecké fotografie v lesnictví a zemědělství.
1934	Byla založena americká fotogrammetrická společnost (dnes známá jako Americká společnost fotogrammetrie a dálkového průzkumu) a také poprvé vyšel vědecký časopis Photogrammetric Engineering.
40. léta 20. stol.	Druhá světová válka přinesla dokonalejší techniky zpracování letecké fotografie a také posunula hranice DPZ mimo viditelné spektrum, do blízké infračervené a mikrovlnné oblasti.
1946	Pořízení prvních snímků Země z vesmíru. USA umístily automatické kamery na balistické rakety V-2, které byly po druhé světové válce dovezeny z Německa.
50. léta 20. stol.	Evelyn Pruitt z americké společnosti pro námořní výzkum poprvé použila termín „remote sensing“, dnes již běžně používaný anglický termín pro dálkový průzkum Země.
1960	Americká NASA vypustila na oběžnou dráhu první nevojenský satelit TIROS-1 (Television & Infrared Observation Satellite) sloužící k meteorologickým účelům.
1972	Vypuštění prvního satelitu z programu Landsat, který nesl multispektrální skener a sloužil k monitorování přírodních zdrojů USA.

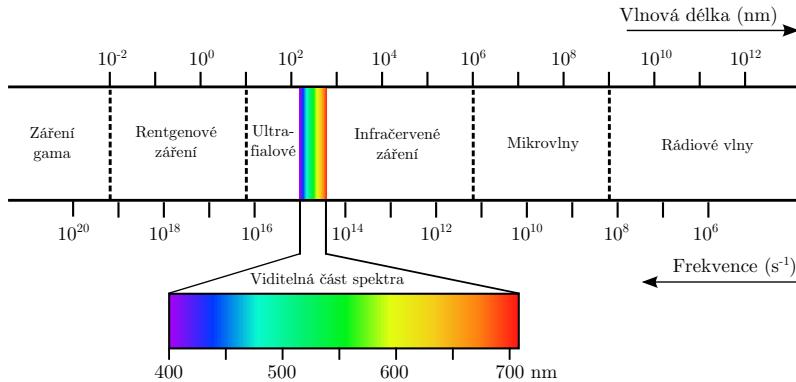
### Pokračování tabulky 1.1

Období	Milníky historie
1977	Na oběžnou dráhu byl vypuštěn Meteosat-1, první z dlouhé řady evropských meteorologických satelitů.
80. léta 20. stol.	Zahájen vývoj hyperspektrálních skenerů.
90. léta 20. stol.	Velký rozvoj DPZ ve všech směrech; byly vypuštěny nové satelity s novými typy skenerů, dochází k rozvoji globálního DPZ a technologií laserového skenování, a v neposlední řadě k rozvoji DPZ přispěla i soukromá sféra.
1995	Vypuštění prvního komerčního satelitu OrbView-1.
1999	NASA spouští globální monitorovací systém Země (Earth Observatory System). První satelit Terra, který je osazen skenery MODIS, ASTER, CERES, MISR a MOPITT, tak poskytuje první globální data o stavu atmosféry, souše i oceánů.
2002	Vypuštění satelitu ENVISAT. Jedná se o největší satelit, který byl vypuštěn Evropskou kosmickou agenturou. Satelit je osazen deseti zařízeními, která poskytují data o stavu atmosféry, souše, oceánů a rozsahu sněhové pokrývky.
2005	Google Inc. spustil mapový server Google Earth, což výrazně přispělo k zvýšení povědomí veřejnosti o potenciálu DPZ pro mnoho aplikací.
10. léta 21. stol.	ESA připravuje sérii pěti satelitů Sentinel v rámci evropského monitorovacího programu Copernicus. První ze série, Sentinel-1 byl uveden na oběžnou dráhu v roce 2014.

Nejznámější částí EM záření je viditelné záření, které představuje velmi důležitou, ale zároveň pouze malou část celého EM spektra (400–700 nm). Pro dálkový průzkum jsou obdobně důležité i ostatní části spektra, jako je blízké infračervené či mikrovlnné záření. Obrázek 1.1 ilustruje základní rozdělení a obvyklé pojmenování jednotlivých oblastí EM spektra. Zde je potřeba zmínit, že vymezení jednotlivých spektrálních oblastí se může lišit v různých aplikačních odvětví.

Typický rozsah vlnových délek prakticky používaných pro dálkový průzkum je od 380 nm po 1 m. Ultrafialová složka záření (UV, 300–380 nm) je v DPZ využívána jen zřídka, neboť tato část záření je silně ovlivněna rozptylem v atmosféře. Pasivní senzory pracují v takzvané odrazové části EM spektra (380–3000 nm), která je podrobněji členěna na část viditelnou (VIS, 400–720 nm), blízkou (NIR, 720–1300 nm) a střední infračervenou (MIR, 1300–3000 nm). Vzdálená infračervená část (3–1000 μm) je odlišná od části odrazivé, neboť v této oblasti

převažuje podíl záření vyzářeného na úkor odraženého záření. Vyzářená infračervená radiace se obvykle nazývá „teplo“ či termální záření. V dálkovém průzkumu označujeme oblast od 8 do 14  $\mu\text{m}$  jako termální infračervené záření (Thermal Infra-Red – TIR). Ještě delší vlnové délky z mikrovlnné oblasti spektra (1 mm až 1 m) jsou používány pasivními a aktivními radarovými systémy, jejichž popis je mimo rámec této knihy.



**Obrázek 1.1** Elektromagnetické spektrum.

### 1.2.2 Zákony záření

Duální vlastnosti elektromagnetického záření popisují dvě fyzikální teorie – teorie vlnová a částicová. Podle vlnové teorie se EM energie šíří prostředím rychlostí světla  $c$  v podobě harmonických sinusových vln. Vzdálenost mezi dvěma po sobě jdoucími maximy nazýváme vlnová délka  $\lambda$ , počet maxim, který projede pevným bodem za jednotku času, nazýváme vlnová frekvence  $\nu$ . Vztah mezi těmito základními parametry EM vlny je následující:

$$c = \nu\lambda. \quad (1.1)$$

Rychlosť světla  $c$  má konstantní hodnotu (přibližně  $3 \cdot 10^8$  metrů za sekundu), mezi frekvencí a vlnovou délkou tedy platí nepřímá úměrnost.

Částicová teorie říká, že elektromagnetické záření je vyzařováno a pohlcováno po diskrétních kvantech, též nazývaných fotony. Max Planck (1858–1947) ukázal, že energie jednoho kvanta je dána rovnicí

$$Q = h\nu, \quad (1.2)$$

kde  $h$  je Planckova konstanta ( $6,626 \cdot 10^{-34}$  J sec) a  $\nu$  je frekvence.

Vlnový a částicový model záření můžeme propojit dosazením  $\nu$  z rovnice (1.1) do rovnice (1.2), čímž získáme

$$Q = \frac{hc}{\lambda}. \quad (1.3)$$

Odtud vidíme, že energie jednoho kvanta  $Q$  klesá s rostoucí vlnovou délkou. Tato vlastnost EM záření je pro dálkový průzkum velmi podstatná. Vysvětuje nám, proč je těžší zaznamenat záření s delší vlnovou délkou (např. mikrovlnné) oproti kratším vlnovým délkat, které nesou vyšší energii.

Množství energie vyzařované objekty je závislé na termodynamické teplotě, přesný vztah je známý jako *Stefan-Boltzmanův zákon*

$$M = \sigma T^4, \quad (1.4)$$

kde  $M$  je celková intenzita záření objektu ( $\text{W m}^{-2}$ ),  $\sigma$  je Stefan-Boltzmanova konstanta ( $5,6697 \cdot 10^{-8} \text{ W m}^{-2} \text{ K}^{-4}$ ),  $T$  je kinetická teplota vyzařujícího objektu (K). Kinetická teplota coby fyzikální vlastnost vyjadřuje množství vnitřní energie objektu (pevného, kapalného či plynného) v souvislosti s pohybem jeho atomů či molekul.

Celkové množství energie vyzářené ideálně vyzařujícím objektem (tzv. „černé těleso“) se mění s kinetickou teplotou a stejně tak vyzářená vlnová délka je funkcí této teploty. Vlnovou délku, při které těleso s danou teplotou vyzařuje nejvíce, udává *Wienův zákon*

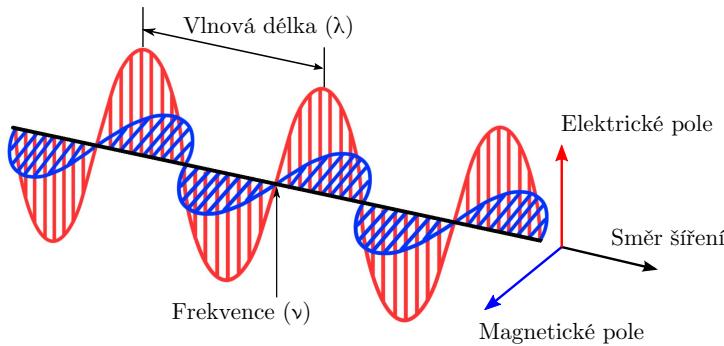
$$\lambda_{max} = \frac{A}{T}, \quad (1.5)$$

kde  $\lambda_{max}$  je vlnová délka s maximálním vyzařováním ( $\mu\text{m}$ ),  $A$  je konstanta s hodnotou  $2898 \mu\text{m K}$ , a  $T$  je kinetická teplota (K). Wienův zákon tedy říká, že vyšší termodynamická teplota znamená kratší vlnovou délku maximálního vyzařování.

Oba výše uvedené principy jsou zahrnutы v Planckově vyzařovacím zákonu (Planck, 1900). Tento zákon předpokládá, že zdroje záření se chovají jako ideální černá tělesa. Černé těleso je teoretický ideální zářič, který absorbuje a znova vyzáří veškerou energii, která na něj dopadne. V přírodě ideální černé těleso neexistuje, ale můžeme jej simulovat v laboratorních podmínkách. Reálná tělesa odráží jen část dopadající energie a vyzařují pouze část energie, kterou by vyzářilo ideální černé těleso se stejnou teplotou. Takový poměr energie nazýváme *emisivita*  $\varepsilon$

$$\varepsilon = \frac{M_{RB}}{M_{BB}} \quad (1.6)$$

kde  $M_{RB}$  a  $M_{BB}$  představují vyzářenou energii reálným a ideálně černým tělesem. Emisivita reálných těles je funkcí vlnové délky, přičemž obecně nabývá hodnot z intervalu (0,1). Emisivita ideálně černého tělesa je rovna 1, emisivita tělesa dokonale odrážejícího všechnu energii je rovna 0. Většina přírodních povrchů má emisivitu mezi 0,85 a 0,99 (Lillesand & Kiefer, 2000).



**Obrázek 1.2** Elektromagnetická vlna má elektrickou a magnetickou složku. Vlnová délka ( $\lambda$ ) je vzdálenost sousedních maxim, frekvence ( $\nu$ ) je dána počtem cyklů za jednotku času v jednom pevném bodě.

### 1.2.3 Průchod záření atmosférou

Všechno záření detekované metodami DPZ, bez ohledu na zdroj, prochází zemskou atmosférou, která výrazně ovlivňuje jeho intenzitu i spektrální složení. Fyzikální procesy, které mění vlastnosti EM záření při průchodu atmosférou, jsou rozptyl a pohlcování (neboli absorpcí) záření.

#### Rozptyl

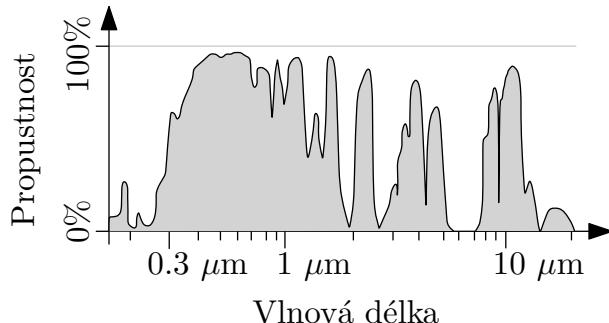
Rozptylem záření v atmosféře rozumíme změnu směru záření při kontaktu s molekulami plynů nebo jinými částicemi přítomnými v atmosféře. Míra rozptylu závisí na velikosti a množství rozptylujících částic, vlnové délce rozptylovaného záření a také na trajektorii průchodu záření atmosférou. Rozlišujeme dva mechanizmy rozptylu, Rayleighův a Mieův, přičemž teorie Mieova je obecnější než teorie Rayleighova.

Rayleighův rozptyl nastane v případě kontaktu záření s molekulami plynů či velmi malými částicemi, jejichž velikost je výrazně menší než vlnová délka záření. To znamená, že záření s kratšími vlnovými délkami je rozptylováno více než záření s delší vlnovou délkou. Například modré světlo je rozptylováno až čtyřikrát silněji než světlo červené, a proto se nám obloha jeví během dne modrá. Při západu a východu slunce záření musí urazit delší dráhu, během níž je rozptyl (a absorpcí) tak výrazné, že pozorujeme pouze méně ovlivněné delší vlnové délky v oranžové a červené části spektra.

Mieův rozptyl nastane v případě kontaktu záření s částicemi srovnatelné velikosti vzhledem k vlnové délce. Takové velikosti dosahují částice prachu, pylu, kouře nebo kapky vody. Pro většinu stavů atmosféry je dominantní mechanismus Rayleighův, nicméně i mechanismus Mieův může výrazně ovlivnit viditelné a blízké infračervené záření.

### Pohlcování

K pohlcování (absorpci) záření dochází v případě, kdy částice obsažené v atmosféře přímo zadrží procházející záření a oslabí tak jeho energii. Absorpce slunečního záření v atmosféře je z velké části způsobena přítomností tří hlavních atmosférických plynů: ozón ( $O_3$ ), oxid uhličitý ( $CO_2$ ) a vodní pára ( $H_2O$ ). Ačkoliv tyto plyny tvoří pouze 3 až 5 % objemu atmosféry, jsou tyto látky zodpovědné za většinu absorpce procházejícího slunečního záření.  $O_3$  pohlcuje krátkovlnné ultrafialové záření (pod 240 nm) a taktéž záření mezi 9 a 10  $\mu m$  v termální oblasti.  $CO_2$  pohlcuje střední a vzdálené infračervené záření (nejvíce mezi 13 a 17,5  $\mu m$ ). Absorpční schopnosti vodní páry jsou několikrát silnější než všech ostatních plynů dohromady. Nejsilnější absorpční pásy vodní páry jsou mezi 1 a 2,5  $\mu m$ , 5,5 a 7  $\mu m$  a nad 27  $\mu m$ . Je zřejmé, že atmosférické plyny snižují průchodnost atmosféry různě pro záření s různou vlnovou délkou. Dalším jevem, ke kterému může docházet, je vyzařování absorbovaného záření v jiných vlnových délkách, což může zejména ovlivnit signál snímaný termálními skenery. Části EM spektra, které jsou minimálně ovlivněny atmosférou, nazýváme atmosférická okna (Obrázek 1.3). Tato okna jsou pochopitelně pro DPZ mimořádně důležitá a de facto jejich existence dálkový průzkum umožňuje. V odrazivé části EM spektra je vliv atmosféry minimální právě mezi 400 a 2500 nm, v termální oblasti pak mezi 8 a 14  $\mu m$ . Proto většina senzorů pracuje právě v těchto spektrálních oblastech.

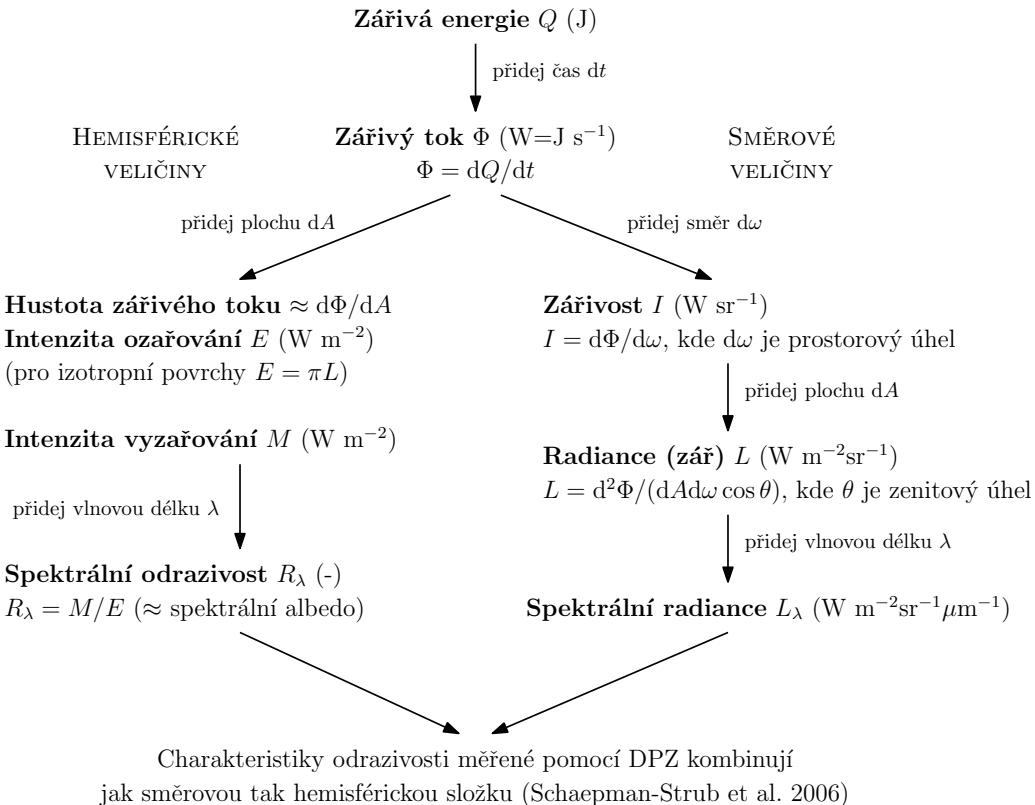


**Obrázek 1.3** Prostupnost atmosféry pro elektromagnetické záření přicházející ze Slunce.

#### 1.2.4 Interakce záření s objekty zemského povrchu

Vzhledem k tomu, že většina systémů DPZ pracuje v odrazivé části EM spektra (tj. 400–2500 nm), budeme v této kapitole dále rozebírat interakci záření a zemského povrchu tak, jak platí právě v této oblasti. Interakce EM záření s objekty zemského povrchu a s atmosférou pro termální oblast je popsána v samostatné části v Kapitole 3.

Nejprve je třeba popsat základní radiometrické veličiny. Přehled nejdůležitějších radiometrických veličin, jejich jednotky a matematická vyjádření jsou shrnutá na Obrázku 1.4. Při interakci záření s povrchem nastávají tři jevy: záření může být



**Obrázek 1.4** Souhrn radiometrických veličin.

pohlceno, propuštěno nebo odraženo. Podle zákona zachování energie je celkový dopadající tok záření ( $E_i$ ) rozdělen na záření odražené ( $E_r$ ), propuštěné ( $E_t$ ) a pohlcené ( $E_a$ ).

$$E_i = E_r + E_t + E_a. \quad (1.7)$$

Vzájemné proporce mezi jednotlivými složkami se liší případ od případu, a závisí na vlnové délce záření, na chemickém složení povrchu a jeho fyzikálních vlastnostech.

Odrazové charakteristiky povrchů určujeme změřením odražené složky dopadajícího záření v jednotlivých vlnových délkách. Z pohledu dálkového průzkumu je navíc velmi důležitá také geometrie odrazu, ovlivněná především drsností povrchu. Ideálně hladký povrch se chová jako zrcadlo, hovoříme o zrcadlovém odrazu; naopak ideálně (homogenně) drsný povrch odráží záření do všech směrů stejně, hovoříme o tzv. lambertiánském odrazu (viz Obrázek 1.5). Většina přirozených povrchů pochopitelně leží někde mezi zrcadlovým a lambertiánským odrazem.

Kompletní charakteristika odrazivosti povrchu je vyjádřena funkcí BRDF (z anglického Bidirectional Reflectance Distribution Function). BRDF představuje teoretický popis geometrické závislosti intenzity odraženého záření na úhlu dopadu a odrazu. Reálná měření DPZ tak neodpovídají teoretickému popisu BRDF

funkce, neboť záření dopadající na detektor je vždy integrováno z relativně širokého zorného úhlu. Proto je třeba mít na paměti, že hodnoty odrazivosti se mohou lišit právě v závislosti na tom, jakým způsobem je zohledněna prostorová distribuce dopadajícího a odraženého záření při výpočtu odrazivosti (více o této problematice viz Schaepman-Strub et al. (2006)).



**Obrázek 1.5** Typy odrazivosti podle prostorové distribuce odraženého záření.

### 1.3 Optické a termální vlastnosti povrchů

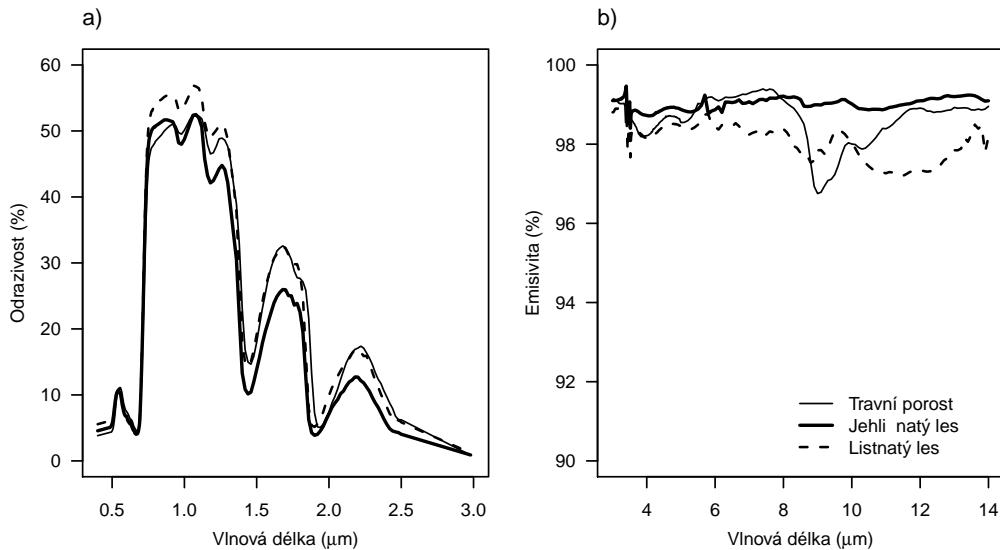
Každý povrch má svým způsobem unikátní spektrální charakteristiku, něco jako otisk lidského prstu. Pomocí spektrální křivky (at' už odraženého či vyzářeného záření) lze od sebe odlišit povrhy, které jsou pouhým okem nerozlišitelné. Lze klasifikovat povrhy s podobnou spektrální odezvou do tematických skupin a podrobou analýzou spektrální křivky lze odvodit některé (bio-)chemické, strukturální či fyzikální vlastnosti zkoumaných povrhů.

V této části představíme spektrální charakteristiky, jak v odrazivé tak termální části EM spektra, pro některé přírodní (vegetace, půda a voda) a umělé povrhy. Všechny spektrální křivky jsou odvozeny ze spektrální knihovny ASTER (<http://speclib.jpl.nasa.gov/>) (Baldridge et al. 2009), která obsahuje na 2000 laboratorně změřených spekter.

#### *Vegetace*

Spektrální křivka odrazivosti vegetace má v oblasti 400 až 3000 nm velmi charakteristický tvar (Obrázek 1.6a). Ve viditelné oblasti je odrazivost ovlivněna především silnou absorpcí rostlinných fotosynteticky aktivních pigmentů jako jsou karotenoidy, xantofily a hlavně chlorofily (ty absorbujují hlavně kolem 450 a 660 nm). Pro blízkou infračervenou část spektra je typický plochý tvar křivky s vysokými hodnotami odrazivosti, která je zejména ovlivňována vnitřní strukturou listu a celkovým usporádáním porostu. Ve střední infračervené oblasti se projevují silné absorpní pásy vody (okolo 1200, 1450, 1940 a 2500 nm) a také další látky obsažené v rostlinách (lignin, celulóza, škrob, proteiny či dusík). V porovnání se spektrální

křivkou odrazivosti, je tvar křivky emisivity v termální oblasti ploší, bez výraznějších absorpčních prvků (Obrázek 1.6b).



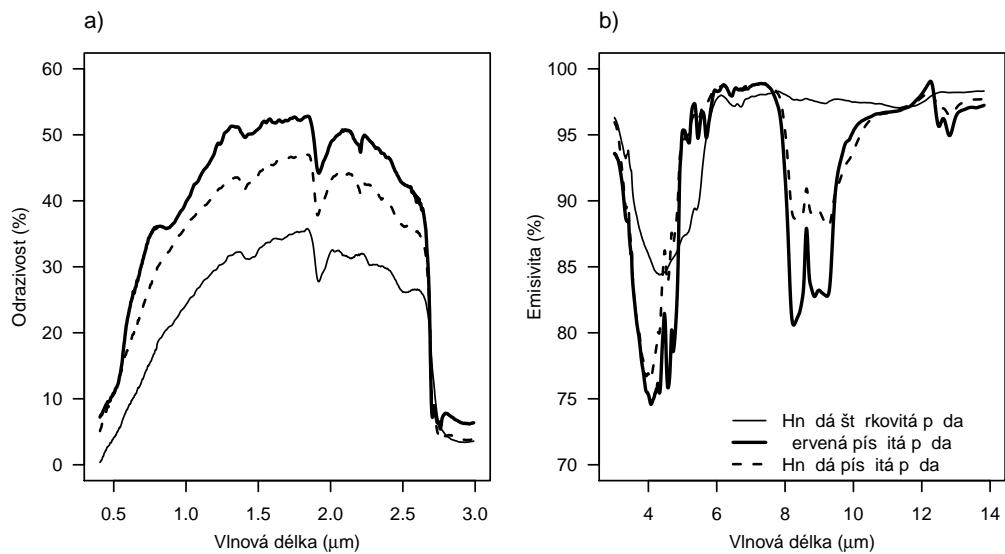
**Obrázek 1.6** Spektrální projev vegetace v (a) odrazivé a (b) termální části elektromagnetického spektra.

### Půda

Spektrální projev půdy je ovlivněn čtyřmi hlavními faktory: minerálním složením, půdní vlhkostí, obsahem organické hmoty a zrnitostí. V odrazivé části spektra (Obrázek 1.7a) hraje významnou roli právě obsah organické hmoty, která, přesáhne-li 2 % v obsahu, sníží celkovou odrazivost a její spektrální odezva tak zamaskuje absorpční pásma obsažených minerálů. Absorpční pásy jednotlivých minerálů se vyskytují především ve střední infračervené oblasti a také dále v termální části spektra. Například projevy absorpce jílovitými minerály, jako je kaolinit nebo montmorillonit, můžeme vidět ve vlnových délkách 2,2 μm a za 2,7 μm. Dalším výrazným faktorem ovlivňujícím spektrální odezvu půdy je půdní vlhkost; její vyšší obsah taktéž snižuje celkovou odrazivost půdy. Nejvízazněji se absorpce vody projevuje ve vlnových délkách 1,4 a 1,9 μm. V termální oblasti (Obrázek 1.7b) můžeme identifikovat výraznou oblast absorpce (7,7–9,7 μm), která odráží přítomnost křemene v půdách.

### Voda

Velmi čistá voda pohltí (případně propustí) převážnou část dopadajícího EM záření a odráží je pouze mírně v modrému pásmu (400–500 nm), proto je křivka odrazivosti téměř plochá a dosahuje minimálních hodnot (Obrázek 1.8a). Nicméně



**Obrázek 1.7** Spektrální projevy půdy v (a) odrazivé a (b) termální části elektromagnetického spektra.

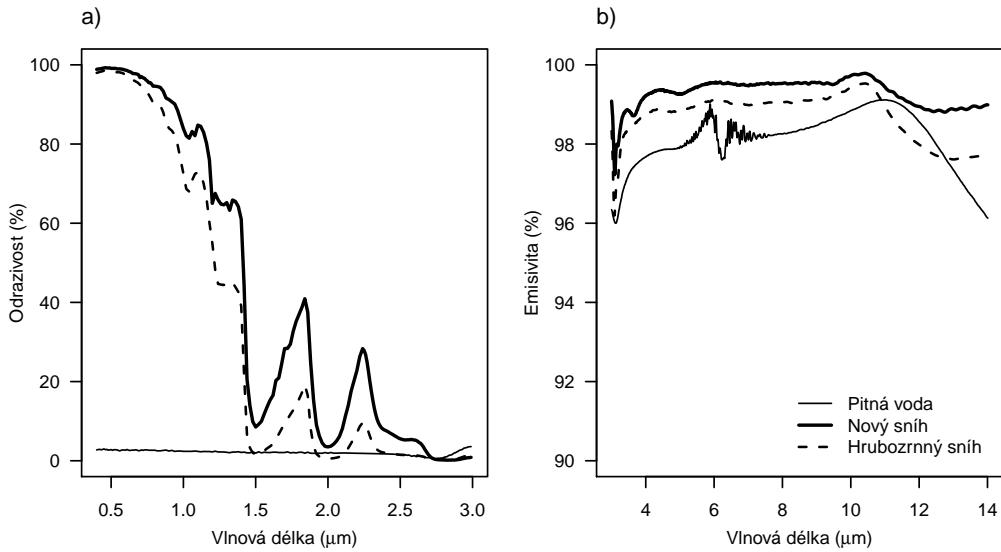
přítomnost rozpuštěných sedimentů, planktonu a vodních rostlin může výrazně změnit odrazivost jak ve viditelných, tak i v infračervených vlnových délkách. Jiné je chování sněhu, který odráží většinu dopadajícího záření ve viditelné oblasti a absorbuje v blízké infračervené oblasti (Obrázek 1.8a). V termální oblasti je většina dopadajícího záření znova vyzářena a spektrální křivka jak vody tak sněhu je bez výraznějších absorpcních pásem (viz Obrázek 1.8b).

### Umělé materiály

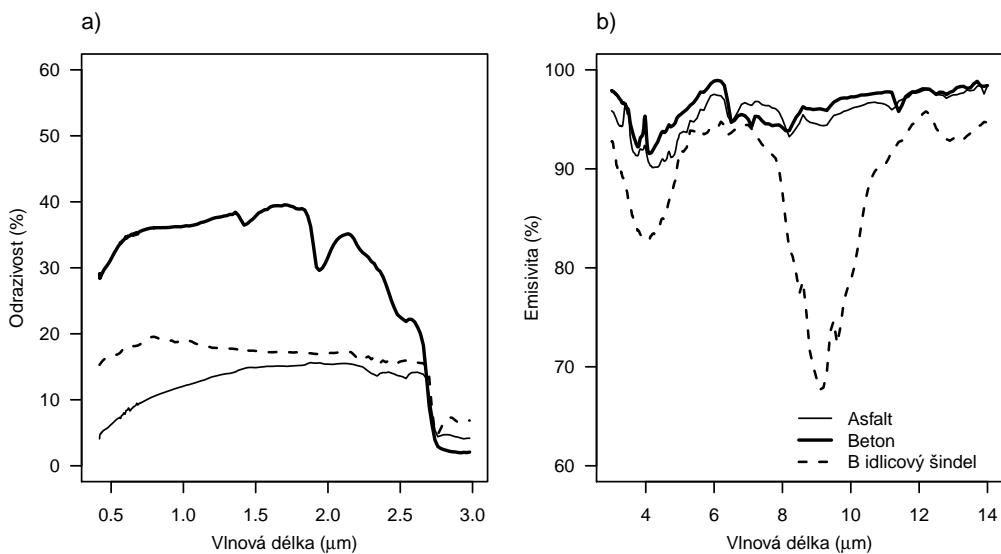
Množství a rozmanitost umělých povrchů je tak velká, že nemůžeme nabídnout spektrálních charakteristiky pro všechny povrhy. Proto jsme vybrali pouze tři běžně dostupné stavební materiály, asfalt, beton a střešní krytinu, jejichž spektrální charakteristiky jsou na Obrázku 1.9. Znalost spektrálních charakteristik umělých povrhů může výrazně přispět ke klasifikaci materiálů a povrhů z multi- či hyperspektrálních snímků zastavěných území.

## 1.4 Principy leteckého DPZ

Dálkový průzkum Země můžeme rozdělit do tří základních kategorií podle toho, jaký typ záření je snímán: 1) odražené a rozptýlené sluneční záření; 2) vyzařování energie z objektů; 3) odražené a rozptýlené záření, které však bylo aktivně vysláno z nějakého zdroje (Obrázek 1.10). V prvních dvou případech hovoříme o tzv. pasivním DPZ, neboť není třeba žádného dalšího zdroje energie než je slunce



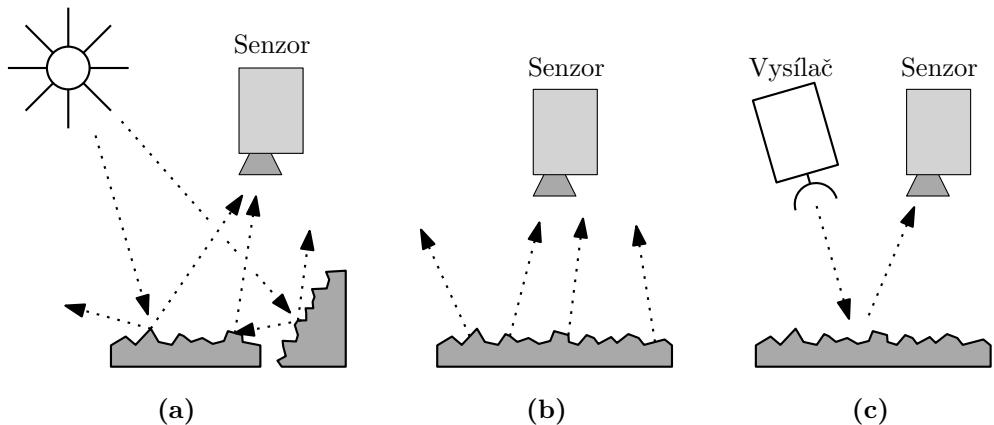
**Obrázek 1.8** Spektrální projev vody a sněhu v (a) odrazivé a (b) termální části elektromagnetického spektra.



**Obrázek 1.9** Spektrální projev umělých povrchů v (a) odrazivé a (b) termální části elektromagnetického spektra.

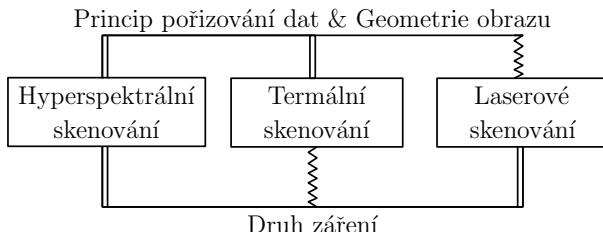
a přirozená energie objektů. V posledním případě hovoříme o tzv. aktivním DPZ, neboť zde je zapotřebí umělého, aktivního zdroje záření (např. laser).

V této knize se budeme zabývat všemi třemi principy snímkování, a to pouze



**Obrázek 1.10** Základní principy DPZ podle typu zaznamenávaného záření: (a) odražené a rozptýlené sluneční záření; (b) vyzařování energie z objektů; (c) odražené záření, které bylo aktivně vysláno z nějakého zdroje.

jenom z leteckých nosičů. V prvním případě letecké spektrometry zaznamenávají odražené sluneční záření ve vlnovém rozsahu 400 až 2500 nm, viz Kapitola 2 – Hyperspektrální data. Ve druhém případě, je energie vyzařovaná zemským povrchem je zaznamenávána leteckým termálním skenerem, viz Kapitola 3 – Termální dálkový průzkum. Ve třetím případě představujeme z aktivních metod technologií laserového skenování, která se od předchozích dvou v základních principech liší (Obrázek 1.11), viz Kapitola 4 – Laserové skenování. Další pasáže této kapitoly jsou zejména aplikovatelné pro hyperspektrální a termální snímkování, méně již pro laserové skenování. Budou vysvětleny pojmy jako prostorové a spektrální rozlišení a představíme nezbytná doprovodná měření k leteckému snímkování.



**Obrázek 1.11** Shodné (dvojitá čára) a odlišné (lomená čára) principy ve srovnání tří základních druhů DPZ (hyperspektrální, termální snímkování vs. laserové skenování).

### Průběh leteckého snímkování

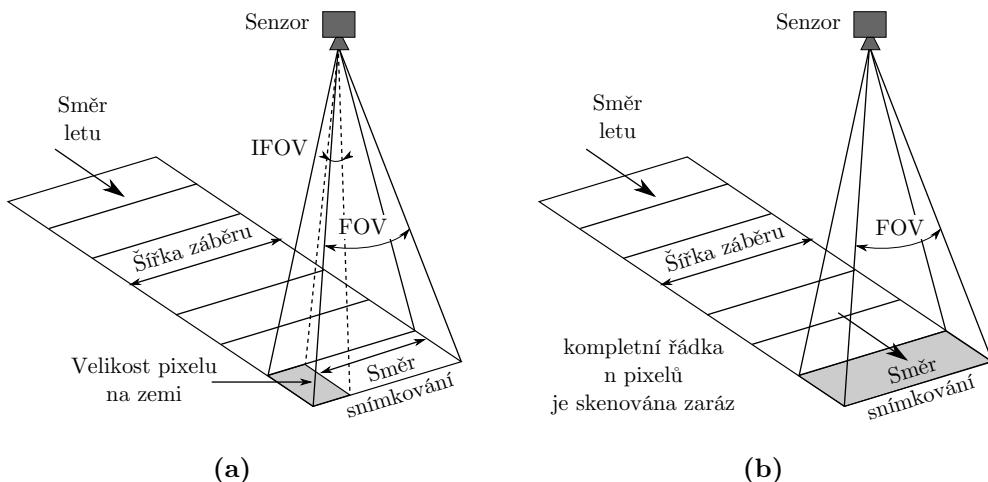
Obrazová data pořízená při leteckém snímkování můžeme chápat jako třírozměrnou matici, dva rozměry odpovídají souřadnicím v rovině a třetí rozměr je osa spektrální (viz Obrázek 2.2). Existují dva základní mechanizmy skenování, jak takovou 3D

datovou strukturu pořídit, rozlišujeme tzv. whiskbroom a pushbroom skenery (Obrázek 1.12).

Whiskbroom skener (Obrázek 1.12a) je elektro-mechanické zařízení, které jednotlivé pixely sbírá v liniích kolmých ke směru letu. Používá k tomu nejčastěji oscilující zrcátko, které přenáší EM záření jednotlivých pixelů linie na detektor. Sběr linií za sebou ve směru letu souvisí s dopředným pohybem letadla. Výhodou takového skenovacího mechanizmu je vyšší spektrální homogenita, neboť každý pixel je pořízen shodným detektorem. Nevýhodou jsou vyšší pořizovací náklady právě mechanického oscilačního zařízení. To se i rychleji se opotřebovává a je náchylné k rezonanci, což může způsobit nežádoucí pruhy v nasnímaných liniích. Příkladem hyperspektrálních whiskbroom skenérů jsou AVIRIS a HyMap.

Pushbroom skener (Obrázek 1.12b) je elektronické zařízení složené z řádky detektorů, které zaznamenají celou příčnou linii najednou. Druhý rozměr obrazových linií je opět vytvořen dopředným pohybem letadla. Výhodou tohoto mechanizmu skenování je silnější signál v každém pixelu umožněný delším integračním časem, tj. dobou, po kterou je EM záření zachycováno detektorem z plochy pixelu. Nevýhodou je to, že řádka detektorů musí být velmi pečlivě zkalirována, abychom dosáhli homogenní spektrální odezvy. Mezi pushbroom spektrometry patří např. AISA, APEX a CASI, analogicky fungují také termální skenery TASI a AISA Owl.

Provoz laserových skenérů se od těch optických výrazně liší. Jsou to systémy aktivní, takže skener sám vypouští EM pulzy a měří čas, za který se vystřelený a od povrchu odražený signál vrátí k snímači skenera. Zároveň jsou zaznamenány charakteristiky tohoto signálu jako jsou intenzita, vlnová délka echa a amplituda. Principy laserového skenování jsou podrobněji vysvětleny v Kapitole 4.



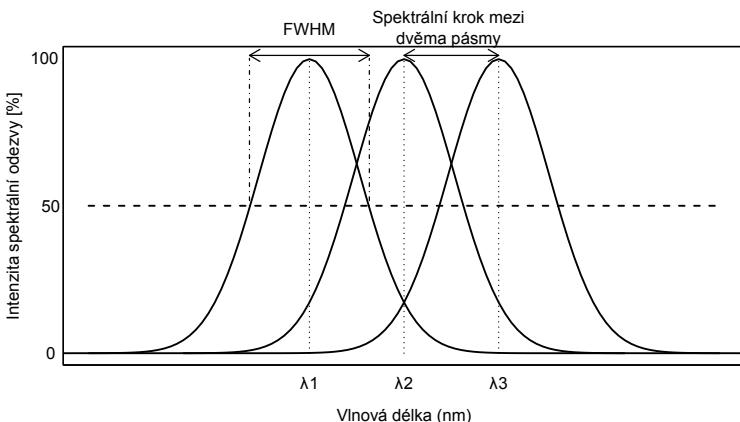
**Obrázek 1.12** Rozdíly mezi mechanizmy skenování – whiskbroom (a) a pushbroom (b) letecký systém. (IFOV – okamžitý úhel záběru, FOV – celkový úhel záběru).

### Rozlišení obrazových DPZ dat

Kvalita a informační obsah dat DPZ vychází z rozlišení snímacího systému. Pod pojmem „rozlišení“ si většina lidí napřed představí pouze rozlišení prostorové, ale u dat DPZ hrají významnou roli také další rozlišení – radiometrické, spektrální a časové.

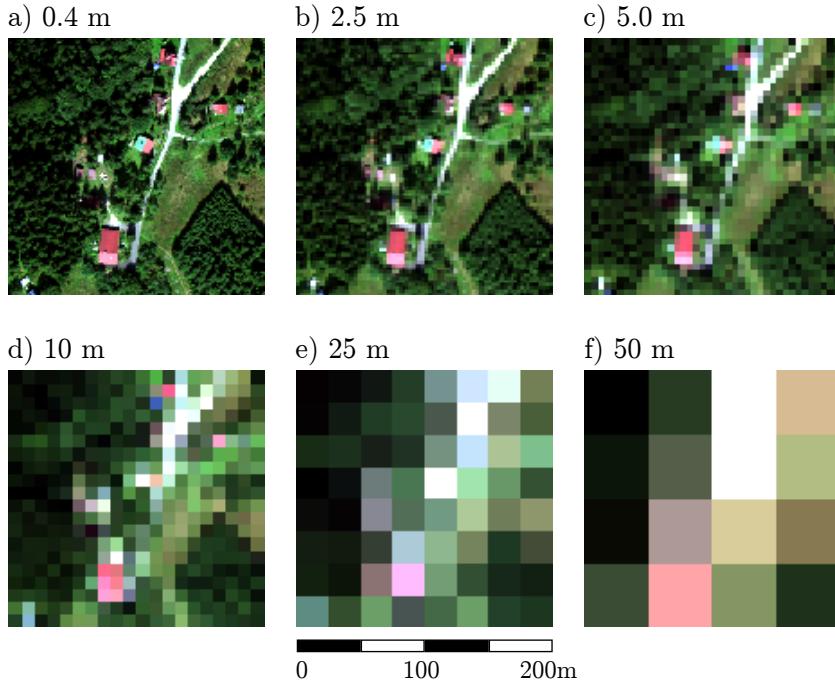
Radiometrické rozlišení určuje nejmenší možnou změnu v intenzitě měřeného signálu, kterou je ještě senzor schopen zaznamenat. Popisuje tedy citlivost senzoru. Skutečné radiometrické rozlišení dat pak dále závisí na poměru signálu k šumu a také na způsobu digitálního kódování, tzn. kolik bitů je používáno k digitalizaci spojité veličiny (intenzity odraženého nebo vyzářeného záření).

Spektrální rozlišení popisuje schopnost senzorů reagovat na změny v záření v různých vlnových délkách. Obvykle jej popisujeme pomocí dvou charakteristik: šírkou jednotlivých spektrálních pásem (FWHM z angl. full width at half maximum) a spektrálním krokem mezi dvěma pásmeny (Obrázek 1.13). Šířku pásma měříme v polovině výšky maximální spektrální odezvy. Spektrální krok je pak vzdálenost mezi maximy spektrální odezvy dvou sousedících spektrálních pásem.



**Obrázek 1.13** Ilustrace pojmu souvisejícího se spektrálním rozlišením DPZ dat – šířka pásma (FWHM) a spektrální krok mezi dvěma pásmeny.

Prostorové rozlišení definujeme jako rozměr nejmenších objektů na zemském povrchu, jejichž hranice dokážeme rozlišit. To primárně závisí na okamžitém úhlu záběru IFOV (z anglického Instantaneous Field of View) senzoru (Obrázek 1.12a). Okamžitý úhel záběru zachycuje část zemského povrchu v zorném poli elementárního prvku detektoru. Prostorové rozlišení samozřejmě závisí také na výšce letu. Může se zdát, že pojmy prostorové rozlišení a velikost pixelu vyjadřují to samé. Avšak obrazová data je možné agregovat do pixelů větších, než je původní prostorové rozlišení, které je určeno právě velikostí IFOV. Proces aggregace prostorových pixelů ilustrujeme na Obrázku 1.14, kde výřez hyperspektrálního snímku měl původní prostorové rozlišení 40 cm a byl následně převzorkován na hrubější velikost pixelu.



**Obrázek 1.14** Změna vizuálního obsahu dat se změnou velikosti pixelu. Původní výřez leteckého snímku s prostorovým rozlišením 0,4 m (a) byl postupně převzorkován pomocí metody aggregace sousedních pixelů (b-f).

Pro úplnost zmiňme i časové rozlišení, které indikuje, jak často je pořízen snímek shodného území. Tato charakteristika dat je důležitá u družicových snímků, ale pro letecký DPZ není tak podstatná.

#### Doplňková měření k leteckému skenování

Každý sběr leteckých dat, ať už jsou hyperspektrální, termální či laserová, je třeba rozšířit o doplňková měření, která probíhají během vlastního náletu. Někdy jsou nezbytná také doprovodná měření v terénu. Tato doplňková data jsou obvykle používána v průběhu předzpracování DPZ či k ověření kvality zpracování. Nejdůležitější měření, které probíhá za letu na palubě letadla, je měření polohy letadla během celého letu pomocí navigačních jednotek IMU a GNSS. Měřena je přesná pozice, výška letu, rychlosť a náklony letadla ve třech osách ve vztahu k ose letu. Tato data jsou následně použita ke geometrickým korekcím a k usazení nasnímaných dat do souřadného systému. Využití navigačních dat v průběhu předzpracování hyperspektrálních snímků je detailněji popsáno v Kapitole 2.3.3.

Jiný druh měření na palubě letadla, který může být velmi užitečný, byť se v praxi provádí méně často, je záznam o změnách atmosférických podmínek během letu. Je možné například měřit úroveň slunečního záření dopadajícího na letadlo a taková doplňková data využít pro zjednodušené atmosférické korekce leteckých

hyperspektrálních dat (Choi & Milton, 2001).

Chceme-li dosáhnout přesnějších korekcí a kalibrací leteckých dat, neobejdeme se bez podpůrných terénních měření. Mezi ně patří změření skutečné odrazivosti vybraných povrchů, zaměření přesné geometrické pozice vybraných kontrolních bodů a záznam lokálních atmosférických podmínek, vše pořízeno současně s přeletem nebo v čase co nejbližším. Ukázka jednotlivých typů doplňkových pozemních měření je na Obrázku 1.15.

Pozemní měření odrazivosti či emisivity vhodných přírodních či umělých povrchů má při zpracování snímků leteckého DPZ dvojí využití. V prvním případě mohou tato spektra sloužit k zpřesnění korekcí odstraňující vliv atmosféry (viz. Kapitola 2.3.2). V druhé případě mohou sloužit k ohodnocení kvality atmosférických korekcí. Spektrální charakteristiky odrazivosti měříme polními spektrometry, mezi nejpoužívanější patří modelová řada FieldSpec od firmy ASD Inc. (Obrázek 1.15a) nebo přístroje firem Spectra Vista Corporation a Ocean Optics. K terénnímu šetření vybíráme povrchy, které jsou: 1) spektrálně homogenní; 2) dostatečně velké, aby byly rozeznatelné v leteckých datech; 3) reprezentativní s ohledem na jasový gradient v našem zájmovém území (změřen by měl být minimálně jeden světlý a jeden tmavý povrch); 4) blízké lambertiánským s vynormovanou spektrální křivkou. V případě zájmu o problematiku spektrálních měření v terénu odkazujeme na Milton (2009) a McCoy (2004).



(a)



(b)



(c)

**Obrázek 1.15** Podpůrná pozemní měření (a) odrazivosti povrchů (ASD Field Spec-3), (b) pozice kontrolních bodů (TOPCON), (c) obsahu aerosolů a vodní páry v atmosféře (Microtops II).

Taktéž zaměřování pozice kontrolních bodů (GCP z anglického Ground Control Points) pomocí systému GNSS má dvojí využití při zpracování dat leteckého DPZ. Zaprvé mohou sloužit ke zpřesnění georeferencování leteckých snímků. Za-

druhé můžeme na jejich základě posoudit přesnost provedené geometrické korekce, například vypočteme-li směrodatnou odchylku mezi skutečnou polohou kontrolních bodů a jejich vypočtenou polohou v georeferencovaném obraze. Kontrolní body proto musí být v obraze snadno identifikovatelné, optimální jsou křížovatky silnic, hranice budov či pozemků apod. GCP body volíme tak, aby rovnoměrně pokrývaly celé zájmové území. Toto je nutné dodržet především tehdy, chceme-li použít pro geometrickou transformaci polynom vyššího stupně a přitom se vyhnout extrapolacím.

Pro důkladnou atmosférickou korekci hyperspektrálních i termálních dat je velmi užitečné znát podrobný stav atmosféry v místě a době náletu (Richter & Schlapfer, 2002). Nejčastěji se k tomuto účelu používají tzv. „sun photometry“, které měří absorpci atmosféry v několika vybraných spektrálních pásmech, z čehož se následně odvodí optická tloušťka aerosolů a obsah vodní páry. Příkladem jsou přístroje Microtops II (Solar Light Company, USA, Obrázek 1.15c) a Cimel (Cimel Electronique S.A.S, Fr).

### Doporučená literatura

- Campbell, J.B. & Wynne, R.H. 2011. *Introduction to remote sensing (5<sup>th</sup> edition)*. The Guilford Press, 72 Spring Street, New York NY 10012.
- Lillesand, T.M. & Kiefer, R.W. 2000. *Remote Sensing and Image Interpretation (4<sup>th</sup> edition)*. John Wiley & Sons, Inc., New York.
- Rees, W.G. 2012. *Physical Principles of Remote Sensing (3<sup>rd</sup> edition)*. Cambridge University Press.

# 2

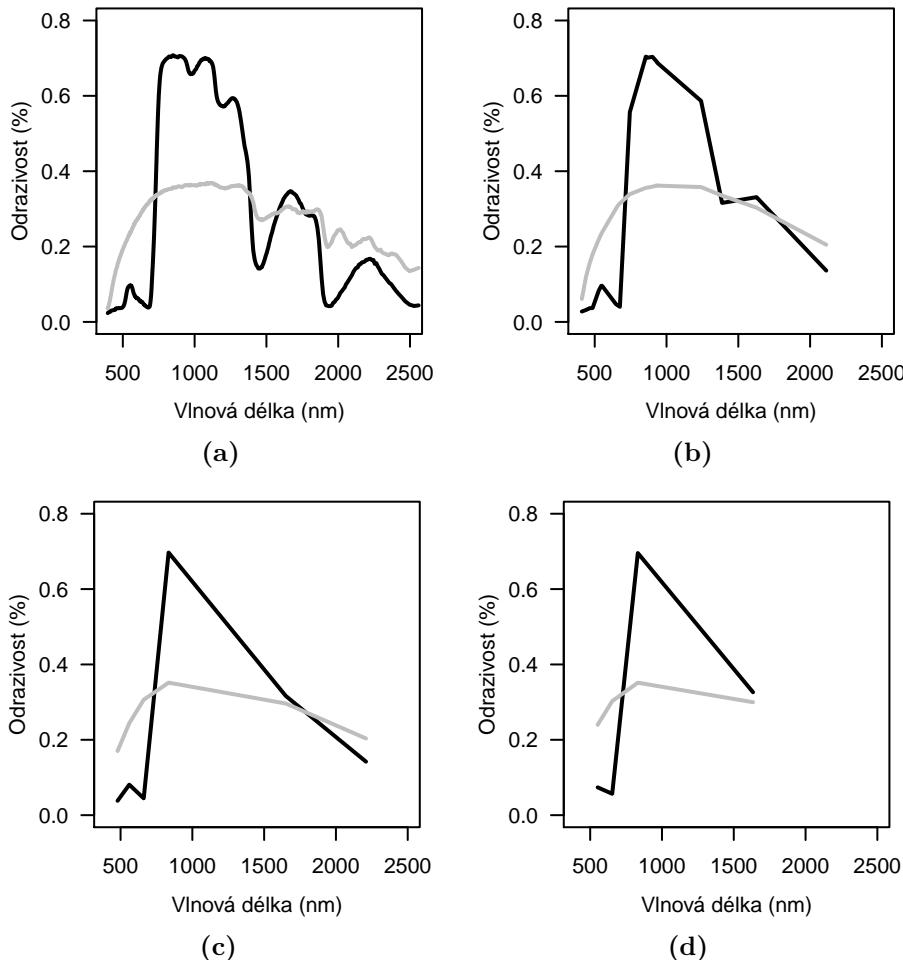
## HYPERSPEKTRÁLNÍ DATA

*Lucie Homolová, Jan Hanuš, Tomáš Fabiánek a František Zemek*

### 2.1 Základní charakteristiky hyperspektrálních dat

Hyperspektrální dálkový průzkum, rovněž nazývaný obrazová spektroskopie, je jedním z nejrychleji se rozvíjejících oborů v oblasti pozorování Země (Ustin et al. 2004; Kokaly et al. 2009; Schaepman et al. 2009). Obrazová spektroskopie používá velké množství úzkých a vzájemně těsně sousedících spektrálních kanálů. V porovnání s daty multispektrálního dálkového průzkumu Země (DPZ) jsou hyperspektrální data tvořena desítkami až stovkami spektrálních kanálů, obvykle 1–10 nm širokých. Každý pixel hyperspektrálních dat tedy obsahuje „spojitou“ spektrální informaci. Obrázek 2.1 znázorňuje spektrální projev vegetace zaznamenaný jak spojité hyperspektrálním, tak i multispektrálními senzory. Z multispektrálních senzorů jsme vybrali tři běžně používané systémy (MODIS, Landsat TM, Spot 4).

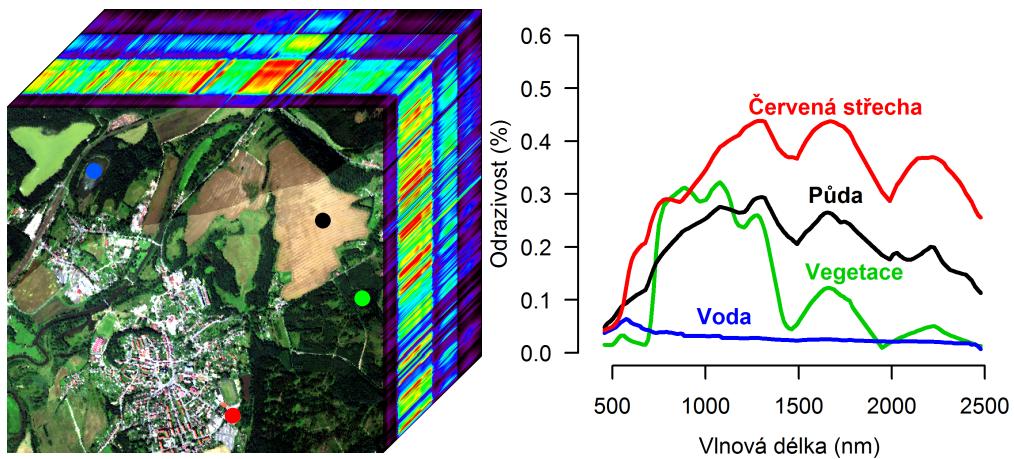
Principy spektroskopie jsou známy již od 18. století. Jejich technická implementace do záznamu obrazu se ale stala proveditelnou až v 80. letech 20. století. Na Obrázku 2.2 je prostřednictvím třídimenzionální datové kostky znázorněn koncept obrazové spektroskopie. Datová kostka je tvořena nad sebou ležícími vrstvami, z nichž každá obsahuje spektrální informaci snímaného povrchu v určitém intervalu vlnových délek.



**Obrázek 2.1** Spektrální projekty živé (černá křivka) a suché (šedá křivka) vegetace měřené (a) laboratorním spektrometrem (USGS databáze spektrálních charakteristik). Spektrální křivky jsou převzorkovány do spektrálního rozlišení senzorů (b) MODIS, (c) Landsat TM, (d) Spot 4.

## 2.2 Přehled leteckých hyperspektrálních senzorů

Od 80. let 20. století byla navržena a vyrobena řada prototypů, ale i komerčně dostupných typů hyperspektrálních leteckých a satelitních senzorů. Satelitní hyperspektrální data jsou v současnosti zaznamenávána třemi senzory: Hyperion (EO-1) (Pearlman et al. 2003), CHRIS (PROBA) (Barnsley et al. 2004) a Resurs-P (Kirilin et al. 2010). Přehled aktuálně používaných leteckých hyperspektrálních senzorů je uveden v Tabulce 2.1. Dnes už jen zřídka využívané senzory byly z přehledu vyloučeny. Přesto považujeme za vhodné alespoň v textu některé starší systémy okrajově zmínit, neboť se výrazně podílely na rozvoji obrazové



**Obrázek 2.2** Koncept obrazové spektroskopie. Data Sokolova nasnímaná senzorem HyMap vyobrazená jako datová kostka. Nejbližší vrstvu kostky představuje barevná syntéza v pravých barvách ( $R = 646 \text{ nm}$ ;  $G = 543 \text{ nm}$ ;  $B = 455 \text{ nm}$ ). Hloubka kostky reprezentuje spektrální dimenzi dat. Každý z pixelů snímku obsahuje spektrální informaci tak, jak je znázorněna na grafu. Barevné značky v datové kostce označují, odkud byly jednotlivé spektrální křivky získány.

spektroskopie. Na mnohé z těchto systémů se můžeme dívat jako na vývojové předchůdce dnešních moderních leteckých obrazových spektrometrů. Např., AIS (Airborne Imaging Spectrometers) je předchůdce dnešního senzoru AVIRIS (Vane et al. 1984), FLI/PMI je předchůdce CASI (Gower et al. 1992), ROSIS je letecký předchůdce satelitního systému MERIS (Kunkel et al. 1991), a další. Podrobnější informace o vývoji obrazové spektroskopie lze nalézt v práci (Schaepman 2009).

V současnosti se hyperspektrální senzory a jejich data stávají dostupnějšími. Velký pokrok byl zaznamenán i ve snížení velikosti a hmotnosti těchto systémů. V posledních letech se na trhu objevují hyperspektrální systémy, které mohou být použity na malých bezpilotních letounech (UAV – Unmanned Aerial Vehicle). Mezi tyto systémy patří např. Micro-Hyperspec (Headwall Photonics), UHD 185 (Cubert) nebo Pika (Recon).

Současná situace v ČR je taková, že jediným poskytovatelem hyperspektrálních leteckých dat je Centrum výzkumu globální změny AV ČR (CzechGlobe). CzechGlobe disponuje vlastní leteckou laboratoří – FLIS (Hanuš et al. 2014). Základem FLIS je fotogrametrické letadlo Cessna 208B Grand Caravan a sada tří senzorů CASI, SASI a TASI od společnosti ITRES, Ltd. Tyto tři senzory pokrývají celou reflektanční a termální infračervenou oblast elektromagnetického spektra. Mimo to, CzechGlobe provozuje i letecký senzor AISA Eagle (Specim, Ltd.).

**Tabulka 2.1** Přehled v současnosti používaných hyperspektrálních senzorů pro optickou část spektra.

Název	Celý název senzoru	Max. počet kanálů	Spektrální rozsah (nm)	Spektrální krok (nm)	Výrobce/Poskytovatel (Zdroj)
AHS 80	Airborne Hyperspectral Scanner	80	441–13170	30–500	Argonst (formerly SenSyTech inc., Daedalus inc.)/ e.g. INTA (http://www.uv.es/~leo/sen2flex/ahs.htm)
AISA Dual (Eagle/Hawk / Fenix)	Airborne Imaging Spectrometer for Applications	488/254	400–970/ 970–2500	1,2–9,2/6,3	Specim Ltd./ e.g. NERC, Univ. of Debrecen, CzechGlobe (Eagle only) (http://specim.fi/index.php/products/airborne)
APEX	Airborne Prism EXperiment	334	380–2500	0,6–10	ESA (Swiss-Belgian consortium)/ Vito (http://www.apex-esa.org/)
AVIRIS	Airborne Visible InfaRed Imaging Spectrometer	224	400–2500	10	NASA, JPL/ NASA, JPL (http://aviris.jpl.nasa.gov/)
CASI/SASI	Compact/SWIR Airborne Spectrographic Imager	288/100	365–1050/ 950–2450	3,5/12	Itres Ltd./ CzechGlobe (http://www.itres.com/products/imagers)
HyMap		128	450–2500	15–20	Integrated Spectronics Pty Ltd / HyVista Corp.
HySpex VNIR/SWIR		160/256	400–1000/ 1000–2500	3,7/6	NEO/ e.g. DLR (http://www.hyspex.no/products/)
PRISM	Portable Remote Imaging SpectroMeter	85+2	350–1050 + 1240–1610	2,8 + n.a.	NASA, JPL/ NASA JPL (http://prism.jpl.nasa.gov/)

## 2.3 Základní předzpracování dat obrazové spektroskopie

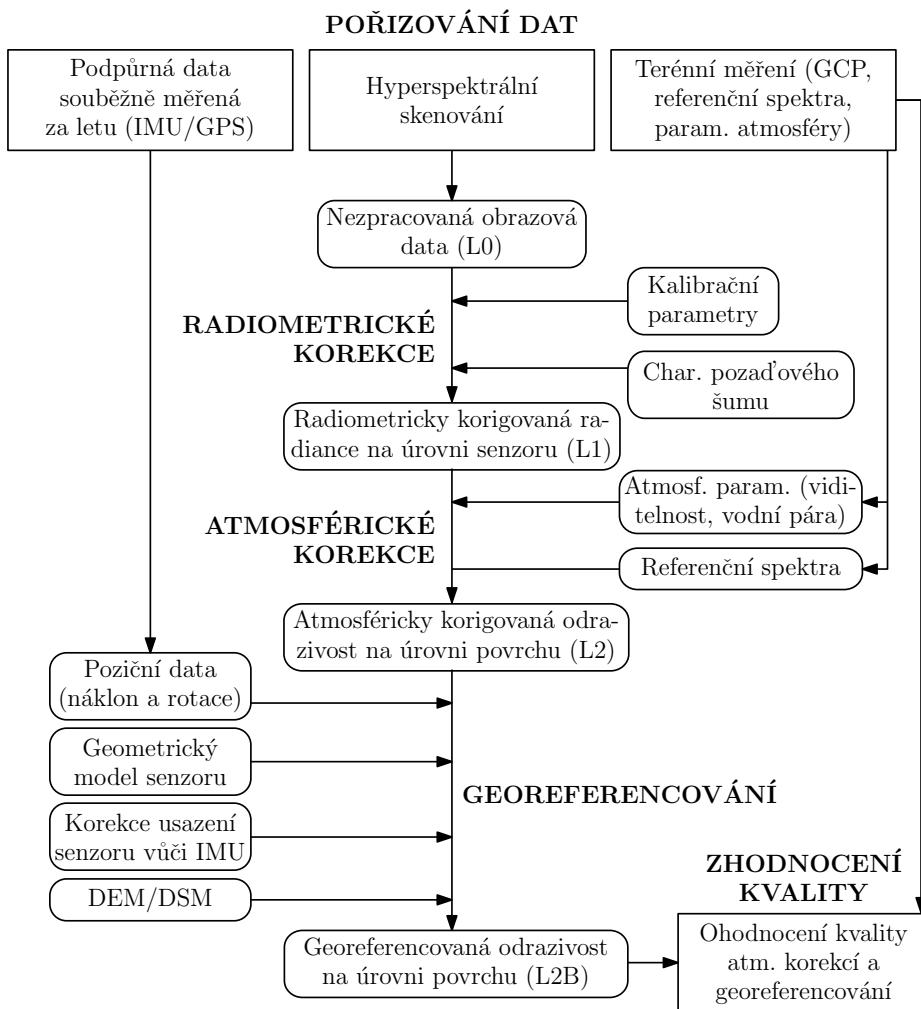
Předzpracování dat obrazové spektroskopie obvykle sestává ze třech kroků: 1) radiometrické korekce – převod DN hodnot na hodnoty radiance na úrovni senzoru; 2) atmosférické korekce – odstranění vlivu atmosféry a převod radiance na hodnoty reflektance (odrazivosti) na úrovni povrchu nebo na hodnoty jasové teploty v případně termálních hyperspektrálních dat; 3) geometrické korekce, tj. kompenzace distorzií vzniklých pohybem letadla a registrace do systému souřadnic. Kvalita předzpracování obrazových spektroskopických dat je obvykle hodnocena v každém z těchto tří kroků.

Zejména pro vědecké využití jsou kladené zvýšené nároky na přesné a aktuální kalibrace senzorů a kvalitu provedených korekcí. V takovém případě je nutné provést spolu s leteckým snímáním podpůrná pozemní měření: měření odrazivosti, poziční měření kontrolních bodů, atmosférická měření. V případech, kdy nejsou kladený tak vysoké nároky na radiometrickou kvalitu dat, je možné provést zjednodušené atmosférické korekce (výpočtem tzv. zdánlivé odrazivosti).

Předzpracování provádí obvykle poskytovatel hyperspektrálních dat. Ve většině případů jsou koncovému uživateli dodávána geometricky korigovaná data v hodnotách odrazivosti na povrchu spolu s parametry senzoru nutnými pro další analýzu dat. Je třeba zmínit, že doposud není ustanoven žádný standardizovaný zpracovatelský řetězec pro letecká hyperspektrální data. Postupy předzpracování se u jednotlivých poskytovatelů často liší v závislosti na senzoru nebo konkrétní aplikaci. Pokud se jedná o softwarové zajištění zpracovatelných řetězců, i to je značně rozmanité, neboť jsou často kombinovány komerční produkty s vlastními programovými moduly. V následujících částech se proto zaměříme na zpracovatelský řetězec, který je v současnosti používán v CzechGlobe. Ten zahrnuje radiometrické, atmosférické a geometrické korekce. Diagram na Obrázku 2.3 schematicky znázorňuje řetězec pro předzpracování CASI dat.

### 2.3.1 Radiometrické korekce

Při průchodu světla optickou částí spektroradiometru dochází k difrakci záření podle specifických vlnových délek. Toto záření dopadá na detektor, kde dochází ke vzniku a akumulaci elektrického náboje v jeho jednotlivých částech detektoru. V určitých časových intervalech je tento náboj odečítán, přičemž prochází zesilovačem a digitalizérem. Digitalizovaný signál je přímo úměrný energii příchozích fotonů, ale není vyjádřen ve fyzikálních jednotkách, nýbrž v digitálních hodnotách (DN – digital numbers). Radiometrickou korekcí jsou tyto DN hodnoty převedeny na fyzikální hodnoty radiance. Spektrální radiance je vyjádřena jako energie toků fotonů na jednotkový úhel a interval vlnové délky (srovnej Obrázky 2.4a a 2.4b). Radiance na úrovni senzoru  $L$  je vypočtena z digitálních hodnot pomocí ka-



**Obrázek 2.3** Předzpracovatelský řetězec dat obrazové spektroskopie.

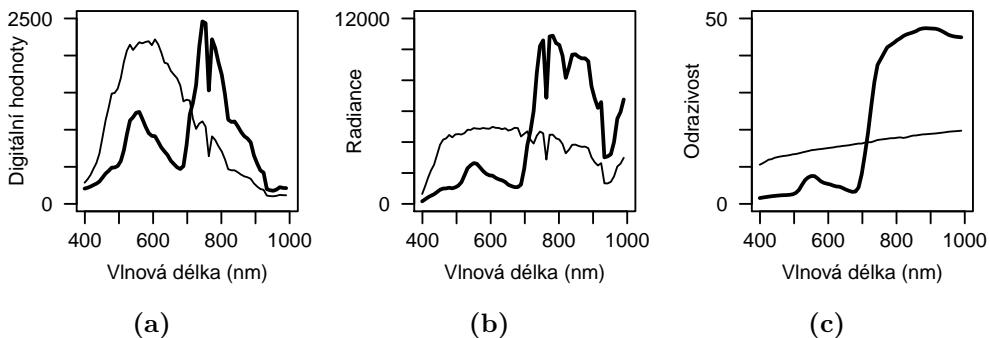
libračních koeficientů ( $C_0, C_1$ ) jednoduchým lineárním vztahem:

$$L = C_0 + C_1 \cdot DN. \quad (2.1)$$

Hodnoty gain ( $C_1$ ) a offset ( $C_0$ ) jsou parametry funkce radiometrické odezvy senzoru, které jsou empiricky stanovené během radiometrické kalibrace senzoru pro každý spektrální kanál. Při radiometrické kalibraci senzor měří signál zdroje o známé radianci, který je umístěn v integrační sféře (Obrázek 2.5).

### 2.3.2 Atmosférické korekce

Signál odražený nebo vyzářený povrchem a změřený leteckým spektrometrem je vždy ovlivněn průchodem té části atmosféry, která je v daném okamžiku mezi



**Obrázek 2.4** (a) DN hodnoty (bezrozměrné), (b) radiance ( $\text{mW cm}^{-2} \text{sr}^{-1} \text{nm}^{-1}$ ), (c) odrazivosti (%) vegetace (tlustá křivka) a asfaltu (tenká křivka) měřené senzorem AISA Eagle.

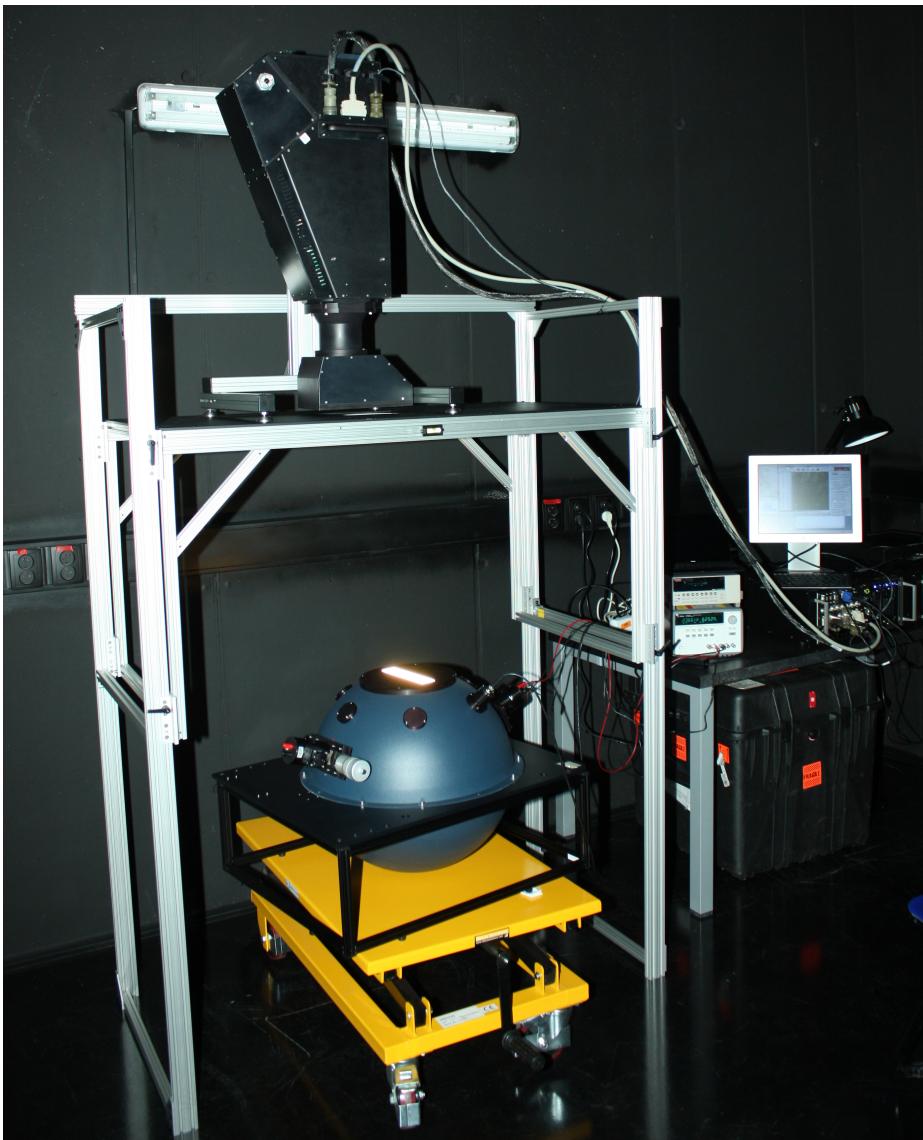
povrchem a senzorem. Při průchodu záření atmosférou dochází zejména ke dvěma jevům – absorpci a rozptylu (viz Kapitola 1). Různé složky atmosféry absorbuje záření v různých vlnových délkách, např: vodní pára v 0,94; 1,14; 1,38 a 1,88  $\mu\text{m}$ , kyslík v 0,76  $\mu\text{m}$ , oxid uhličitý v 2,08  $\mu\text{m}$ . Rozptylem v atmosféře jsou ovlivněna zejména EM záření s vlnovou délkou kratší než 1  $\mu\text{m}$ . Záření dopadající na detektor spektroradiometru se skládá ze tří hlavních komponent (Obrázek 2.6): 1) záření rozptýlené atmosférou ( $L_1$ ); 2) záření odražené od měřeného povrchu ( $L_2$ ); 3) záření odražené od objektů sousedících s měřeným povrchem ( $L_3$ ).

V DPZ aplikacích se často setkáváme s potřebou srovnávat data nasnímaná různými senzory, popřípadě nasnímaná v jiný časový okamžik či na různých lokalitách. Abychom mohli různorodá obrazová data vůbec porovnat, je třeba odstranit nežádoucí vliv atmosféry, která se mění v čase a prostoru, a pracovat tak s hodnotami odrazivosti na úrovni povrchu. Tento proces převodu radiance na úrovni senzoru na odrazivosti na úrovni povrchu (srovnej Obrázky 2.4b a 2.4c) je označován jako atmosférická korekce. V tuto chvíli je potřeba zmínit, že pojmen „odrazivost (reflektance)“ je v této knize užíván v obecném smyslu. Podrobnější vysvětlení rozdílů mezi různým vyjádřením hodnot odrazivosti v závislosti na směru dopadu a odrazu slunečního záření je k nalezení v publikaci Schaepman-Strub et al. (2006).

Algoritmy pro atmosférické korekce mohou být rozděleny do dvou hlavních skupin: 1) empirické metody, jejichž výsledkem jsou hodnoty tzv. „zjevné odrazivosti“; 2) metody založené na radiativním přenosu, tj. na přesné simulaci průchodu slunečního záření atmosférou, jejichž výsledkem jsou hodnoty absolutní odrazivosti. Přehled různých metod atmosférických korekcí uvádí Gao et al. 2009.

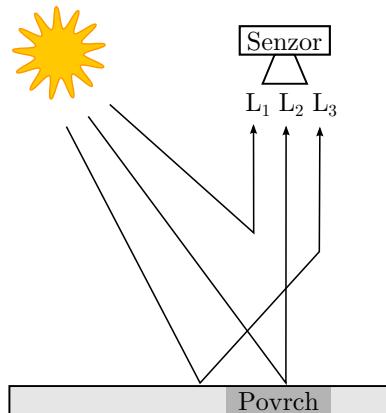
### *Empirické metody*

Produktem empirických atmosférických korekcí je tzv. zjevná odrazivost, což jsou hodnoty relativní vůči hodnotám odrazivosti zvoleného kalibračního povrchu na



**Obrázek 2.5** Radiometrická kalibrace hyperspektrálního senzoru (SASI 600, který je umístěn nahoře na rámu) pomocí integrační sféry (LabSphere®).

snímku. Existuje několik různých empirických metod, mezi něž řadíme i metody vyvinuté pro speciální druhy povrchů jako např. vodní plochy. Mezi nejčastěji používané empirické metody patří: Flat Field Correction (FF), Internal Average Relative Reflectance Spectra (IARR) a Empirical Line Correction (EL). Jelikož EL je často používanou metodou, budeme se jí věnovat podrobněji. EL metoda vyžaduje pozemní spektrální měření provedené současně s leteckým snímáním. Další podmínkou je přítomnost alespoň dvou terčů – světlého a tmavého. Terče



**Obrázek 2.6** Schématické znázornění složení záření měřeného senzorem.  $L_1$  = záření rozptýlené atmosférou,  $L_2$  = záření odražené od měřeného povrchu,  $L_3$  = záření odražené od objektů sousedících s měřeným povrchem.

musí být zároveň dostatečně velké a homogenní, aby bylo možné ve snímku najít reprezentativní spektrum terče. Následně je pro každý spektrální kanál sestaven lineární regresní model mezi hodnotou terče ze snímku a hodnotou změrenou v terénu. Regresní model je následně aplikován na příslušný spektrální kanál celého snímku. Takto získaná spektra se obvykle velmi dobře shodují se spektry naměřenými v terénu. Tato shoda je vázána na stabilní atmosférické podmínky v rámci korigovaného snímku. Pokud se atmosférické podmínky části snímku, kde nejsou přítomné referenční terče, liší, korekce této části neproběhne správně a v datech budou patrné atmosférické efekty.

Dalším příkladem, jak atmosféricky korigovat hyperspektrální data bez nutnosti pozemních spektrálních měření, je výpočet zjevné odrazivosti na úrovni senzoru. V tomto případě jsou nasnímaná obrazová data normalizována pomocí hodnot dopadajícího slunečního záření na úroveň letadla. Záření je měřeno v průběhu snímkování pomocí difúzního kosinového adaptéra připojeného ke spektrometru. Tímto způsobem je možné odstranit rozdíly v osvětlení při snímání jednotlivých linií a vlivy atmosféry nad úrovní letadla. V závislosti na letové výšce a aktuální atmosférické situaci v době snímání mohou být korigovaná data do jisté míry ovlivněna vrstvou atmosféry mezi letadlem a snímaným povrchem.

### *Metody založené na modelování radiativního přenosu záření atmosférou*

Atmosférické korekce založené na modelu radiativního transferu (RTM) umožňují výpočet absolutní reflektance bez předchozí znalosti reflektančních vlastností povrchu. Tento výpočet je rozdělen do dvou částí: odhad atmosférických parametrů a výpočet reflektance povrchu. Hlavními parametry, které jsou relevantní pro atmosférické korekce, jsou: druh aerosolů, viditelnost a obsah vodních par. Jsou to

totíž parametry, které se v průběhu času rychle mění. Viditelnost a obsah vodních par mohou být měřeny sunfotometrem (Obrázek 1.15c, Kapitola 1) v rámci terénních podpůrných měření nebo mohou být odhadnuty přímo z nasnímaných dat. Vlastní výpočet odrazivosti je potom založen na tzv. „look-up tabulkách“ generovaných pomocí RTM. Při modelování je pro každou vlnovou délku, kombinaci parametrů atmosféry a letovou hladinu vypočtena příslušná transmitance atmosféry. Pokud předpokládáme plochý terén bez vlivu záření ze sousedních objektů a bezmračné podmínky, pak může být radiance na úrovni senzoru ( $L$ ) vyjádřena jako:

$$L = L_{path} + \frac{\rho \tau E_g}{\pi}, \quad (2.2)$$

kde  $L_{path}$  je záření rozptýlené atmosférou ( $L_1$  na Obrázku 2.6),  $\rho$  – odrazivost povrchu,  $\tau$  – transmitance atmosféry vypočtená jako součet přímé a difúzní transmittance,  $E_g$  – globální iradiance na úrovni povrchu, vypočtená jako suma přímé a difúzní iradiance pro povrch s nulovou odrazivostí. Jelikož všechny členy rovnice kromě  $\rho$  jsou známé (změřené nebo získané z RTM), je možné vypočítat reflektanci měřeného povrchu. Pro detailnější informace o atmosférických korekcích pomocí RTM odkazujeme na publikace (Gao et al. 2009; Richter 2012; Richter & Schläpfer 2002). Zde je možné najít detailní popis toho, jak jsou jednotlivé parametry atmosféry odhadnuty, a příklady komplexních řešení atmosférických korekcí.

V současné praxi se nejčastěji používají dva modely radiativního transferu atmosféry, MODTRAN a 6S. Více je používán MODTRAN (Berk Berk et al. 2006; Berk et al. 1989), ačkoliv se ukazuje, že 6S může poskytnout přesnější výsledky díky podchycení vlivu polarizačních efektů (Kotschenova et al. 2006). Každopádně, tyto dva modely slouží jako základ většiny softwarových nástrojů, které se v současné době používají pro korekci leteckých, ale i satelitních DPZ dat. V Tabulce 2.2 je přehled dostupných softwarových produktů pro atmosférické korekce.

### 2.3.3 Geometrické korekce

Data nasnímaná z leteckých nosičů nejsou nikdy tak geometricky stabilní jako satelitní data DPZ. Letecká data jsou často ovlivněna řadou geometrických zkreslení, jejichž zdrojem je usazení senzoru v letadle, pohyby letadla během snímání a proměnlivost terénu. Letecká data tak nemohou být přímo použita jako mapové podklady bez toho, aniž by došlo k geometrickým korekcím. Charakter geometrických zkreslení leteckých dat je natolik komplexní, že není možno celou letovou linii korigovat pomocí pozemních výškovacích bodů a polynomických transformací, jako je praktikováno u satelitních snímků. Tudíž geometrické korekce leteckých hyperspektrálních dat jsou prováděny po jednotlivých řádcích a nebo i pixelech. Tento způsob zpracování je umožněn díky využití IMU/GNSS jednotek, které zaznamenávají okamžitou pozici letadla (zeměpisnou délku a šířku, nadmořskou

**Tabulka 2.2** Přehled nástrojů pro atmosférické korekce leteckých hyperspektrálních dat terestriálních ekosystémů.

Název	Vývojář	Reference	Použitý RTM	Licence
ACORN (Atmosphere CORrection Now)	ImSpec LLC, USA	(Kruse 2004) <a href="http://www.imspec.com">http://www.imspec.com</a>	MODTRAN-4	komerční
ATCOR (Atmospheric and Topographic CORrection)	German Aerospace Centre & ReSe Applications Schläpfer	(Richter & Schlapfer 2002) <a href="http://www.rese.ch/products/atcor/atcor4/">http://www.rese.ch/products/atcor/atcor4/</a>	MODTRAN-5	komerční
ATREM (ATmospheric REMoval algorithm)	Uni. of Colorado, Boulder, USA	(Gao et al. 1993)	HITRAN a 6S	pouze výzkumná
FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes)	Air Force Phillips Laboratory, Hanscom AFB & Spectral Sciences, Inc., USA	(Adler-Golden et al. 1999)	MODTRAN-4	komerční (součást ENVI)
HATCH (High-accuracy Atmospheric Correction for Hyperspectral data)	Uni. of Colorado, Boulder, USA	(Qu et al. 2003)	HITRAN & vlastní RT algoritmus	výzkum

výšku), směr (úhly sklonů letadla kolem podélné osy a příčné osy, odklon od kurzu letu) a rychlosť pohybu letadla. Dalšími parametry, které vstupují do geometrických korekcí hyperspektrálních dat jsou: geometrická charakteristika senzoru (zorný úhel a šířka záběru) a digitální model terénu (více informací o DMT následuje v Kapitole 4.5). Geometrické korekce se obvykle dělají ve dvou krocích: přímé geokódování a převzorkování do daného referenčního systému.

První krok, přímé geokódování, se skládá z geometrické korekce a ortogonalizace. V procesu geometrické korekce jsou eliminovány zkreslení spojené s pohybem letadla. Ortogonalizace řeší zkreslení způsobené geometrií senzoru a topografií snímaného povrchu.

Během druhého kroku, převzorkování, jsou hodnoty z jednotlivých pixelů přiřazeny do mřížky zvoleného referenčního systému (např. UTM mapová projekce). Součástí tohoto kroku je výběr velikosti pixelu výsledného snímku a interpolační metody použité pro převod hodnot jednotlivých pixelů. Nejčastěji využívané metody interpolace jsou: nejbližší soused, bilineární a kubická interpolace. V oblasti hyperspektrálního dálkového průzkumu je vůbec nejčastěji používána metoda nejbližšího souseda. Je to z toho důvodu, že při ní nedochází ke změně hodnot, a tudíž zůstává zachován fyzikální význam měřených spektrálních veličin.

Softwarové nástroje pro geometrické korekce hyperspektrálních leteckých dat jsou obvykle dodávány výrobcem senzoru (např., CaliGeo pro senzory firmy Specim a GeoCorr v případě senzorů od firmy ITRES). Tyto programové nástroje lépe zohledňují drobná specifika konkrétních senzorů. Jedním z komerčně dostupných nástrojů pro komplexní geometrické zpracování dat letecké spektroskopie je např. produkt PARGE (Schläpfer & Richter 2002).

### 2.3.4 Hodnocení kvality provedených korekcí

Stále větší důraz je v současnosti při analýze hyperspektrálních dat kladen na informace o jejich kvalitě. Tyto informace jsou důležité, zejména pokud jsou současně analyzovány data z různých zdrojů nebo termínů snímkování. Každý krok předzpracování dat může být charakterizován určitými parametry kvality. Některé z indikátorů kvality jsou zjištovány pro celý snímek jako celek a jiné lze zjišťovat na úrovni jednotlivých pixelů.

Nejdůležitějším indikátorem radiometrické kvality dat je poměr úrovně signálu vůči šumu, tzv. Signal-to-Noise Ratio (SNR). U současně dostupných senzorů je teoretická maximální hodnota SNR, která je deklarovaná výrobcem, cca. 1000:1. Nicméně v praxi se setkáváme spíše s hodnotami v rozmezí 10–300:1. Zejména ve vlnových rozsazích, kde je pro některé povrchy nízká odrazivost, je SNR nízké. povrchy a vlnové rozsahy s nízkou odrazivostí mají nízké SNR.

Kvalita atmosférických korekcí je hodnocena pomocí referenčních spektrálních měření provedených současně s leteckým snímáním. Referenční spektra jsou srovnávána se spektry, která odpovídají pozici pozemního měření ve snímku. Na měřené referenční plochy jsou kladeny nároky na velikost vůči velikosti pixelu,

spektrální homogenitu a jejich geolokaci tak, aby je bylo možné ve snímku jednoznačně identifikovat. Shodu mezi spektry pozemně měřených a letecky snímaných dat lze hodnotit vizuálně, ale jako objektivní kritérium se používá suma čtverců odchylek – RMSE. Hodnoty RMSE pod 2 % procenta jsou považovány za velmi dobrou shodu, hodnoty do 5 % za dostatečnou kvalitu provedených atmosférických korekcí (Richter & Schläpfer 2002).

Geometrická kvalita hyperspektrálních leteckých dat je vyjádřena horizontální poziční přesností. Pro její výpočet se používá soubor pozemních kontrolních bodů. Ty musí být ve snímku jednoznačně identifikovatelné a musí se provést jejich přesné zaměření. Geometrická kvalita dat je nejvíce ovlivněna prostorovým rozlišením snímku a prostorovým rozlišením použitého digitálního modelu terénu (DEM) pro ortorektifikaci. V případech, kdy jsou k dispozici dostatečně kvalitní podpůrná data (IMU/GNSS a DEM), je možno v optimálních případech dosáhnout střední polohové chyby odpovídající velikosti jednoho pixelu.

Dále se ještě můžeme setkat s doplňkovými informačními vrstvami, kde je vyznačeno u kterých pixelů došlo např. k saturaci signálu, či je daný pixel negativně ovlivněn atmosférickými jevy, jako snímání pod oblačností apod.

### Doporučená literatura

- Liang, S. 2004. *Quantitative remote sensing of land surfaces*. Hoboken, New Jersey: John Wiley & Sons, Inc.
- Gao, B.-C., Montes, M.J., Davis, C.O. & Goetz, A.F.H. 2009. Atmospheric correction algorithms for hyperspectral remote sensing data of land and ocean. *Remote Sensing of Environment* 113, Supplement 1, S17—S24.
- Schaepman, M.E. 2009. Imaging Spectrometers. In T.A. Warner, M. Duane Nellis, & G.M. Foody (Eds.), *The SAGE Handbook of Remote Sensing* (pp. 166–178). London (UK): SAGE.



# 3

## TERMÁLNÍ DATA

*Jakub Brom, Marek Pivovarník, Petra Hesslerová, Václav Nedbal,  
Vladimír Jirka, Hana Vinciková, Jan Procházka a Petr Lechner*

Letecká obrazová data, která zachycují rozložení teploty zemského povrchu, nabízejí hodnotnou informaci využitelnou v řadě aplikací různých oborů jako jsou hodnocení energetické bilance a evapotranspirace, hodnocení teploty vodních těles, hodnocení vegetace, mineralogické mapování, urbánní studie, teplotní projekty vulkánů, analýza minových polí, detekce odvodnění, archeologické studie a podobně. Je třeba si uvědomit, že distanční teplotní data mohou být analyzována a interpretována ve dvou různých rovinách. V prvním případě může být analyzována pouze vizuální informace (např. hledání ztracených osob pomocí termovizní techniky, detekce specifických objektů a procesů). V druhém případě je použita radiometrická informace, která dovoluje kvantitativní analýzu teplotních a spektrálních vlastností povrchu. V Kapitole 10 je popsána jedna z aplikací, zaměřených na analýzu teplotního režimu krajiny. Klíčové analýzy teplotních dat jsou zde vztázeny k detekci rozložení a kvantifikaci teploty.

Abychom byli schopni řádně interpretovat teplotní data, je nezbytné pochopit a poznat jejich charakteristiky a návazně principy jejich získávání. Stručná diskuze k danému tématu je v následujícím textu. Dále je uveden současný přehled o dostupné technice získávání termálních dat včetně její specifikace. V přiloženém seznamu literatury lze najít celou řadu odkazů, které detailně popisují uváděnou problematiku.

### 3.1 Vlastnosti termálních dat

Každý objekt o teplotě vyšší než  $0^{\circ}\text{K}$  emituje elektromagnetické záření. Množství a spektrální složení emitované energie závisí na teplotě objektu a jeho emisivitě. V případě ideálního absolutně černého tělesa je množství a spektrální distribuce záření popsána Planckovým zákonem (viz Kapitola 1.2.2). Většina přírodních i umělých objektů, které můžeme sledovat pomocí leteckého průzkumu, má teplotu povrchu v rozmezí 270–330 K. Podle Planckova zákona to znamená, že velikost toku tepelné radiace může být zjišťována ve dvou atmosférických oknech, 3–5 a 8–14  $\mu\text{m}$ . V prvním jmenovaném atmosférickém oknu je zaznamenána jak složka emitovaná zemským povrchem, tak i část odraženého slunečního záření. Z tohoto důvodu jsou data zpravidla získávána v nočních hodinách, kdy je vliv odraženého slunečního záření minimalizován. Druhé atmosférické okno je vhodnější pro získávání distančních teplotních dat z důvodu, že je zde dominantní emitovaná energie zemským povrchem a že její maximum je situováno do této části elektromagnetického záření (viz popis Wienova zákona posuvu v Kapitole 1.2.2). V dalším textu bude diskutována pouze část tepelné radiace emitované ve druhém atmosférickém oknu.

Snímek získaný v tepelné části elektromagnetického spektra může představovat buď termogram, ve kterém se pro každý pixel zaznamenává pouze jedna hodnota intenzity toku tepelné radiace v daném místě, nebo je představován tzv. termální hyperspektrální kostkou. V tomto případě každý pixel obsahuje celý spektrální profil pro dané místo v daném spektrálním rozlišení. Je-li provedena řádná korekce dat, mohou být termální data využita pro vytvoření teplotní mapy povrchu. Oproti konvenčním pozemním měřením teploty, která poskytuje zpravidla bodovou teplotní informaci, letecká termální data jsou prostorově spojité. Tato informace může být kvalitativního (pro porovnání) i kvantitativního charakteru (získání absolutních hodnot). Pro kvalitativní účely není v zásadě nutné provádět atmosférické korekce termálních dat, nicméně v případě kvantitativních analýz jsou přesnost kalibrací a geometrické a atmosférické korekce nutností (další diskuse viz Kapitola 3.3). Pro pochopení významu radiometrických kalibrací a atmosférických korekcí termálních dat a jejich aplikace je důležitá znalost rovnice radiativního transferu, která je popsána níže.

#### 3.1.1 Faktory určující tepelné vlastnosti objektu

Z pohledu dálkového průzkumu Země je zásadní tepelnou vlastností objektů jejich emisivita ( $\varepsilon$ ). Principy emisivity a některé příklady spektrálních křivek emisivity jsou uvedeny v Kapitole 1. V krátkosti, emisivita může být chápána jako efektivita vyzařování tepelné radiace daným tělesem v porovnání k tepelnému záření emitovanému absolutně černým tělesem při stejně teplotě. Emisivita v zásadě závisí na vlnové délce, teplotě a směru vyzařování. Předpokládáme-li, že teplota pozorovaných objektů zemského povrchu se zpravidla pohybuje v intervalu 270–330 K

a objekt je snímán v kolmém průmětu, potom lze očekávat, že emisivita v zásadě závisí pouze na vlnové délce.

Při získávání termálních dat pomocí dálkového průzkumu Země je potřeba zhodnotit aktuální stav počasí a sezónní a denní vlivy, které mohou významně ovlivňovat tepelnou výměnu na povrchu tělesa (na zemském povrchu). Vedle emisivity mohou tepelnou výměnu tělesa ovlivnit tepelné vlastnosti tělesa samotného. Jedná se o následující vlastnosti:

- tepelná vodivost (konduktivita) je mírou rychlosti, s jakou dochází k průchodu tepla materiálem, tzn. jedná se o schopnost vést teplo [ $\text{W m}^{-1} \text{K}^{-1}$ ],
- tepelná kapacita určuje, jak velké množství tepla může daný materiál pohltit, tzn. schopnost udržovat teplo [ $\text{J K}^{-1}$ ],
- termální inercie (tepelná setrvačnost) je mírou reakce materiálu na teplotní změnu, tzn. je rychlosť teplotní změny tělesa s časem [ $\text{J m}^{-2} \text{K}^{-1} \text{s}^{-1/2}$ ].

Výše uvedené tepelné vlastnosti těles mohou být využity pro různé další aplikace, jako je např. analýza vztahů mezi tepelnou setrvačností půdy a obsahem vody v půdě (Maltese et al. 2013).

### 3.1.2 Teplotní projev povrchu jako výsledek energetických přeměn

Teplotní projev povrchu lze chápat nejenom jako termodynamický stav daného tělesa, respektive jeho povrchu, ale též jako důsledek energetických přeměn, které na povrchu probíhají. Ke změnám teploty povrchů v přírodě dochází především na základě změn celého komplexu radiační výměny mezi povrchem a prostředím a díky vedení tepla. Uplatňuje se zde jak energie do systému (na povrch tělesa) vstupující, tak i množství energie, které ze systému odchází. V přírodě se za běžných podmínek ve většině případů na utváření teploty povrchů podílí též transformace energie při fázové přeměně vody (kondenzace a výpar vody, tání a mrznutí vody a sublimace a desublimace vody) a jistou roli hraje vedení tepla tělesem.

Abychom si osvětlili problematiku změny teploty povrchů, musíme začít u rovnice radiační bilance:

$$R_n = R_s^\downarrow - R_s^\uparrow + R_l^\downarrow - R_l^\uparrow \quad (3.1)$$

Rovnice vyjadřuje bilanci energetických vstupů a výstupů do přírodních systémů a z nich ve formě krátkovlnného ( $R_s$ ) a dlouhovlnného ( $R_l$ ) elektromagnetického záření. Zdrojem krátkovlnného záření je zde Slunce ( $R_s^\downarrow$ ). Po dopadu na povrch je část krátkovlnného záření odražena ( $R_s^\uparrow$ ). Bilance dlouhovlnného záření je dána vyzařováním energie v infračervené části elektromagnetického spektra v souladu se Stefan-Boltzmannovým zákonem ze zemského povrchu ( $R_l^\uparrow$ ) a z atmosféry ( $R_l^\downarrow$ ). Výsledek radiační bilance představuje tzv. celkovou čistou radiaci ( $R_n$ ), která je

využita pro procesy tepelné přeměny do jednotlivých tepelných toků. Můžeme hovořit též o tepelné bilanci, kterou můžeme vyjádřit rovnicí:

$$R_n = J + P + G + H + LE, \quad (3.2)$$

kde  $J$  je energie spotřebovaná na změnu teploty povrchů,  $P$  je energie spotřebovaná na fotosyntézu,  $G$  je tok tepla do půdy,  $H$  je tok zjevného (pocitového) tepla a  $LE$  je tok latentního tepla výparu, tedy teplo spotřebované na výpar. Vzhledem k tomu, že množství energie spotřebované na změnu teploty povrchu a na fotosyntézu je zpravidla velmi malé (v řádu jednotek procent celkové energie), jsou tyto dva toky obvykle v úvahách o energetických přeměnách zanedbány. Významně se tedy uplatňují tok tepla do půdy, tok zjevného tepla a tok latentního tepla výparu. Všechny uvedené radiační a tepelné toky jsou zpravidla uváděny jako tok energie ve  $\text{W m}^{-2}$ .

Jednoduchou úpravou rovnice tepelné bilance můžeme vypočítat tok zjevného tepla:

$$H = R_n - G - LE. \quad (3.3)$$

Analogicky Ohmovu zákonu můžeme tok zjevného tepla vyjádřit jako poměr tepelného gradientu  $\delta T$  [ $^{\circ}\text{C}$ ] mezi povrchem  $T_s$  [ $^{\circ}\text{C}$ ] a atmosférou  $T_a$  [ $^{\circ}\text{C}$ ] vči odporu povrchu pro přenos tepla a hybnosti  $r_a$  [ $\text{s m}^{-1}$ ] (Thom 1975)

$$H = \frac{\rho c_p \delta T}{r_a} = \frac{\rho c_p (T_s - T_a)}{r_a}, \quad (3.4)$$

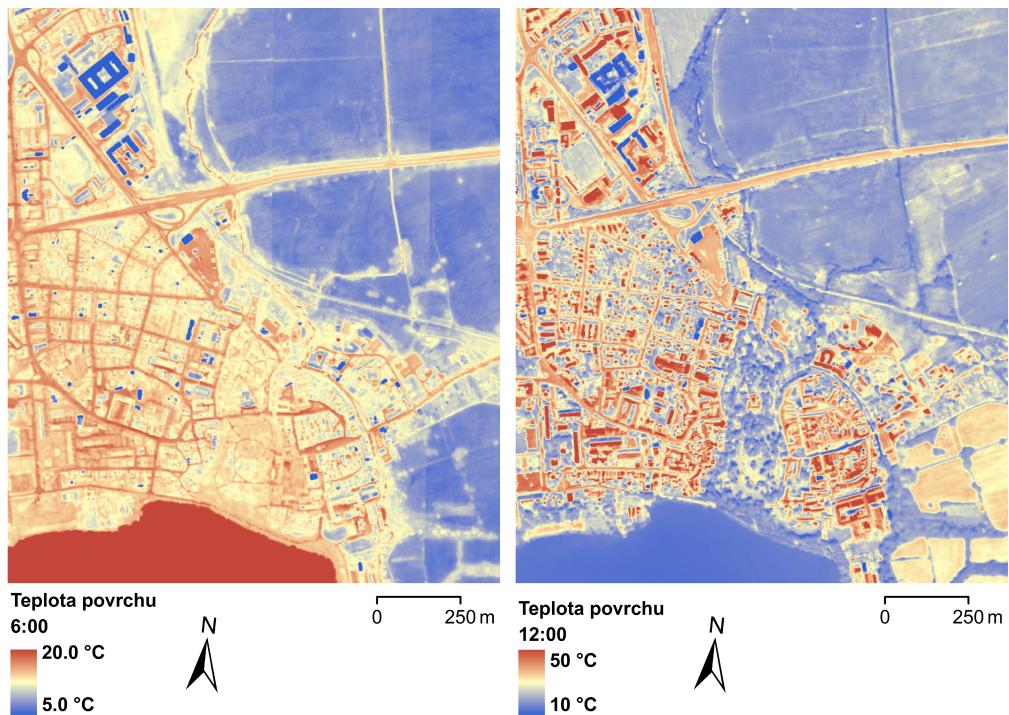
kde  $\rho$  je hustota vzduchu [ $\text{kg m}^{-3}$ ] a  $c_p$  je měrná tepelná kapacita suchého vzduchu [ $\text{J kg}^{-1} \text{K}^{-1}$ ]. Zde je potřeba poznamenat, že  $r_a$  je funkcí aerodynamických vlastností povrchu (např. drsnosti povrchu), rychlosti proudění, vertikálního teplotního profilu mezi povrchem a atmosférou a stability atmosféry.

Kombinací rovnic (3.3) a (3.4) můžeme vyjádřit teplotu povrchu následovně:

$$T_s = \frac{(R_n - G - LE) r_a}{\rho c_p} + T_a. \quad (3.5)$$

Z uvedené rovnice vyplývá, že se na teplotě povrchu uplatňuje bilance slunečního záření, tepelný přenos energie do vlastního tělesa (půdy), výpar, případně kondenzace vody, aerodynamické vlastnosti povrchu a proudění větru a vlastnosti prostředí (tepelná kapacita vzduchu, měrná hustota vzduchu a teplota vzduchu). Za zásadní lze považovat množství slunečního záření, aerodynamické vlastnosti povrchu a proudění vzduchu, které zde působí jako dodatková energie, a energii spotřebovanou na výpar.

Při pohledu na přírodní povrchy (viz Obrázek 3.1) můžeme vidět, že se významně liší plochy s funkční vegetací a bez vegetace, plochy suché a vlhké. Platí-li, že teplota povrchu je výsledkem energetických přeměn, můžeme na krajinné úrovni významně ovlivnit její teplotní projev úpravou vodního režimu a vegetačního krytu.



**Obrázek 3.1** Teplotní mapy centra Třeboně a přilehlého okolí v ranních a poledních hodinách během bezoblačného letního dne (27. 7. 2008). Ze snímku je patrné, že v zastavěném území dochází k akumulaci tepla a vzniká tak tzv. tepelný ostrov města. Podobně je тепло akumulováno i ve vodních tělesech (v jižní části rybník Svět). Porosty s funkční vegetací, kde dochází k intenzivní evapotranspiraci, mají nižší teplotu povrchu v průběhu celého dne. (Poznámka: Hodnoty teploty stejné barevné škály obou obrázků jsou rozdílné.)

### 3.1.3 Rovnice radiačního přenosu

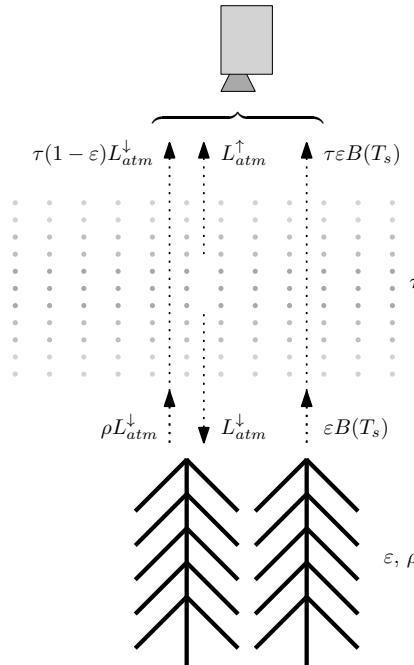
Signál, měřený senzorem ( $L_m$ ), se skládá ze složky radiace emitované povrchem Země, odraženého záření ( $L_{atm}^\downarrow$ ) a přímého vyzařování atmosféry ( $L_{atm}^\uparrow$ ). Příspěvky těchto tří složek k radiační bilanci jsou vyjádřeny rovnicí radiačního přenosu (Radiative Transfer Equation – RTE):

$$L_m = \tau \varepsilon B(T_s) + \tau(1 - \varepsilon)L_{atm}^\downarrow + L_{atm}^\uparrow, \quad (3.6)$$

kde  $B(T_s)$  je radiace povrchu Země při teplotě povrchu  $T_s$  podle Planckova zákona,  $\varepsilon$  je emisivita povrchu Země a  $\tau$  propustnost atmosféry. Je třeba zdůraznit, že všechny složky rovnice jsou závislé na vlnové délce. Smysl RTE je znázorněn na Obrázku 3.2;  $\rho$  je reflektance. Podle Kirchhoffova zákona je reflektance  $\rho$  rovna vztahu  $(1 - \varepsilon)$ , a to pro neprůhledné a neprůsvitné povrchy.

Pro odhad teploty povrchu Země (LST) z rovnice RTE (vztah (3.6)) je ne-

zbytné nejprve odstranit vliv atmosféry. Tento proces je úlohou atmosférických korekcí; stanovení parametrů atmosféry je dále popsáno v Kapitole 3.3. Pokud neznáme povrchovou teplotu a emisivitu povrchu Země, není možné rovnici spočítat (nemá řešení), a to ani po aplikaci atmosférických korekcí. V případě senzoru s několika termálními kanály by měla být rovnice RTE aplikována na každý z těchto kanálů. K řešení tohoto problému bylo vytvořeno několik přístupů a algoritmů, jejichž přehled uvádí Li et al. 2013.



**Obrázek 3.2** Termální radiace dopadající na senzor vzniká třemi hlavními způsoby: 1) radiace  $\tau\epsilon B(T_s)$  emitovaná povrchem Země s emisivitou  $\epsilon$  při teplotě  $T_s$  zeslabená průchodem atmosférou; 2) odražené záření  $\tau(1-\epsilon)L_{atm}^{\downarrow}$  zeslabené propustností atmosféry; 3) vlastní vyzařování atmosféry  $L_{atm}^{\uparrow}$ .

## 3.2 Přehled leteckých termálních přístrojů

Měření radiační (jasové) teploty je bezkontaktní. Pro bodové měření jsou užívány pyrometry (infračervené termometry). Pro zachycení prostorové informace jsou užívány dva systémy infračerveného zobrazování:

- Focal Plane Arrays (FPA) – maticové zobrazovací systémy, především termokamery,
- skenovací systémy – u mnoha satelitních a hyperspektrálních senzorů.

Termální širokopásmové kamery zaznamenávají prostorovou informaci pouze v jednom spektrálním kanálu. Snímek termální širokopásmové kamery tak často zahrnuje signál celého určitého atmosférického okna. Prostorové rozlišení termálních širokospektrálních kamer dosahuje hodnot od  $100 \times 100$  do  $1024 \times 1024$  pixelů. Tabulka 3.1 uvádí souhrn širokospektrálních kamer v současnosti užívaných pro pořizování termálních dat s důrazem na jejich provozovatele v České republice.

Přístroje založené na technologii infračervené Fourierovy transformace (FT-IR) jsou určeny převážně pro použití v laboratoři, existují však i letecké typy přístrojů, využívající stejný princip. Přístroj Hyper-Cam LW, vyvinutý společností Telops, Inc. (Kanada), který užívá technologie FPA, dosahuje prostorového rozlišení  $320 \times 256$  pixelů. Hyper-Cam LW užívá oba rozměry FPA pro zaznamenání prostorové informace, zatímco spektrální informace je zaznamenávána interferometrem. Spektrální rozlišení Hyper-Cam LW je  $0,0015\text{--}0,0035\text{ }\mu\text{m}$ .

V případě mechanooptických skenerů je prostorová informace zaznamenávána jedním rozměrem FPA, zatímco další rozměr je použit pro záznam spektrální informace (viz Kapitola 1.4). Nevýhodou tohoto systému záznamu obrazu je závislost na relativním posunu mezi senzorem a jeho cílem. Tabulka 3.2 uvádí souhrn v současnosti užívaných mechanooptických hyperspektrálních termálních senzorů.

Kromě výše uvedených technologií a přístrojů existuje mnoho dalších, které dosud nejsou v provozu, nebo jsou stále ve vývoji. Existují také jiné principy získávání dat, kombinující zmíněné technologie FPA.

**Tabulka 3.1** Příklady termálních širokospektrálních kamer pro použití v letadlech a bezpilotních strojích.

Název	Spektrální rozsah ( $\mu\text{m}$ )	Prostorové rozlišení (pixelů)	Výrobce / Provozovatel v ČR
Thermalimager TI	8–14	$768 \times 500$	Termal Imaging Ltd./Scandat
Digi THERM	7,5–14	$640 \times 480$	IGI GmbH/Gispro Sp.o.o.
FLIR SC645	7,8–14	$640 \times 480$	FLIR Systems. Inc./ARGUS GEO SYSTÉM s.r.o., ENKI, o.p.s.
FLIR SC660	7,5–13	$640 \times 480$	FLIR Systems. Inc./CzechGlobe
FLIR PM695	7,5–13	$320 \times 240$	FLIR Systems. Inc./ENKI, po.p.s., ČVUT, Airship.Com
Vario CCAM	7,5–14	$640 \times 480$	Jenoptic Germany/Geodis Brno, s.r.o.

**Tabulka 3.2** Přehled v současnosti provozovaných leteckých termálních hyperspektrálních senzorů.

Název	Celý název	Max. počet kanálů	Spektrální rozsah (μm)	Spektrální rozlišení (nm)	Výrobce/Provozovatel v ČR
AHS 80	Airborne Hyperspectral Scanner	80	0,441–13,17	30–500	Argonist (dříve SenSyTechnic., Daedalus inc.) / e.g. INTA ( <a href="http://www.uv.es/~leo/sen2flex/ahs.htm">http://www.uv.es/~leo/sen2flex/ahs.htm</a> )
TASI	Thermal Airborne Spectrographic Imager	32/64	8–11,5	125/55	Itres Ltd. / CzechGlobe ( <a href="http://www.itres.com/products/imagers">http://www.itres.com/products/imagers</a> )
AISA Owl		84	8–12	100	Specim Ltd. / neznámý ( <a href="http://www.specim.fi/index.php/products/airborne/aisaowl">http://www.specim.fi/index.php/products/airborne/aisaowl</a> )
SEBASS	Spatially Enhanced Broadband Array Spectrograph System	128	7,5–13,5		The Aerospace Corporation / neznámý
HyTES	Hyperspectral Thermal Emission Spectrometer	256	7,5–12	18	Jet Propulsion Laboratory / Jet Propulsion Laboratory ( <a href="http://hytes.jpl.nasa.gov/">http://hytes.jpl.nasa.gov/</a> )

### 3.3 Korekce a kalibrace termálních dat

Korekce termálních dat jsou nezbytné pro provedení přesných analýz a odhadů parametrů zemského povrchu. Korekce obvykle zahrnují kalibraci senzoru, odstranění vlivu atmosféry (tuhých částic, vody v atmosféře atd.) a geometrické korekce. Popis geometrických korekcí je zde záměrně vynechán, protože funguje na stejném principu jako geometrické korekce dat pořízených leteckou obrazovou spektroskopí. Detailně je tato problematika popsána v Kapitole 2.3.3. V této části je kláden důraz na radiometrické a atmosférické korekce. Obecně platí, že senzory získávají tepelná data v surovém (nezpracovaném) formátu, obvykle označovaném jako digitální hodnota (digital number = DN). Hlavním cílem těchto korekcí je definovat vztah mezi DN hodnotami a vyzařováním zemského povrchu nebo povrchovou teplotu. Existuje mnoho přístupů a metod radiometrické korekce a kalibrace dat (Lillesand & Kiefer 2000). Volba vhodné metody závisí na typu dat a typu senzoru a také na účelu pořízení dat.

#### 3.3.1 Radiometrická kalibrace

Prvním krokem, nazývaným radiometrická kalibrace senzoru, je převedení DN hodnot na spektrální radianci. Všeobecně používaný přístup se skládá z měření dvou absolutně černých těles o známé teplotě. Absolutně černá tělesa by měla reprezentovat teplotní extrémy, které jsou zaznamenány v daném snímku. Lze předpokládat, že hodnota naměřená termálním radiometrem (DN) je lineárně závislá na množství dopadající energie a platí tedy následující rovnice:

$$L = a + b \text{ DN}, \quad (3.7)$$

kde  $L$  je dopadající záření na senzor a  $a, b$  jsou kalibrační konstanty radiometru. Předpokládejme, že pro radianci  $L(T_{BBC})$  chladného černého tělesa a radianci  $L(T_{BBH})$  teplého černého tělesa platí Planckův zákon. Potom se konstanty  $a$  a  $b$  vypočítají podle následujících rovnic:

$$a = \frac{L(T_{BBH})\text{DN}_C - L(T_{BBC})\text{DN}_H}{\text{DN}_C - \text{DN}_H} \quad (3.8)$$

$$b = \frac{L(T_{BBC}) - L(T_{BBH})}{\text{DN}_C - \text{DN}_H} \quad (3.9)$$

kde  $\text{DN}_C$  a  $\text{DN}_H$  jsou hodnoty chladného a teplého tělesa měřené senzorem. Opět je třeba zdůraznit, že rovnice (3.7) závisí na vlnové délce a je tedy nutné provádět radiometrické kalibrace pro všechna spektrální pásma.

Radiometrické kalibrace lze provádět v laboratoři (v případě širokopásmových kamer) nebo přímo před snímáním dat (v případě hyperspektrálních senzorů). Obecně je doporučován druhý přístup, protože bere v úvahu okamžitý stav senzoru.

DN hodnoty senzoru mohou být převedeny také přímo na teplotu místo na hodnoty radiance. Nicméně vztah mezi teplotou a radiancí je nelineární a opírá se o znalost emisivity snímaného objektu. Pro kalibraci proto musí být použito několik černých těles s různou teplotou. Nelineární vztah mezi DN hodnotami a teplotou ( $T$ ) je vyjádřen jako

$$\text{DN} = \frac{R}{\exp\left(\frac{B}{T}\right) - F}, \quad (3.10)$$

kde  $R$ ,  $B$  a  $F$  jsou neznámé konstanty. Tento druh kalibrace je často používán pro data z termálních širokopásmových kamer.

### 3.3.2 Atmosférické korekce

Atmosféra ovlivňuje termální data ve třech směrech. Zeslabuje emitované záření zemským povrchem a zároveň sama je zdrojem emitovaného i odraženého záření, které senzor zaznamenává. Odstranění atmosférických vlivů z termálních dat je nezbytným předpokladem pro přesné stanovení teploty, případně spektrální emisivity. Vlivy atmosféry jsou zahrnuty do rovnice radiačního transferu (3.6) jako parametry propustnosti atmosféry ( $\tau$ ), jejího vlastního dlouhovlnného vyzařování ( $L_{atm}^{\uparrow}$ ) a záření odraženého ( $L_{atm}^{\downarrow}$ ). Pro atmosférické korekce lze využít modelování různých typů atmosfér či aplikaci in-scene algoritmů.

Principy aplikovaných korekcí jsou rozdílné pro hyperspektrální data a data pořízená širokopásmovou termální kamerou. Na příkladu termovizní techniky FLIR se zmíníme o korekcích širokopásmových kamer, v následující sekci zmíníme o možnosti korekce hyperspektrálních termálních dat.

#### Širokopásmová termální data

Kalibrace širokopásmových teplotních dat je jednodušší než kalibrace hyperspektrálních termálních dat. V případě, že cílem analýzy těchto dat je co nejpřesnější stanovení povrchové teploty, je nezbytné mít k dispozici kalibrační údaje o aktuálním stavu atmosféry v době snímání, včetně dalších doplňkových dat. Termovizní kamery lze kalibrovat v době pořizování snímků nebo v rámci zpracování a vyhodnocení dat. V případě kamery FLIR se bude jednat o následující parametry:

- emisivita snímaného objektu  $\varepsilon$ ,
- relativní vlhkost vzduchu  $R_h$ ,
- vzdálenost od měřeného objektu  $D_{obj}$  (např. výška letu),
- (efektivní) teplota okolí objektu  $T_{refl}$ ,
- teplota oblohy  $T_{sky}$ ,

- teplota externí optiky  $T_{exo}$ .

Většinu parametrů lze získat z meteorologických stanic. Jako hodnotu emisivity můžeme nastavit 0,98, což je hodnota použitelná pro většinu povrchů pokrytých vegetací. V případě umělých povrchů (plechová střecha, apod.), lze hodnotu nastavit dle příslušné tabulkové hodnoty. Relativní vlhkost vzduchu je měřena na meteorologické stanici, stejně jako teplota vzduchu ve 2 m, která approximuje hodnotu teploty okolí objektu  $T_{refl}$ . Teplotu oblohy  $T_{sky}$  approximujeme z dat naměřených pyrgeometrem. Toto zařízení měří emitované záření zemským povrchem ve vlnových délkách 4,5–50 µm. Teplota oblohy je odhadnuta na základě vztahu (3.11)

$$T_{sky} = \sqrt[4]{\frac{R_{ldown} + \varepsilon\sigma(T_{rad})^4}{\varepsilon\sigma}}, \quad (3.11)$$

kde  $R_{ldown}$  je hodnota výměny dlouhovlnného záření mezi oblohou a pyrgeometrem,  $T_{rad}$  je teplota radiometru,  $\sigma$  – Stefan-Boltzmanova konstanta. Hodnoty emisivity jsou approximovány hodnotami pro černé těleso, tzn.  $\varepsilon = 1$ .

Posledním kalibračním parametrem je teplota externí optiky ( $T_{exo}$ ), kterou můžeme zadat shodnou s teplotou vzduchu v případě, že výška snímkování nepřekračuje 300 metrů. Pokud je výška snímkování vyšší, dosazujeme teplotu v okolí kamery.

Je důležité si uvědomit, že mnoho z výše zmíněných parametrů se v čase a prostoru značně liší. Proto je optimální jejich průběžné měření v době náletu na několika lokalitách, rovnoměrně rozmištěných po snímkovaném území.

### *Hyperspektrální termální data*

Atmosférické korekce hyperspektrálních termálních dat jsou založeny na modelech radiačního přenosu záření. Stejně jako optická data využívají i termální data model MODTRAN (Berk et al. 2006). MODTRAN simuluje propustnost atmosféry i její dlouhovlnné vyzařování na základě vstupních parametrů, jako je vertikální profil teploty a vlhkosti vzduchu, koncentrace CO<sub>2</sub>, typ modelu atmosféry (jestliže nejsou k dispozici měřené vertikální profily), aerosolový model a další. Některé ze vstupních parametrů lze získat měřeními in-situ. Např. sluneční fotometr měří obsah vodní páry a aerosolů v atmosféře, radiosondy se používají pro měření vertikálních profilů teploty a vodní páry, radiometry zaznamenávají dlouhovlnné vyzařování zemského povrchu. Jestliže tato měření nejsou k dispozici, lze využít data z lokálních meteorologických stanic nebo využít předem definované modely standardní atmosféry. Dalším zdrojem dat mohou být bud' hyperspektrální letecké snímky či družicová data blízká době snímkování.

Příkladem softwaru, který umožňuje atmosférické korekce jak v optické, tak v termální části spektra, je ATCOR (Richter & Schläpfer 2002). ATCOR využívá tzv. „look-up tabulek“ generovaných modelem MODTRAN, zahrnuje rovněž topografické vlivy a parametry senzoru. Nabízí i možnosti využití základních separačních algoritmů teploty a emisivity.

Pro atmosférické korekce hyperspektrálních termálních dat existuje i řada algoritmů, založených na principu vlastní hyperspektrální kostky, jako je např. In-Scene Atmospheric Corrections (ISAC) (Young et al. 2002) a Autonomous Atmospheric Compensation (AAC) (Gu et al. 2000). Výhoda těchto algoritmů spočívá v tom, že nevyžadují další doplňková data.

### *Nepřímé kalibrace*

Tento způsob kalibrace představuje specifickou kalibrační techniku, využívající naměřených in-situ dat na přírodních i umělých kalibračních plochách, pomocí nichž jsou následně kalibrovány vlastní obrazové záznamy. V podstatě se jedná o radiometrickou kalibraci a atmosférické korekce prováděné zároveň. DN hodnoty naměřené termálním senzorem na leteckém nosiči jsou kalibrovány na radiometrické hodnoty dat získaných pozemním měřením na vybraných homogenních kalibračních plochách. Pozemní měření je prováděno v době letecké kampaně např. přenosným FTIR spektrometrem (Model 102, D&P Instruments, US). Vybrané kalibrační plochy musejí být dostatečně velké, aby je bylo možno na snímku bezpečně identifikovat. Zároveň musejí být spektrálně homogenní. Tento způsob kalibrace dat se využívá spíše pro hyperspektrální než pro širokopásmová termální data.

### Doporučená literatura

- Kuenzer, C. & Dech, S. 2013. Thermal Infrared Remote Sensing: Sensors, Methods, Applications. *Remote Sensing and Digital Image Processing* 17.
- Quattrochi, D.A. & Goel, N.S. 1995. Spatial and Temporal Scaling of Infrared Remote Sensing Data. *Remote Sensing Reviews* 12: 256–286.

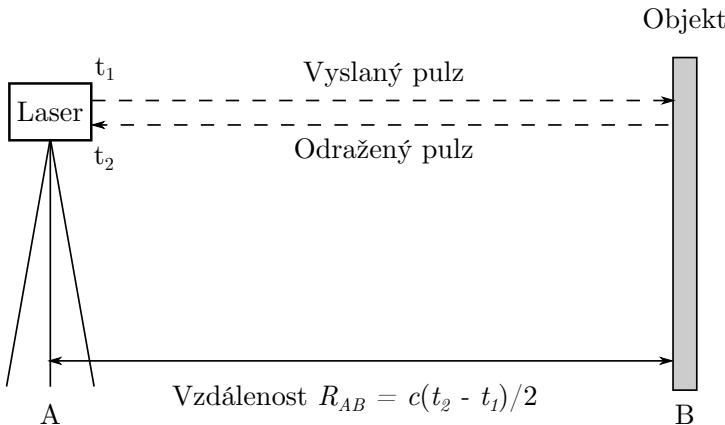
# 4

## LETECKÉ A POZEMNÍ LASEROVÉ SKENOVÁNÍ

*Vlastimil Hanzl, Jan Novotný, Miloš Cibulka a Lucie Homolová*

Laserové skenování je technologie pro bezkontaktní snímání dat, umožňující přesné určení polohy a struktury objektu zájmu. Laserové skenery jsou aktivní systémy emitující světelné pulzy a zaznamenávající energii odraženou zpět (Obrázek 4.1). Tato technologie je známa již z šedesátých let minulého století. Pokrok v oblasti elektroniky stimuloval rychlý vývoj této technologie v posledních dvaceti letech. Možnost zpracování velkého množství dat výkonnými počítači otevřela laserovému skenování prostor pro široké aplikace v oblastech jako jsou mapování výškopisu, životného prostředí, průmyslových objektů i kulturního dědictví.

Laserové skenery mohou být instalovány na pohybujících se platformách (letecké laserové skenování – LLS), ale rovněž i na pozemních platformách. V následujících odstavcích budou stručně popsány základní principy laserového skenování, některé komerčně dostupné LLS systémy, základní kroky zpracování dat a zmíněn bude i nejzádanější produkt LLS – digitální výškový model (DEM).



**Obrázek 4.1** Základní princip laserového měření délek používající pulzní metodu. Vzdálenost ( $R_{AB}$ ) mezi skenerem A a objektem B je vypočtena z rozdílu mezi časem, kdy je světelný pulz vyslán a ( $t_1$ ) a časem, kdy odrážený pulz vrátí zpět ( $t_2$ ) a pomocí rychlosti světla ( $c$ ).

## 4.1 Letecké laserové skenování

### 4.1.1 Princip leteckého laserového skenování

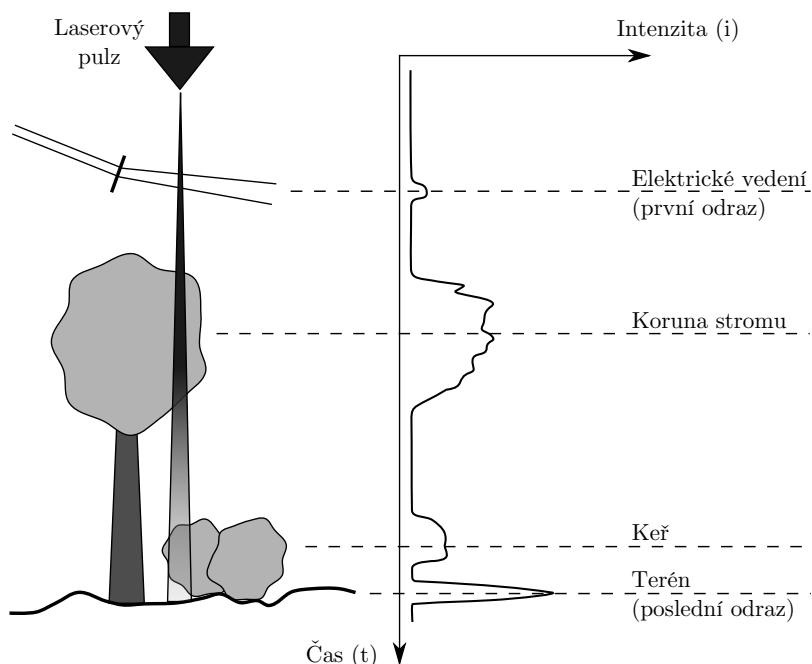
Typický letecký skenovací systém se skládá z následujících hlavních komponent:

1. Dálkoměrná jednotka. Skládá se z laseru, přijímací a vysílací optiky, přijímače s detektorem a digitalizační jednotkou pro sběr přijatých signálů a časového čítače měřícího čas mezi vyslaným a vráceným pulzem. Jednotka měří šíkmou vzdálenost mezi skenerem a zemí (viz Obrázek 4.1).
2. Skenovací mechanismus. Určuje vzor, s nímž pulzy dopadají na zemský povrch. Typickým příkladem skenovacího mechanismu je oscilující zrcadlo, které společně s úhlovým zařízením vypouští laserové pulzy v rovině kolmé ke směru letu. Skenovací mechanismus zajišťuje postupné bodové měření podél jedné linie (profil). Dopředný pohyb letadla pak vytváří řadu profilů pokrývajících celý pás terénu.
3. Řídící a záznamová jednotka. Je to počítačové zařízení dovolující operátorovi řídit nastavení skenování a proces záznamu dat.
4. Jednotka IMU/GNSS. Měří přesnou pozici a orientaci leteckého skeneru.
5. Snímkovací zařízení. Laserové skenování je často prováděno souběžně se sběrem obrazových dat, například integrovanou multispektrální digitální kamерou (60–80 megapixelů).

Většina současných LLS systémů je schopna zaznamenávat vícenásobné odrazy jednoho vyslaného pulzu a intenzitu vráceného odrazu. Nejnovější skenery poskytují možnost digitalizace celého tvaru odražené vlny (Obrázek 4.2). Tato vlastnost

je užitečná pro mapování vegetace, protože umožňuje mapování různých úrovní vegetace a obecně struktury pokryvu (Mallet & Bretar 2009).

Souběžně s měřenou vzdáleností je zaznamenána rovněž intenzita odraženého pulzu. Kvalita signálu informace je závislá na vlnové délce, odrazivosti povrchu, úhlu dopadu a atmosférických podmínkách. Mnoho systémů využívá vlnovou délku z oblasti blízkého infračerveného světla, která je méně ovlivněna atmosférickými podmínkami. Většina přirozených povrchů má vysokou odrazivost vlnových délkách, které jsou využívány v laserech. S informacemi o intenzitě je potřeba pracovat opatrně. Normalizace intenzity je požadována s ohledem na různé skenovací úhly a proměnné vzdálenosti mezi skenerem a pozemními objekty. Signál z větší vzdálenosti může být slabší než u blízkých objektů při stejné odrazivosti (Jutzi & Gross 2007). Údaje o intenzitě zachycených pulzů, i přes možnost využití např. při klasifikacích bodového mračna, bývají často na okraji zájmu uživatelů. V nedávné době byly vyvinuty vícevlnné skenery pro měření pokryvu a jsou úspěšně testovány pro monitoring vegetace (Bo et al. 2011; Wei et al. 2012). Mohou používat samostatně čtyři vlnové délky (556 nm, 670 nm, 700 nm a 780 nm). V těchto vybraných vlnových délkách je dobré viditelná změna ve spektrální odrazivosti vyvolaná stresem z nedostatku dusíku. Navíc tyto vlnové délky slouží dobře k vylišení jednotlivých fenologických fází rostlin.



**Obrázek 4.2** Laserový skenovací systém s úplným záznamem vlny poskytuje úplnou digitalizaci odraženého signálu.

### 4.1.2 Skenovací parametry a vlastnosti LLS systémů

Uživatel/operátor by měl znát některé parametry a vlastnosti LLS systémů, aby získal data požadovaného rozlišení a kvality. Významnými parametry jsou frekvence opakování pulsů (PRF) a míra rychlosti skenování postupných profilů (*scan rate*). Oba parametry, společně s výškou letu a úhlem záběru, t.j. úhlová šířka skenovaného pruhu (FOV), určují hustotu bodů na povrchu Země. Se zvyšováním frekvence opakování pulsů (PRF) se rovněž zvyšuje hustota bodů. Dřívější skenery mohly mít jen jeden pulz ve vzduchu, t.j. další pulz nemohl být vyslan, dokud se předchozí nevrátil. Toto omezení byla nyní překonána technikou „vícenásobných pulsů“, které se nazývají: *Multiple-Pulses-in-the-Air* (MPiA) Leica, *Continuous Multi-Pulse* (CMP) Optech, *Multiple Time Around* (MTA) Riegl. Se zavedením těchto technik maximální PRF vzrostla na 200 kHz a více, ale je stále závislá na výšce letu. Parametr rychlost skenování postupných profilů je nepřímo úměrný FOV. Zvýšení rychlosti skenování se provádí také pomocí použitím dvojic skenerů v jednom systému, například Riegl BP-560 používá dvojici skenerů LMS-Q560 nebo Pegasus systém od firmy Optech.

Vzor skenovací šablony závisí na tom, jak je paprsek rozmítán, tedy na skenovací rychlosti a skenovacím mechanismu. Zubovitá šablona a sinusoidální šablona jsou tvarovány obousměrným oscilujícím zrcadlem (Optech nebo Leica). Šablona ve tvaru pravidelné mřížky vzniká použitím jednosměrně rotujícího optického hranolu (Riegl). Šablona, s mříží s nestejně vzdálenými body napříč a ve směru letu, vznikne použitím skeneru se skleněnými vlákny, TopEye systém používá Palmerův skener s nutujícím zrcadlem vytvářejícím překrývající se eliptické skeny.

Další významnou vlastností skeneru je velikost stopy (otisku) laserového paprsku na povrchu. Je to území kruhovitého nebo eliptického tvaru na povrchu. Průměr stopy závisí na výšce letu a na divergenci laserového paprsku, která má typickou hodnotu 0,1–1,0 mrad. Například při divergenci 0,25 mrad a výšce letu 1 km je průměr stopy 29 cm. Velikost stopy může být zmenšena snížením výšky letu.

### 4.1.3 Přesnost skenování

Všechny naměřené údaje mají určité limity přesnosti. Celková přesnost LLS dat leží v rozsahu 8–50 cm pro souřadnice  $X$  a  $Y$ , 8–20 cm pro výšky, v závislosti na výšce letu. Jsou tři hlavní zdroje chyb, které ovlivňují přesnost polohy laserového bodu: 1) měření skeneru; 2) IMU/GNSS měření; 3) přístrojové seřízení. Vzdálenosti jsou měřeny s chybou cca 0,02 m. Úhel skenování se měří s chybou 0,001–0,002 gon (to znamená, že v nadiru má polohová chyba hodnotu 1,6–3,2 cm při výšce 1 km). GNSS a IMU mají největší podíl na celkové chybě systému LLS. Chyby z polohy snímače  $eX$ ,  $eY$  jsou cca 8–50 cm;  $eZ$  8–20 cm a chyby v orientaci snímače  $ew$ ,  $e\phi$  jsou 5 mgon (to znamená polohovou chybu 8 cm při výšce letu 1 km) a  $e\kappa = 15$  mgon. Třetí položka obsahuje chyby v *boresight misalignment*.

ment (což jsou posuny a úhlové odchylky mezi tělem IMU a laserovým snímačem) a chybu v *lever arm* (vektor mezi GNSS anténou a referenčním bodem IMU). Všechny tyto dílčí chyby nezpůsobí chybu větší než 1 cm ve finálních datech. Další zdroje chyb o velikosti 0–5 centimetrů jsou: vliv divergence paprsku, vliv terénu a vlastnosti objektů, synchronizace času, vliv transformace souřadnicových systémů, atmosférické refrakce, správnost montáže snímače.

## 4.2 Přehled leteckých laserových skenerů

Topografické LLS systémy mohou být víceúčelovými přístroji nebo jsou navrženy pro specifické aplikace. Jejich použitelnost je dána kombinací několika základních parametrů, jako jsou maximální operační výška, maximální frekvence opakování pulsů, atd. Například při mapování koridorů, v různých inženýrských aplikacích, je požadována vysoká hustota přesně měřených dat pořízených z nižších výšek (obvykle desítky bodů na metr čtvereční) v centimetrové přesnosti. Na druhé straně je požadováno pokrytí rozsáhlějších oblastí, data musí být získána ze stále větší výšky letu. Tento druh dat umožňuje digitální mapování terénu na regionálních a národních úrovních. Současně jsou dostupné víceúčelové a zákaznicky stavěné systémy. Na trhu dominují tři hlavní komerční dodavatelé LLS: Leica Geosystems, Optech a Riegl. V Tabulce 4.1 jsou sumarizovány základní parametry několika vybraných systémů, které jsou aktuálně dostupné.

Leica Geosystems vstoupila na trh v roce 2001 a má současné modely: ALS70 CM je určen pro města a mapování koridorů, ALS70 HP je zaměřen na obecné mapování, ALS70 CM je určen pro města a mapování koridorů.

Společnost Optech vybudovala svoji sérii nazvanou ALTM (Airborne Laser Terrain Mapper). První model ALTM 1020 byl vyroben v roce 1993. Aktuální modely ALTM jsou Pegasus, Orion a Galaxy. Pegasus je zaměřen na mapování s vysokou hustotou bodů, Orion je zaměřen na inženýrské mapování z nižších výšek. Galaxy zastupuje další generaci LLS určených pro mapování větších území a sběr dat pro DTM.

Riegl vyrábí LLS systémy od roku 2003. Model LMS-Q680i je určen pro všeobecné účely. LMS-Q780 je určen pro mapování z velkých výšek. LMS-Q1560 je plně integrovaný LLS pro mapování velmi rozsáhlých oblastí.

Některé společnosti poskytují systémy vybudované specifické účely, jako například FLI-MAP od Furgo Geospatial nebo TopEye systém od Blomu (Petrie 2011).

Speciálním druhem LLS jsou batymetrické LLS, které se používají pro mapování mělké vody a přístavů (Mandlburger et al. 2011). Základní rozdíl, v porovnání s ostatními LLS, je použití dvou dálkoměrů s různou vlnovou délkou. Jeden o vlnové délce v oblasti NIR se odráží od vodní hladiny a druhý, s vlnovou délkou v zelené oblasti, prochází vodním sloupcem a odrazí se ode dna zpět. Výškové rozdíly určené pomocí obou měření umožňují určit hloubku vody až do

hloubky 25 metrů, v závislosti na znečištění vody.

V České republice operují dva systémy. V roce 2014, Argus Geo Systém používal ALS 50-II (Leica) a LMSQ-680i (Riegl). Jiný systém – LMSQ-780i (Riegl) – byl pořízen výzkumným centrem AdMaS, na VUT v Brně.

**Tabulka 4.1** Přehled základních parametrů LLS systémů dodávaných třemi hlavními výrobci, které jsou právě dostupné na trhu. (Zkratky: PRF – frekvence opakování pulsů, FOV – úhel záběru, SR – rychlosť skenování postupných profilů.)

Model	Max. výška (m)	Max. PRF (bod/sec)	Max. FOV (°)	Max. SR (Hz)
<b>Leica Geosystems</b> ( <a href="http://www.leica-geosystems.com/en/Airborne-LIDAR_86814.htm">http://www.leica-geosystems.com/en/Airborne-LIDAR_86814.htm</a> )				
ALS70 CM	1,600	500.000	75	200
ALS70 HP	3,500	500.000	75	200
ALS70 HA	5,000	250.000	75	100
<b>Optech</b> ( <a href="http://www.optech.com/index.php/products/airborne-survey/lidar-systems/">http://www.optech.com/index.php/products/airborne-survey/lidar-systems/</a> )				
Pegasus HD500	2,500	500.000	75	140
Orion C300	1,100	300.000	50	90
Galaxy	4,700	550.000	60	100
<b>Riegl</b> ( <a href="http://www.riegl.com/nc/products/airborne-scanning/">http://www.riegl.com/nc/products/airborne-scanning/</a> )				
LMS-Q680i	1,650	400.000	60	200
LMS-Q780i	3,050	400.000	60	200
LMS-Q1560	4,700	800.000	60	400

### 4.3 Pozemní laserové skenování

Pozemní laserové skenování se od leteckého odlišuje tím, že pozemní skener není v pohybu během skenovacího procesu. Během získávání dat u LLS je paprsek rozmitán v jedné rovině kolmo ke směru letu. U pozemních skenerů jsou data získávána z celé hemisféry kolem přístroje. Pro určení souřadnic bodu jsou měřeny šíkmá vzdálenost a vertikální a horizontální úhel. Pozemní skenery zaznamenávají diskrétní pulzy, nepoužívají digitalizaci vlny (*full wave digitizing*) s výjimkou několika skenerů firmy Riegl. Z hlediska přesnosti a maximálního dosahu můžeme pozemní skenery rozdělit do tří skupin: s krátkým, středním a dlouhým dosahem. Skenery s krátkým dosahem získávají data s přesností okolo 1 mm do maximální vzdálenosti 50–120 m. Tyto skenery většinou používají fázovou metodu pro měření vzdáleností, kdy vzdálenost je určována z fázového rozdílu vyslané a přijaté modulované vlny. Nejznámější výrobci téhoto skenerů jsou německé společnosti Zoller+Fröhlich and Faro, Leica Geosystems a Basis Software Inc. z USA. Jen společnost Callidus používá pulzní metodu měření pro krátký dosah

(Obrázek 4.1). Skenery se středním dosahem mají dosah obvykle 150–350 m a skenery s dlouhým dosahem mají dosah přes 500 m (1–4 km) s přesností měřených délek mezi 5 a 20 mm. Mezi známé výrobce patří Leica, Trimble, Topcon, Reigl a Optech.

## 4.4 Zpracování dat z leteckého laserového skenování

Pro zpracování dat z leteckého laserového skenování jsou obvykle vyžadovány následující kroky: 1) kalibrace systému; 2) vyrovnání řad; 3) filtrace a klasifikace bodů; a 4) speciální techniky zpracování závisející na druhu aplikace.

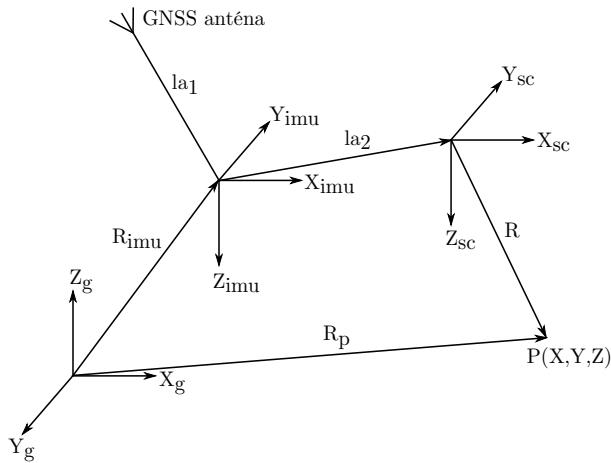
### 4.4.1 Kalibrace

Pro určení přesné polohy bodu na zemském povrchu je potřeba znát polohu a orientaci skeneru. Pro tyto účely jednotka GNSS/IMU kontinuálně zaznamenává polohu a orientaci leteckého nosiče. Tato data musí být časově synchronizována s daty ze skeneru. Skenerem jsou pořizována data s vyšší frekvencí než data pro polohu ( $\approx 10$  Hz) a orientaci ( $\approx 200$  Hz). Proto data z GNSS/IMU musí být interpolována a synchronizována s daty z LLS.

Nutná je znalost prostorového vztahu mezi LLS a složkami GNSS/IMU. Prostorový vztah je dán: 1) vektorem z referenčního bodu IMU a fyzickým centrem antény GNSS; 2) úhlovým pootočením mezi osami souřadnicového systému skeneru a IMU včetně vektoru mezi počátky systémů (Obrázek 4.3). První položka je určena geodetickým měřením, druhá kalibračním letem. Kalibrace se provádí obvykle na začátku sezony a kdykoliv, kdy je manipulováno se skenerem nebo GNSS/IMU.

### 4.4.2 Vyrovnání řad

Po výpočtu prostorové polohy bodů v jednotlivých řadách následuje vyrovnání řad. Obvyklý překryt mezi řadami je 20 %. To zabezpečuje pokrytí celého povrchu. V důsledku zbytkových systematických chyb skeneru nemají body pokrývající identické objekty v překrytu sousedících řad stejnou polohu a výšku. Cílem vyrovnání řad je odstranění těchto diferencí v rámci jednoho mračna bodů. Software pro zpracování dat z LLS umožňuje automatickou identifikaci společných objektů ve dvou překrývajících se řadách. Transformační klíč mezi řadami se vypočte metodou nejmenších čtverců. Jedna řada se vybere jako základní a ostatní se postupně připojí. Tento krok se nazývá relativní orientace řad. Absolutní orientace celého mračna bodů je provedena prostorovou transformací do geodetického systému. K tomu potřebujeme minimálně tři vlivcovací body neležící na přímce.



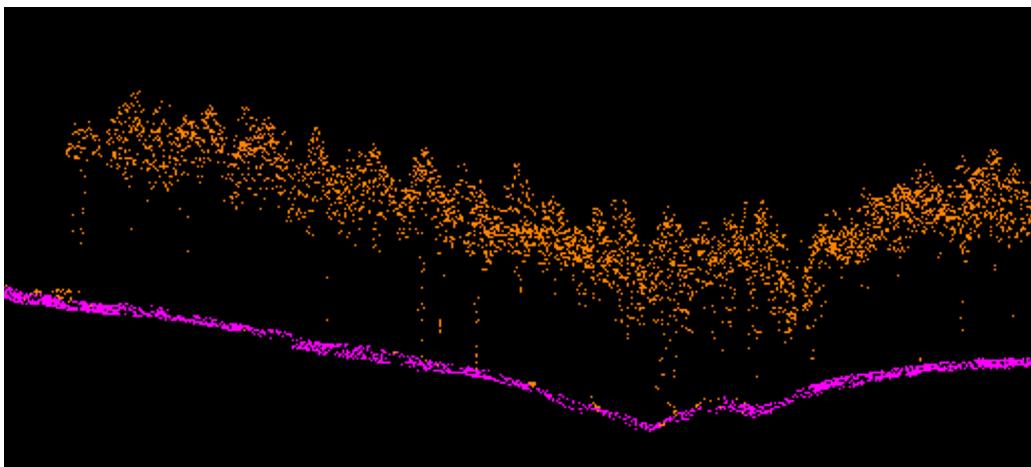
**Obrázek 4.3** Zobrazení geometrických vztahů mezi souřadnicovými systémy jednotky IMU ( $X_{imu}$ ,  $Y_{imu}$ ,  $Z_{imu}$ ), skenerem ( $X_{sc}$ ,  $Y_{sc}$ ,  $Z_{sc}$ ), geodetickým systémem ( $X_g$ ,  $Y_g$ ,  $Z_g$ ) a laserovým bodem  $P$  s neznámými souřadnicemi  $X$ ,  $Y$ ,  $Z$ . Další symboly jsou  $la_1$  – prostorový vektor z fázového centra antény GNSS do počátku souřadnicového systému inerciální jednotky,  $la_2$  – prostorový vektor z počátku souřadnicového systému inerciální jednotky do počátku souřadnicového systému skeneru,  $R_{imu}$  – prostorový vektor z počátku geodetického souřadnicového systému do počátku souřadnicového systému inerciální jednotky,  $R_p$  – prostorový vektor z počátku geodetického souřadnicového systému k určovanému bodu  $P$ ,  $R$  – prostorový vektor z počátku souřadnicového systému skeneru k určovanému bodu  $P$ .

#### 4.4.3 Filtrace a klasifikace

Nejčastěji jsou data z LLS používána pro mapování reliéfu terénu a proto klasifikace bodů rostlého zemského povrchu má velký význam. Proces klasifikace bodů odražených od rostlého povrchu země je označován jako filtrace (Obrázek 4.4). Několik filtračních technik je popsáno v literatuře (Sithole & Vosselman 2004). Dva přístupy popíšeme detailněji. První skupina filtračních algoritmů je založena na konceptu matematické morfologie. Aplikuje dvě základní operace (otevření a zavření) na mračnu bodů pro určení horního a dolního povrchu v profilu (Vosselman 2000). Druhý přístup pracuje s progresivním zhutněním souboru pozemních bodů. Nejprve jsou body vybrány jako lokální minima v řídké mříži. Další body jsou přidány podle specifických kritérií jako jsou výškové rozdíly mezi body a úhlové odchylinky (Axelsson 2000).

#### 4.4.4 Aplikace speciálních technik zpracování

Všechny další kroky pro zpracování dat jsou na konkrétní aplikace. Data z LLS jsou nejvíce používána pro: 1) digitální model terénu (viz Kapitola 4.5); 2) extrakce budov; 3) aplikace v lesnictví (viz Kapitola 9); 4) inženýrské aplikace; 5) aplikaci v oblasti dokumentace kulturního dědictví; 6) mobilní mapování. Jiné



**Obrázek 4.4** Znázornění procesu filtrace zemského povrchu. Body zemského povrchu jsou prezentovány fialovou barvou, ostatní nekласifikované body jsou prezentovány oranžovou barvou.

techniky zpracování zahrnují například klasifikaci objektů, vektorizaci, úpravu povrchů, konverzi mračna bodů do rastrového formátu. Například Obrázek 4.5 ukazuje klasifikaci objektů v městské zástavbě.

## 4.5 Digitální výškový model a jeho přesnost

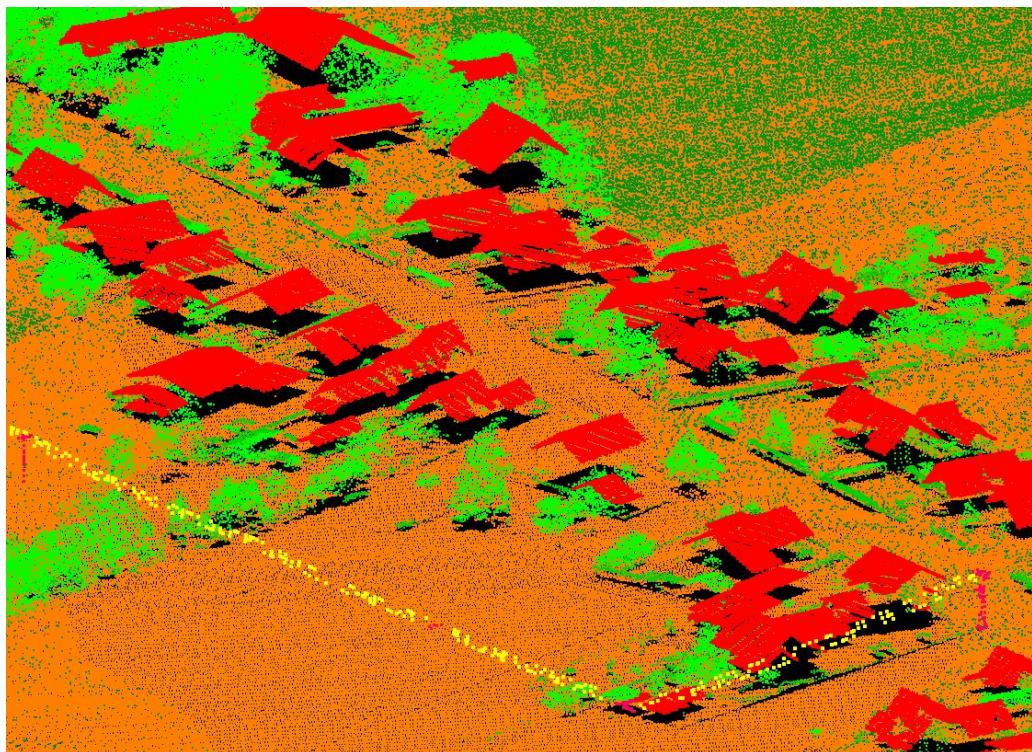
### 4.5.1 Definice pojmu

Důležité je objasnení rozdílů mezi pojmy digitální výškový model, digitální model terénu a digitální model povrchu. Definujeme digitální výškový model (DEM) jako obecný pojem pro jakýkoliv druh digitální prezentace výškových dat. Digitální model terénu/reliéfu (DMT/DMR) používáme jen pro rostlý povrch země bez vegetace a budov. Digitální model povrchu (DMP) je odvozen z prvních odrazů od ploch zahrnujících rostlý terén, povrch vegetace a ostatní povrhy objektů.

### 4.5.2 Digitální výškové modely v České republice

Do nedávna byla data z LLS v České republice poskytována privátním sektorem. V současnosti jsou data z LLS zpracována v rámci projektu následujících státních institucí: Český úřad zeměměřický a katastrální (ČÚZK), Ministerstvo obrany, Ministerstvo zemědělství. Cílem projektu je vytvoření nového výškopisu ČR na základě leteckého laserového skenování provedeného v letech 2009 až 2013. Výstupy jsou digitální model terénu 4. a 5. generace (DMR 4G, DMR 5G) a digitální model povrchu 1. generace (DMP 1G).

DMR 4G je poskytován ve tvaru diskrétních bodů v pravidelné mříži  $5 \times 5$  m.



**Obrázek 4.5** Příklad klasifikace objektů v městské zástavbě. Klasifikace mračna bodů do pěti tříd: střechy (červené body), stromy a vysoká vegetace (světle zelené body), nízká vegetace (tmavě zelené body), elektrického vedení (žluté body), povrchu terénu (oranžové body).

Jeho deklarovaná přesnost je dána střední výškovou chybou 0,3 m v otevřeném území a 1 m v zalesněném území. DMR 5G je distribuován ve tvaru trojúhelníkové nepravidelné sítě (TIN). Jeho deklarovaná přesnost je dána střední výškovou chybou 0,18 m a 0,3 m v zalesněném území. V současnosti DMR 5G pokrývá jen část území ČR, dokončen by měl být koncem roku 2015. DMP 1G je distribuován ve tvaru TIN se střední výškovou chybou 0,4 m pro objekty pravidelného tvaru jako jsou budovy, a 0,7 m pro objekty s nepravidelnými hranicemi jako je vegetační kryt. DMP 1G by měl být dokončen koncem roku 2015.

#### 4.5.3 Posouzení přesnosti DEM

ČÚZK periodicky vyhodnocuje přesnost svých produktů. Deklarovaná přesnost všech nových produktů je mnohem vyšší ve srovnání s předchozími produkty, jako je výškopis odvozený ze Základní báze geografických dat (ZABAGED) (Brázdil 2012). Nicméně v zalesněných oblastech může být přesnost nižší než deklarovaná v důsledku mnoha faktorů, které ovlivňují pronikání signálu lesním porostem.

DEM slouží jako důležitý zdroj geoprostorových informací pro plánování a hospodaření v lesích a proto je velmi důležité dobře charakterizovat přesnost nových DEM produktů v lesním prostředí. Z toho důvodu bylo Mendelovou univerzitou provedeno nezávislé ověření přesnosti nového DMR 5G modelu a vrstevnic ze ZABAGED (starší topografický model ČR produkovaný ČÚZK) v zalesněných oblastech (Cibulka & Mikita 2011; Mikita et al. 2013). Srovnávací studie byla provedena na vybraných plochách bukových a smrkových lesů. V rámci terénního šetření byly tachymetricky zaměřeny přesné souřadnice kontrolních bodů. Nicméně šance zaměřit stejné body, které jsou součástí modelu DMR 5G je nízká. K získání srovnatelných dvojic (výška z modelu vs. výška změřená v terénu) bylo nutné body DMR 5G interpolovat. Porovnáno bylo několik interpolačních technik z prostředí GIS, jako jsou metoda vážené inverzní vzdálenosti, přirozeného souseda, Delaunayova triangulace a kriging.

Střední kvadratická chyba (RMSE) vypočítaná z rozdílů výšek mezi kontrolním body a interpolovanými body DMR 5G dosáhla hodnot 0,27 až 0,43 m v závislosti na metodě interpolace. Nejvyšší chybu měla metoda vážené inverzní vzdálenosti a to pro oba typy lesa (0,43 m pro bukový porost a 0,35 pro smrkový). Jednodušší interpolační techniky (přirozený soused, Delaunayova triangulace) dosáhly v obou porostech chyby menší. Systematická složka RMSE, bez ohledu na použitou interpolační metodu, činila 0,16 m. Kladné znaménko chyby značí, že terén odvozený z dat LLS (DMR 5G) leží nad skutečným terénem. To je pravděpodobně způsobeno tím, že laserový paprsek nepronikne celým bylinným patrem a nedosáhne skutečně holého povrchu. Nicméně srovnání tachymetrických měření s modelem ZABAGED (výšky z vrstevnic) vedlo k chybám řádově vyšším, 1,6 m pro bukový a 1,0 m pro smrkový porost. V některých, heterogenních místech byla maximální odchylka až 7 m (Cibulka & Mikita, 2011).

Výsledky tohoto nezávislého hodnocení ukazují, že pokud by se podařilo odstranit systematickou chybu 0,16 m, výsledky by byly plně v souladu s deklarovanou přesností ČÚZK pro oblasti s hustou vegetací pro DM 5G. Možným řešením pro částečné překonání tohoto problému by bylo získávání LLS dat v období, kdy jsou stromy bez listí, což by zvýšilo přesnost v listnatých lesech.

### Doporučená literatura

- Shan, J. & Toth, C.K. 2009. *Topographic laser ranging and scanning: principles and processing*. CRC Press. Taylor & Francis Group.  
Petrie, G. 2011. Airborne topographic laser scanners. *GEO Informatics* 14: 34—44.



# 5

## MONITORING KVALITY VODY

*Miroslav Píkl, Blahoslav Maršálek, Eliška Maršálková,  
Marcela Pavlíková a František Zemek*

### 5.1 Úvod

Voda je na Zemi nezastupitelná v mnoha přírodních procesech, stejně jako v mnoha průmyslových odvětvích. Prakticky každý z těchto procesů vyžaduje jistou kvalitu vody. Monitoring kvality vody se tedy liší podle účelu, pro nějž bude voda použita a podle typu vodního prostředí. Jeden z hlavních celosvětově rozšířených problémů v oblasti kvality vod představuje rozvoj vodního květu sinic (Chorus 2001). Masový rozvoj vodního květu sinic byl zaznamenán v souvislosti s eutrofizací vody v mnoha jezerech, vodních nádržích, řekách a příbřežních oblastech (Pael & Paul 2012). Některé studie rovněž poukazují na zvyšující se četnost výskytu nebezpečných koncentrací vodního květu sinic (Duan et al. 2009; Kahru et al. 2007). V případě přehradních nádrží na pitnou vodu, vodních ploch využívaných pro rekreaci i rybníků, má množství a složení fytoplanktonu zásadní význam pro plnění jejich funkcí. Jedním z hlavních důsledků nadměrného rozvoje těchto organismů je pokles množství rozpuštěného kyslíku nebo i jeho úplné odčerpání, když tyto masy organismů začnou odumírat a rozkládají se. Kromě tohoto obecně platného vlivu jsou některé druhy sinic schopné produkovat toxické látky – cyanotoxiny (Rao et al. 2002). Cyanotoxiny jsou skupina látek, jež je strukturně, funkčně, fylogeneticky a toxikologicky velmi různorodá. Nejvíce

rozšířené cyanotoxiny produkované sinicemi sladkých a brackých vod jsou hepatotoxické cyklické oligopeptidy – microcystin a nodularin. Výskyt sinic není striktně vázán na otevřenou vodní hladinu. Například microcystin byl izolován z planktonních a také z bentických a půdních sinic rodů *Anabaena*, *Microcystis*, *Oscillatoria* (*Planktothrix*), *Nostoc*, *Anabaenopsis*, *Hapalosiphon* (Chorus 2001). Široké spektrum těchto biologicky aktivních látek a jejich množství, jež jsou sinice s to produkovat, jsou důvodem k vývoji nových způsobů monitoringu rozšíření vodního květu sinic.

Klasické metody monitoringu a kvantifikace fytoplanktonu jsou založeny na laboratorních mikroskopických analýzách vzorků vody. Mikroskopické rozbory jsou doplněny spektroskopickým stanovením obsahu chlorofylu. Tento přístup je omezen na odběrové místo, hloubku odběru a jeho čas. Nové přístupy k monitoringu fytoplanktonu umožňují do jisté míry postihnout distribuci fytoplanktonu v prostoru a čase. Mezi tyto metody se řadí:

- optické metody měření *in situ* (in-situ průtoková cytometrie, analytická průtoková cytometrie apod. (Goddard et al. 2005),
- in-situ fluorescenční stanovení dominantních skupin řas a sinic (Gregor et al. 2005; Gregor et al. 2007; Gregor & Maršálek 2004; Izydorczyk et al. 2005),
- letecké a satelitní optické metody dálkového průzkumu Země (DPZ).

Monitoring řas a sinic prostřednictvím DPZ je obvykle založen na kvantifikaci pigmentů: především chlorofylu (Chl), z dalších pigmentů nejčastěji fykocyaninu (Fy) (Randolph et al. 2008). Nejjednodušší empirické metody DPZ dosahují uspojovajivé přesnosti nejčastěji při vyšších koncentracích pigmentů (Cheng et al. 2013). Při nízkých koncentracích Chl nebo dalších pigmentů mohou signál pozmenit jiné opticky aktivní látky přítomné ve vodě. Mezi ně se řadí zejména rozpustěné organické látky a nerozpustěné anorganické látky. K přesnějšímu odhadu koncentrace pigmentů ve vodách s jejich malým obsahem byly vyvinuty semianalytické (Gittelson et al. 2007; Le et al. 2009) a fyzikálně založené metody (Vos et al. 2003). Oba tyto přístupy zahrnují kromě obsahu chlorofylu i další opticky aktivní látky, a proto obvykle dosahují lepších výsledků než metody empirické.

Výběr vhodné metody předběžného zpracování a následné analýzy dat DPZ musí být přizpůsoben kategorii vod. V dálkovém průzkumu vodních ploch se zpravidla rozlišují dvě základní kategorie vod:

- otevřené oceány,
- vnitrozemské a mělké příbřežní vody.

Toto rozdelení je založeno na činitelích působících na signál měřený prostředky DPZ. U otevřených oceánů je to zejména vlastní absorpcie vody a spektrální charakteristiky fytoplanktonu. U vnitrozemských a příbřežních vod mají na signál vliv rozpustěné organické látky, nerozpustné anorganické a organické částice, a v mělkých vodách i spektrální vlastnosti dna a příbřežní zóny.

Kromě monitoringu fytoplanktonu se metod DPZ používá i pro hodnocení jiných charakteristik vodních ekosystémů. Mezi nejčastější aplikace řadíme použití laserového skenování v batymetrii mělkých vod (Fernandez-Diaz et al. 2014) a mapování sedimentů (Montreuil et al. 2014). Hyperspektrální data mohou sloužit při odhadu hloubky v mělkých vodách (Ma et al. 2014) a k odhadu nerozpustěných anorganických (Giardino et al. 2014) a rozpustěných organických látek (Zhu et al. 2013). Už z krátkého výčtu je patrné, že DPZ se hodí k hodnocení značného počtu parametrů vody. Proto se v této kapitole budeme dále zabývat jen využitím letecké obrazové spektroskopie pro hodnocení koncentrací chlorofylu a fykocyaninu. Demonstrujeme jej krátkou případovou studií v oblasti vodní nádrže Brno.

## 5.2 Materiál a metody

### 5.2.1 Zájmová oblast

Vodní nádrž Brno (49,2414756 N, 16,5064217 E) zaujímá plochu 256 ha. Retenční kapacita nádrže činí 7,6 mil. m<sup>3</sup> při maximální hloubce 23 m. Mezi hlavní důvody výstavby vodní nádrže v této oblasti patřila regulace průtoku při povodňových událostech a rekreační využití. Vodní nádrž je známá rozvojem vodního květu sinic. V letech 1990–2008 byl každé léto pozorován masivní rozvoj vodního květu. Z toho důvodu byla v oblasti vodní nádrže provedena řada opatření omezujících rozvoj vodního květu sinic. Vzhledem k intenzivnímu rekreačnímu využití nádrže jsou během vegetačního období 2 × měsíčně sledovány důležité parametry kvality vody (koncentrace Chl a Fy, mikroskopické složení fytoplanktonu, koncentrace rozpustěného kyslíku, průhlednost, teplotní stratifikace vodního sloupce a vodivost).

### 5.2.2 Měření kvalitativních parametrů vody

V době leteckého snímání se uskutečnilo terénní měření parametrů vody na 10 odběrných místech. Vlastní měření byla provedena z lodi, aby se omezil vliv břehových porostů a dna. Měření probíhalo ve svrchní vrstvě (0–30 cm) vody, jelikož ta nejvíce určuje signál měřený senzory DPZ. Na každém odběrném místě byly pomocí YSI sondy (YSI Inc., USA) měřeny koncentrace Chl a Fy. YSI 6600 měří indukovanou fluorescenci chlorofylu při vlnové délce 680 nm a fykocyaninu v pásmu 650–660 nm. Současně s koncentracemi Chl a Fy byly měřeny i ostatní ukazatele kvality vody (mikroskopická analýza fytoplanktonu, vodivost, koncentrace rozpustěného kyslíku, turbidita a teplota). Dále byl zjišťován příspěvek jednotlivých skupin fytoplanktonu k celkové koncentraci chlorofylu. Pomocí Fluro-Probe (bbe Moldaenke, Německo) byly rozlišovány 4 kategorie fytoplanktonu: řasy, sinice, rozsivky, skryté řasy. Rozlišení skupin je založeno na indukci fluorescence pigmentů EM zářením o vlnových délkách 370, 470, 525, 570 a 610 nm.

### 5.2.3 Měření spektrálních dat

Pro tuto studii byly snímány tři soubory spektrálních dat: 1) laboratorní spektra roztoků řas a sinic o různých koncentracích; 2) spektra měřená v terénu současně s měřením kvality vody; 3) letecká hyperspektrální data.

Pro laboratorní měření byly připraveny 2 sady roztoků s různou koncentrací chlorofylu. První sada byla připravena pouze z řas a druhá pouze ze sinic. Spektrální měření probíhala ve spektroskopické laboratoři. Pro měření byl použit spektrometr ASD FieldSpec (ASD Inc., USA). Spektra byla měřena ve spektrálním rozsahu 400–2500 nm se spektrálním rozlišením 1 nm. Vzorky byly měřeny v Petriho miskách na otočném stolku (ASD Inc., USA). Tím byla zajištěna stálá geometrie osvitu a snímání. Před každým vzorkem byl měřen bílý referenční terč (Spectralon®), aby následně bylo možné měřit přímo reflektanci (odrazivost) vzorků.

Terénní spektrální měření se prováděla z lodi současně s měřením parametrů kvality vody (Obrázek 5.1). Jestliže předmětem zájmu jsou sinice a řasy, je současné měření podstatné proto, že prostorová distribuce řas a sinic se v čase rychle mění. Mají na to vliv jak povětrnostní podmínky, tak denní cyklus aktivity těchto organismů. Reflektanční spektra byla měřena spektrometrem ASD FieldSpec (ASD



**Obrázek 5.1** Spektrální měření v oblasti s vysokou koncentrací řas a sinic poblíž hráze.

Inc., USA) ve spektrálním rozsahu 400–2500 nm s rozlišením 1 nm. Měření byla prováděna optickým vláknem (FOV 25°) z výšky 30 cm kolmo k hladině. Na jednotlivých odběrných místech bylo zaznamenáno 6 spekter, každé jako průměr z 25 měření. Současně se spektrální informací jsme zaznamenávali GPS pozici měření. Na každém odběrném místě byl nejprve změřen bílý referenční terč (Spectralon®). Následně mohla být měřena přímo reflektance vodní plochy. Změřená terénní spektra byla korigována dynamickou parabolickou korekcí (Beal & Eamon 2009) odstraňující posuv mezi viditelnou a infračervenou částí spektra. Takto korigovaná spektra byla následně spektrálně převzorkována tak, aby odpovídala spektrálnímu rozlišení leteckého senzoru.

Letecká hyperspektrální data vodní nádrže Brno byla nasnímána 8. září 2013 pomocí skeneru AISA Eagle (Specim Ltd., Finsko). Snímek byl pořízen ve spektrálním rozsahu 400–990 nm se spektrálním rozlišením 3 nm. Prostorové rozlišení snímku je 3,5 m. Surová data byla radiometricky, geometricky a atmosféricky korigována (Kapitola 2). V důsledku nízké reflektance vody a vysokému spektrálnímu rozlišení bylo ve spektrální informaci přítomné značné množství šumu. Tento spektrální šum byl vyhlazen pomocí filtru typu Savitzky-Golay (velikost okna 9 spektrálních kanálů a polynom 2. rádu), (Savitzky & Golay 1964). Přestože letecká data byla snímána ve směru JV-SZ krátce před solárním poledнем, byly ve snímku zaznamenány přímé odrazy slunečního záření. Ty byly pravděpodobně způsobeny zčeřením hladiny větrem v době snímání. Tyto přímé odlesky byly odstraněny pomocí korekce, kterou navrhli Hedley et al. (2005). Použitá metoda odhaduje množství přímo odraženého slunečního záření v oblasti blízké infračervené oblasti spektra, kde by měl být signál vody teoreticky nulový. Po této korekci byla porovnána spektra leteckého snímkování s terénními měřeními.

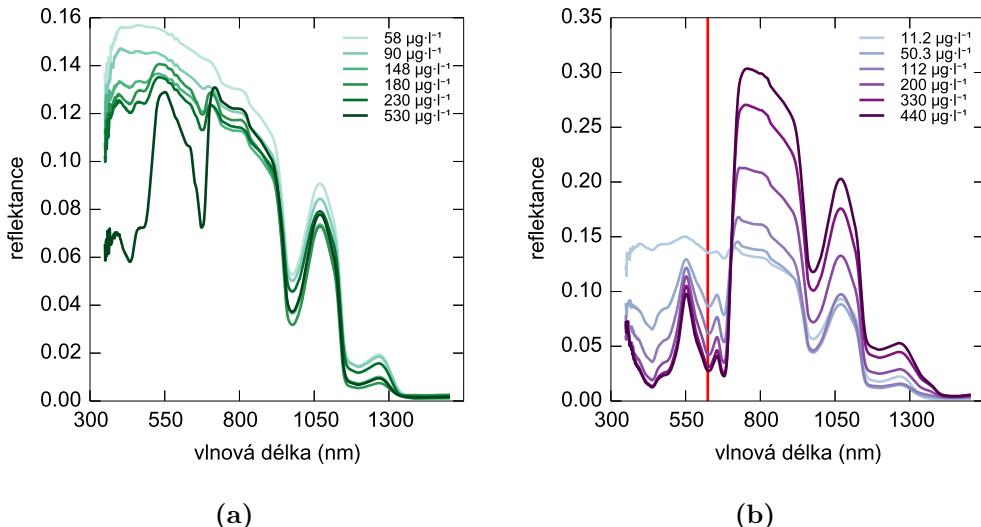
#### 5.2.4 Mapování distribuce fytoplanktonu

Distribuce řas a sinic ve vodní nádrži Brno byla zjišťována pomocí odhadu koncentrací Chl a Fy z leteckého hyperspektrálního snímku. Využili jsme statistický přístup, kdy byl nalezen empirický vztah mezi koncentracemi pigmentů a příslušnými spektrálními charakteristikami. Byly testovány 2 spektrální indexy vhodné pro odhad množství Chl a Fy. Poměrový index  $R_{700}/R_{675}$  byl nejprve použit pro odhad koncentrace Chl (Vinciková et al. 2013). Druhý poměrový index  $R_{700}/R_{600}$  byl navržen pro odhad koncentrací Fy ve vzorcích s rozdílným poměrem Chl/Fy. V případě odhadu koncentrace Fy nebylo použito jeho absorpcní maximum (620 nm) proto, že absorpcie v této vlnové délce je ovlivněna absorpcí chlorofylu, zatímco ve vlnové délce 600 nm je vliv Chl minimální (Mishra et al. 2009). Nalezené lineární vztahy mezi poměrovými indexy a koncentracemi Chl a Fy byly následně aplikovány na plochu vodní nádrže Brno v leteckém hyperspektrálním snímku.

## 5.3 Výsledky a diskuse

### 5.3.1 Spektrální odlišnosti laboratorně měřených vzorků řas a sinic

V prostředí spektroskopické laboratoře byly měřeny 2 koncentrační řady. První byla tvořena pouze řasami a druhá pouze sinicemi (Obrázek 5.2). Z obrázku je patrné, že různé koncentrace mají odlišnou spektrální odezvu, zejména v oblasti absorpce chlorofylu (460 a 680 nm). Tyto dva absorpční pásy jsou přítomné jak u řas, tak u sinic. Při srovnání těchto dvou koncentračních řad je možné pozorovat, že zákal sinic absorboval ve viditelné oblasti spektra více záření než zákal řas s podobnou koncentrací chlorofylu. Zákal sinic rovněž vykazoval vyšší hodnoty reflektance v infračervené části spektra. Sinice obsahují kromě chlorofylu i jiné, pro sinice specifické, pigmenty, které absorbují záření odlišných vlnových délek. Nejčastěji pozorovaným pigmentem je fykocyanin, jehož absorpční maximum 620 nm je znázorněno na Obrázku 5.2b červenou linií. Oblast absorpce fykocyaninu se v DPZ nejčastěji využívá pro rozlišení mezi řasami a sinicemi (Jupp et al. 1994; Srivastava et al. 2013).

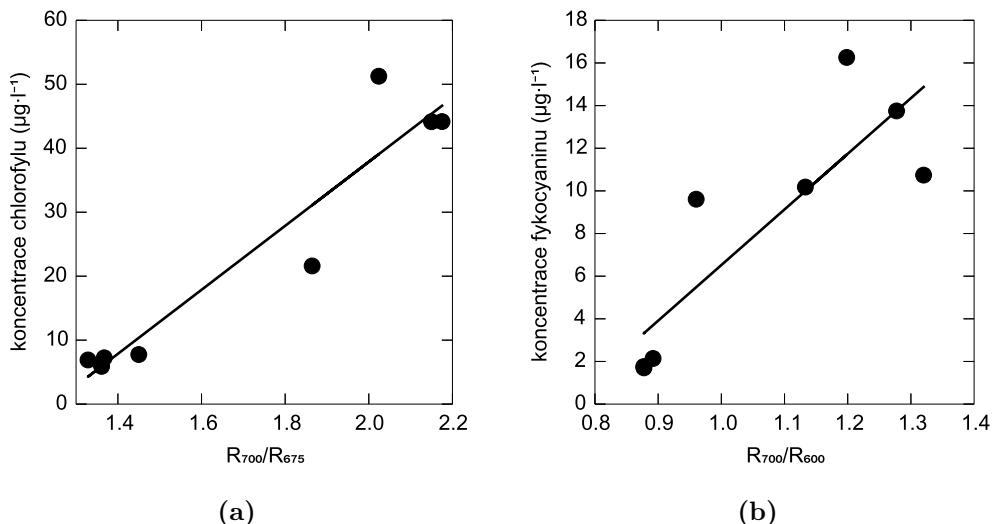


**Obrázek 5.2** Laboratorně měřená spektra koncentračních řad zákalu řas (a) a sinic (b) s rostoucí koncentrací chlorofylu-a

### 5.3.2 Distribuce řas a sinic ve vodní nádrži Brno

Pro stanovení koncentrace Chl a Fy ve vodní nádrži byly použity 2 spektrální indexy,  $R_{700}/R_{675}$  citlivý k obsahu chlorofylu a  $R_{700}/R_{600}$  reagující na obsah fykocyaninu. Mezi těmito dvěma indexy a příslušnými koncentracemi byl nalezen lineární

vztah (Obrázek 5.3). Přesnost modelu v případě Chl dosahovala podobných hodnot jako uvádí Vinciková et al. (2013). Model pro odhad koncentrace fykocyaninu vysvětluje méně variability než model pro Chl (Obrázek 5.3a vs. 5.3b). Rovněž při srovnání s výsledky, které uvádí Mishra et al. (2009), bylo dosaženo nižší přesnosti modelu pro odhad koncentrace Fy. Tento rozdíl je pravděpodobně způsoben vnějšími faktory (turbidita, rozpuštěné organické látky, odraz od okolní vegetace), které ovlivnily spektrální charakteristiky.



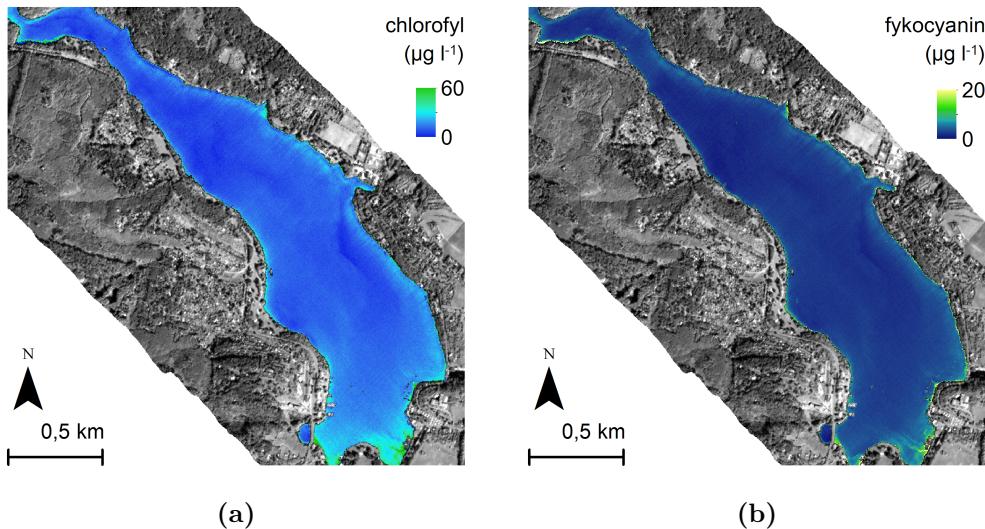
**Obrázek 5.3** Lineární vztah in-situ měřených koncentrací chlorofylu (a) a fykocyaninu (b) a příslušných spektrálních indexů vypočtených z in-situ spektrálních měření.

Pro odhad koncentrací chlorofylu a fykocyaninu byly použity následující vztahy:

$$\text{Chl} = 50.03 \frac{R_{700}}{R_{675}} - 62.19, \quad R^2 = 0.90, \quad (5.1)$$

$$\text{Fy} = 26.10 \frac{R_{700}}{R_{600}} - 19.58, \quad R^2 = 0.73. \quad (5.2)$$

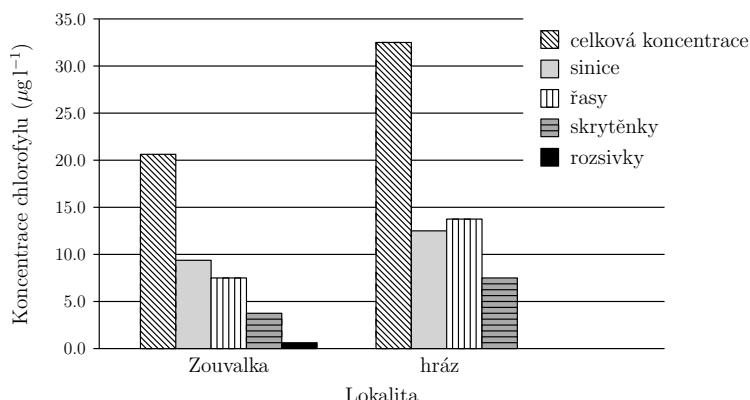
Tyto vztahy byly aplikovány na letecký hyperspektrální snímek vodní nádrže (Obrázky 5.4a, 5.4b). Na obou mapách je patrné podobné prostorové rozdělení koncentrací Chl a Fy. To je v souladu s dřívějšími pozorováními, protože mezi obsahem Chl a Fy byla zjištěna korelace (Randolph et al. 2008). Nejvyšší koncentrace obou pigmentů byly pozorovány poblíž hráze. V této oblasti se akumuluje větší množství fytoplanktonu v souvislosti s pomalým tokem vody směrem ke hrázi, a také vzhledem k blízkosti rekreační oblasti. Na mapách je rovněž patrné, že v oblasti volné hladiny byly relativně nízké koncentrace Chl a Fy. Tento stav byl rovněž potvrzen terénními měřeními, při nichž byla zjištěna nejvyšší koncentrace obou pigmentů právě v blízkosti hráze (Tabulka 5.1). Zvýšená koncentrace Chl a Fy byla zjištěna rovněž v oblasti Zouvalky, ale složení fytoplanktonu se v prostoru Zouvalky a hráze lišilo (Obrázek 5.5).



**Obrázek 5.4** Mapy koncentrací chlorofylu (a) a fykocyaninu (b) v hlavní části vodní nádrže Brno, získané z leteckých hyperspektrálních dat. Oblast hráze je zobrazena v dolním rohu snímku. Zouvalka je oblast výše proti proudu a není na snímku zobrazena.

**Tabuľka 5.1** Koncentrace pigmentov zjištene ve Vodní nádrži Brno v září 2013.

Lokalita	Počet vzorků	Chlorofyl ( $\mu\text{g l}^{-1}$ )	Fykocyanin ( $\mu\text{g l}^{-1}$ )
Otevřená vodní hladina	6	$6,4 \pm 0,12$	$4,45 \pm 0,15$
Zouvalka	2	20,7	10,2
Oblast hráze	2	32,7	10,7



**Obrázek 5.5** Složení fytoplanktonu v oblastech se zvýšenou koncentrací chlorofylu (měření FluoroProbe)

## 5.4 Závěr

Studie prokazuje vhodnost použití metod DPZ pro kvantifikaci a záznam prostorové distribuce vodního květu sinic pomocí spektrálních indexů citlivých na změny koncentrace chlorofylu a fykocyaninu. Taková mapování jsou důležitá z hlediska hygienického a ekologického. Zároveň studie poukázala na nutnost použití korekcí a úpravy změřených dat na základě pozemních měření, bez nichž nastává nebezpečí vzniku artefaktů a nesprávné interpretace dat.

### Doporučená literatura

- Chorus, I. 2001. *Cyanotoxins: occurrence, causes, consequences*. Springer - Verlag Berlin Heidelberg.
- Lindell, T., Pierson, D.C., Premazzi, G. & Zilioli, E. 1999. *Manual for monitoring European lakes using remote sensing techniques (Report EUR 18665 EN)*. European Communities. Office for Official Publications of the European Communities, Luxembourg.
- Richardson, L.L. & LeDrew, E.F. (Eds.) 2006. *Remote sensing of aquatic coastal ecosystem processes*. Springer.



# 6

## MAPOVÁNÍ SUBSTRÁTŮ A NOVĚ VZNIKAJÍCÍCH PŮD PŘI REKULTIVACI VÝSYPEK

*Jan Frouz, Miroslav Pikl, Olga Vindušková a František Zemek*

### 6.1 Úvod

Povrchová těžba uhlí má významný dopad na ekosystémy v okolí. Ekosystém zasazený těžbou je často doslova „vymazán“, bud’ je odtěžen, anebo překryt jiným materiálem. Nadložní vrstvy (hlušina) ležící nad uhelnou slojí jsou odtěženy a poté uloženy na výsypkách, což má vliv na rozsáhlou část krajiny (Bell & Donnelly 2006). V mnoha případech se tyto nadložní substráty stávají matečným substrátem pro tvorbu nových půd (Karu et al. 2009; Šourková et al. 2005).

Nadložní substráty mohou být odtěženy z velkých hloubek, často až stovek metrů. Takové substráty se významně liší od běžných půd. Mají často extrémní pH (jsou příliš kyselé nebo naopak zásadité), extrémní zrnitost (jsou štěrkovité, písčité nebo jílovité), v mnoha případech je materiál separován tak, že sestává ze zrn podobné velikosti. V nadložním substrátu mohou také být obsaženy vysoké koncentrace těžkých kovů a solí, což se odráží ve vysokých hodnotách jeho konduktivity (vodivosti půdního výluku). Substráty neobsahují recentní organickou

hmotu, ale mohou obsahovat fosilní organickou hmotu různého původu (Bradshaw 1997). Působení všech zmíněných vlastností zpravidla vede k jistému stupni toxicity těchto substrátů.

Na rozdíl od jiných ploch zasažených znečištěním, kde je toxicity výsledkem akumulace toxických látek pocházejících z vnějšího prostředí, toxicity na výsypkách je typicky výsledkem zvětrávání na nich uložených substrátů. Zvětrávání (zejména oxidace pyritu) snižuje pH a může uvolnit některé těžké kovy. Zvětrávání může také uvolnit další ionty a tím vést ke zvýšení vodivosti substrátu a jeho toxicity (Bradshaw 1997; Frouz et al. 2005).

Určení potenciální toxicity výsypkových ploch je důležité pro odhad jejich budoucího vývoje. Například na Sokolovské výsypce se při vhodném způsobu rekultivace obnoví vegetační kryt za 5–10 let. Rovněž, jsou-li plochy ponechány samovolnému vývoji, vegetace se na nich obnoví za 10–15 let. Naopak, na plochách s intenzivní oxidací pyritu, se vegetace nemusí objevit ani za 50 let od nasypání substrátu (Frouz et al. 2014).

Biologické testy nadložních substrátů ukazují, že v oblasti Sokolovska mají na jejich toxicitu největší vliv pH, konduktivita a obsah polyfenolů. Primární příčinou sníženého pH je většinou oxidace pyritu. Pyrit se v těžební oblasti vyskytuje v blízkosti uhelných slojí, a proto jsou problémy s toxicitou nejčastější u substrátů s vysokým obsahem uhlí. Identifikace uhelných příměsí v substrátu tedy může být dobrým indikátorem míry jeho toxicity. V substrátech s malou sorpční kapacitou a chudých na bazické kationty, jako jsou písek nebo kaolinit, může být pokles pH výraznější.

Kromě toxicity spojené s pyritem a uhlím může toxicity vzniknout i jinými mechanismy. Například vysoká vodivost substrátu způsobená značným obsahem karbonátů a sulfátů může být toxická pro rostliny a půdní organismy v souvislosti se zvýšeným osmotickým tlakem půdního roztoku (Frouz et al. 2005).

Identifikace fosilní organické hmoty (FOH, uhlí a kerogen) a charakteristika jejího původu může být důležitá pro rozpoznávání potenciálně toxických ploch. Po rekultivaci nebo během samovolné obnovy vegetačního krytu se postupně zvyšuje obsah recentní (nedávno vzniklé) půdní organické hmoty (RPOH) (Šourková et al. 2005). Tím se zlepšuje kvalita půdy (zvyšuje se její póravitost, provzdušnění, vodní kapacita a infiltrace srážkové vody). RPOH je také zdrojem energie a živin pro půdní organismy (Brady & Weil 1999) a navíc se stává zásobárnou uhlíku. Akumulace RPOH tak může částečně tlumit zvyšování koncentrace CO<sub>2</sub> v atmosféře (IPCC 2007; Lal 2004).

Množství RPOH se v běžných půdách stanovuje prostřednictvím obsahu organického uhlíku. V půdách uhelných výsypek se vyskytuje FOH, jež také obsahuje organický uhlík (Vindušková & Frouz 2013). Běžnými metodami pro stanovení organického uhlíku nelze odlišit recentní a fosilní uhlík. Jedinou metodou, kterou lze spolehlivě rozlišit mezi FOH a RPOH, je datování radioaktivním uhlíkem. Jde však o velmi nákladnou metodu, kterou nelze rutinně používat pro analýzu výsypkových půd. Novým přístupem k odlišení recentní a fosilní formy

organického uhlíku by mohlo být využití hyperspektrálních dat.

Dálkový průzkum Země (DPZ) je možné využít pro studium řady půdních vlastností (Ben-Dor et al. 1997; Mulder et al. 2011). Hlavním limitujícím faktorem dálkového průzkumu půd je vegetační pokryv. I když je půda zdánlivě holá, bývá pokryta fyzikálními nebo biologickými krustami, které mohou mít vlastnosti odlišné od hlubších vrstev půdy. Využití DPZ je v oblasti výsypek vhodné z několika důvodů: jsou zde velké plochy půd (substrátu) bez vegetačního pokryvu, v průběhu nasypávání probíhá homogenizace substrátu a pro některé procesy, jako jsou eroze nebo uchycení vegetace, mohou být vlastnosti svrchní vrstvy a povrchových krust důležitější než vlastnosti hlubších vrstev půdy.

V tomto příspěvku představíme možné aplikace DPZ pro mapování výsypkových substrátů s odlišnou potenciální toxicitou, pro přímý odhad toxicity těchto ploch a pro odhad obsahu fosilní a recentní organické hmoty.

## 6.2 Materiál a metodika

### 6.2.1 Studované území

V této studii byly využity dvě skupiny výsypkových ploch. V první skupině je zastoupeno 42 ploch, jež popsali Frouz et al. (2005), situovaných v blízkosti tří těžebních revírů: 1) sokolovský hnědouhelný revír – mezi Sokolovem a Chodovem (severozápadní Čechy); 2) severočeský uhelný revír – poblíž Bíliny a Ústí nad Labem (severní Čechy); 3) lužický lignitový revír – poblíž Chotěbuзи (východní Německo). Ve všech těchto revírech vznikly při povrchové těžbě rozsáhlé plochy nasypané hlušiny, kterou jsme vzorkovali. Na českém území převažují jílovité třetihorní sedimenty, zatímco v německé oblasti jsou nadložní vrstvy převážně písčité. Tato skupina ploch posloužila ke srovnání chemických a ekotoxikologických charakteristik s laboratorně změřenými spektry. Druhá skupina ploch byla vybrána na výsypkách u Sokolova (Česká republika). Na většině výsypek tvoří nadložní vrstvu třetihorní jíly cyprisového souvrství s alkalickým pH. Tyto jíly obsahují převážně kaolinit, illit a montmorillonit a 2–10 % fosilní organické hmoty. V menším rozsahu jsou zde přítomny i další substráty, zejména neutrální až slabě kyselé zvětralé tufity, sopečné popely třetihorního původu ležící pod uhelnými slojemi, kyselé jílové substráty s převahou kaolinitu, uhelné jíly, kyselé kaolinitové jíly s vysokým obsahem uhlí, a konečně jarositové krusty na třetihorních jílových substrátech. V části výsypek byly substráty zmapovány terénním průzkumem, současně bylo měřeno pH v pravidelné síti  $25 \times 25$  m a reflektance (odrazivost) jednotlivých substrátů. Tento datový soubor byl použit ke srovnání chemických a ekotoxikologických charakteristik substrátů s terénně změřenými spektry a pro klasifikaci substrátů na základě leteckých hyperspektrálních dat.

### 6.2.2 Laboratorní chemické a ekotoxikologické charakteristiky substrátů

Vzorky pro chemickou analýzu byly usušeny na vzduchu a uloženy na tmavém místě při pokojové teplotě. pH ve vodném výluhu substrátu bylo měřeno pH metrem se skleněnou elektrodou, konduktivita byla měřena konduktometrem ve zfiltrované suspenzi substrátu a vody (v poměru 1:5). Byly použity dva testy ekotoxicity: klíčení hořčice seté (*Sinapis alba*) a test na roupicích (*Enchytraeus*). Klíčení hořčice seté bylo testováno v nádobovém pokusu v květináčích, podobném pokusu Fargasové (Fargasová 1994, 1998). Tento test zjišťuje podíl semen, která vyklíčí na daném substrátu. Popis testu toxicity na roupicích uvádějí Frouz et al. (2005). Tento test měří růst populace roupic, tj. vymezeného počtu stejnověkých roupic, přidaných do zkoumaného substrátu.

### 6.2.3 Spektrální data

#### A. Laboratorní spektrální měření

Spektrální charakteristiky 42 substrátů z první skupiny ploch byly změřeny v prostředí spektroskopické laboratoře. Vzorky byly usušeny a prosety přes kalibrované 2 mm síto. Vzorky byly měřeny v černých Petriho miskách spektrometrem ASD FieldSpec (v rozsahu 350–2500 nm s krokem 1 nm). Měření probíhalo na rotujícím stolku (ASD Inc.). Tento systém zajistil u všech vzorků stejnou geometrii osvitu a snímání záření a zároveň umožnil homogenizaci spektrální informace. Spektra jednotlivých vzorků byla získána jako průměr dat z 50 měření. Bílý referenční panel (Spectralon®) byl použit pro přímé měření reflektance. Posuv mezi viditelnou a infračervenou částí spektra, který se u těchto spektrometrů vyskytuje, byl odstraněn pomocí parabolické korekce (Beal & Eamon 2009).

Vztah laboratorních spektrálních dat s pH a toxicitou substrátu byl hledán ve dvou krocích. Prvním krokem byl výpočet korelace mezi reflektancí jednotlivých vlnových délek a daným parametrem (pH, toxicita). Z takto sestavené korelační křivky se zjišťovaly vlnové délky odpovídající lokálním minimům, maximům či středním hodnotám v případě plochého průběhu křivky. Hodnoty reflektance těchto vlnových délek vstupovaly do vícenásobné krokové regrese v do předním režimu výběru proměnných (soft. Statistica 10).

#### B. Terénní spektrální měření

Terénní měření reflektance (ASD FieldSpec) devíti substrátů se uskutečnilo na 14 homogenních plochách z druhé skupiny studovaných ploch (Sokolovsko). Před měřením jednotlivých substrátů byl použit bílý referenční panel (Spectralon®), takže následně už byla měřena přímo reflektance substrátu. Naměřená spektra prošla parabolickou korekcí (Beal & Eamon 2009). Reprezentativní spektra jednotlivých substrátů byla získána jako průměr 15 opakovaných měření daného

substrátu. Tato reprezentativní spektra byla následně spektrálně převzorkována tak, aby odpovídala spektrálnímu rozlišení leteckých hyperspektrálních dat.

### *C. Letecké hyperspektrální snímání*

Letecká hyperspektrální data byla snímána v oblasti druhé skupiny ploch (Sokolov) v srpnu 2008. Pro snímání byl použit systém AISA Eagle. Data byla snímána ve spektrálním rozsahu 400–1000 nm, při spektrálním rozlišení 10 nm a prostorovém rozlišení 0,4 m. V průběhu snímání byla změřena podpůrná data, která následně sloužila pro atmosférické a geometrické korekce leteckých dat (viz. Kapitola 2). Radiometrické korekce byly provedeny v prostředí CaliGeo (Spectral Imaging Ltd.). Atmosferické korekce proběhly s využitím programu ATCOR-4.

#### **6.2.4 Identifikace substrátů z leteckých hyperspektrálních dat**

Prostorová distribuce jednotlivých substrátů byla zjišťována pomocí klasifikace leteckých dat. Klasifikace probíhala v prostředí ENVI. Pro per-pixelovou klasifikaci byl využit klasifikátor „Spectral Angle Mapper“ (SAM). Tato metoda srovnává spektrální úhly vektorů jednotlivých spekter klasifikovaných pixelů vůči referenčním spektrům (Kruse et al. 1993). Jako referenční spektra sloužila spektra z terénního měření (Kapitola 6.2.3). Pro vlastní klasifikaci byl zvolen přístup různých prahových hodnot pro jednotlivé substráty. Z toho důvodu byly v leteckém snímku vybrány zájmové oblasti se známým substrátem a vypočteny průměrné hodnoty spektrálního úhlu jednotlivých substrátů. Tyto hodnoty pak posloužily jako prahové hodnoty pro klasifikaci celého území.

#### **6.2.5 Charakterizace fosilní organické hmoty pomocí infračervené spektrometrie**

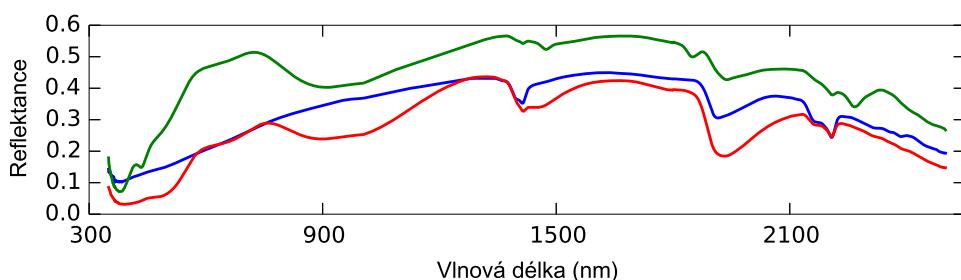
Spektra vzorků byla měřena v blízké infračervené oblasti v rozsahu vlnových délek 1000–2500 nm. Byla změřena spektra umělých směsí ( $n = 125$ ) namíchaných z jílu, uhlí a recentní organické hmoty (získané z fermentační vrstvy) a také 14 vzorků půd, v nichž byl zároveň stanoven obsah recentního a fosilního uhlíku pomocí datování radioaktivním uhlíkem (Karu et al. 2009). Obsah recentního uhlíku ve směsích byl vypočten z poměru mezi celkovou recentní organickou hmotou a jejím obsahem organického uhlíku. Celkový obsah organického uhlíku byl ve směsích vypočten jako součet obsahů organického uhlíku v jílu, uhlí a recentní organické hmotě.

Ze změřených spekter byly metodou částečných nejmenších čtverců (Partial Least Squares, PLS) (Janik et al. 2007) vytvořeny modely pro stanovení obsahu celkového organického uhlíku ( $C_{tot}$ ) a recentního uhlíku ( $C_{rec}$ ) – nejdříve pouze s použitím spekter umělých směsí a poté s přidáním spekter půd.

## 6.3 Výsledky a diskuse

### 6.3.1 Vztah laboratorně měřených spektrálních charakteristik jílových substrátů k jejich chemizmu a toxicitě

Předchozí studie (Frouz et al. 2011, 2005) ukázaly, že konduktivita a pH jsou dva hlavní faktory zodpovědné za toxicitu substrátů pro zástupce flóry i půdní fauny. Pomocí vícenásobné regrese jsme vytvořili rovnici pro predikci pH nadložních substrátů na základě laboratorních spekter (Obrázek 6.1) substrátů získaných ve třech těžebních oblastech (Tabulka 6.1). Přestože tento přístup byl velmi úspěšný při predikci pH (vztah je statisticky významný a vysvětluje přes 80 % variability v datech), hledání obdobného vztahu pro toxicitu bylo daleko méně úspěšné. Rovnice popisující vztah toxicity a spektrálních charakteristik byla sice také statisticky významná, ale vysvětlovala pouze 23 % variability dat. Tento nesoulad mezi úspěšností mezi odhadu pH a toxicity je pravděpodobně způsoben komplexností půdní toxicity, která je projevem řady faktorů (Frouz et al. 2011, 2005), jež zvolený přístup nebyl schopen odhalit. Nejčastějším důvodem toxicity je nízké pH. Nízké pH také zvyšuje rozpustnost hliníku a jiných kovů, které mohou přispívat k toxicitě substrátů. Z toho vyplývá, že efekt pH může být pozměněn přítomností



**Obrázek 6.1** Příklady měřených jílových substrátů: obrázek vlevo, zelená křivka - žlutý jíl (illit + jarosit); prostřední obrázek, červená křivka - jarosit; obrázek vpravo, modrá křivka - uhelný jíl (kaolinit + uhlí).

těchto kovů. Dalším důvodem toxicity substrátů je vysoká konduktivita způsobená vysokou koncentrací kationtů, zejména sodíku. Vysoká konduktivita je někdy spojena naopak s vysokým pH. V neposlední řadě je toxicita často spojena s přítomností uhlí. Obsah uhlí je negativně korelován s pH substrátu. Dalším způsobem, jak uhlí může přispívat k toxicitě, je přítomnost polyfenolů v uhlí (Frouz et al. 2005). Tato komplexnost toxicity je tedy důvodem, proč nebyl příliš úspěšný pokus odhadnout toxicitu na základě jednoduché funkce spektrálních vlastností.

**Tabulka 6.1** Výsledky vícenásobné regrese pro odhad a) pH a b) toxicity substrátu na základě laboratorních hyperspektrálních dat.

<b>pH (<math>R^2 = 0.801</math>, <math>p &lt; 0.00001</math>)</b>				
a)	<b>Reflektance</b>	<b>Regresní koeficient</b>	<i>SD<sup>a</sup></i>	<i>p<sup>a</sup></i>
	Kvocient	9,46	0,95	< 0,0001
	1270	-247,23	156,80	0,1241
	435–450	88,59	13,67	< 0,0001
	380–385	-105,61	18,59	< 0,0001
	350	-7,94	9,10	0,3891
	1880–1885	76,09	11,84	< 0,0001
	1425–1430	-106,47	17,97	< 0,0001
	1249	265,60	160,15	0,1064

<b>Toxicita (<math>R^2 = 0.2311</math>, <math>p = 0.0174</math>)</b>				
b)	<b>Reflektance</b>	<b>Regresní koeficient</b>	<i>SD<sup>a</sup></i>	<i>p<sup>a</sup></i>
	Kvocient	0,76	0,23	0,0024
	1290	-2,00	0,62	0,0026
	435–450	7,09	3,47	0,0481
	380–385	-6,48	4,33	0,1427

<sup>a</sup> *SD* – směrodatná odchylka, *p* – hladina významnosti testu,  
 $R^2$  – koeficient determinace

### 6.3.2 Mapování jílových substrátů pomocí leteckých hyperspektrálních snímků a jeho použití k odhadu toxicity

Jednotlivé nadložní substráty mají podobné chemické vlastnosti a hodnoty toxicity (Frouz et al. 2005) často odlišné od odpovídajících hodnot ostatních substrátů. Proto pokud zmapujeme substráty, můžeme toxicitu v daném území odhadnout kombinací mapy substrátů a průměrných toxicit pro dané substráty. Spíše než

hledání přímého vztahu mezi spektry substrátů a toxicitou, může tedy být slibnější využít hyperspektrální data pro klasifikaci substrátů a tuto klasifikaci poté kombinovat s průměrnými laboratorními hodnotami toxicity těchto známých substrátů.

Jednotlivé substráty jsme klasifikovali z leteckých hyperspektrálních dat pomocí SAM. Dosažená celková úspěšnost klasifikace byla 71,18 %. Výsledky klasifikace jsou uvedeny v Tabulce 6.2. Jílové substráty cyprisového souvrství byly pro potřeby klasifikace rozděleny do podtříd, tj. na žluté a šedé. Obě tyto podtřídy převažují v daném území a u obou byla přesnost klasifikace nejvyšší.

Pomocí této klasifikace byla poté pro vybrané území Podkrušnohorské výsypky s vysokou variabilitou substrátů o rozloze asi 1 ha vytvořena mapa substrátů (Obrázek 6.2a). Kombinací této mapy a průměrných toxicit pro jednotlivé substráty byl získán prostorový odhad toxicity na zkoumaném území. Z tohoto území bylo dále odebráno 14 náhodných vzorků, v nichž byla testována toxicita na hořčici seté (*S. alba*). Ze srovnání toxicity odhadované pomocí hyperspektrálních dat a toxicity změřené v těchto 14 bodech vyplývá, že odhad pomocí hyperspektrálních dat vysvětluje asi 55 % variability dat. To je více, než pokud odhadneme toxicitu na základě hodnot pH extrapolovaných z pravidelné sítě bodů, které vysvětlily pouze 21 % variability dat (Obrázek 6.2b).

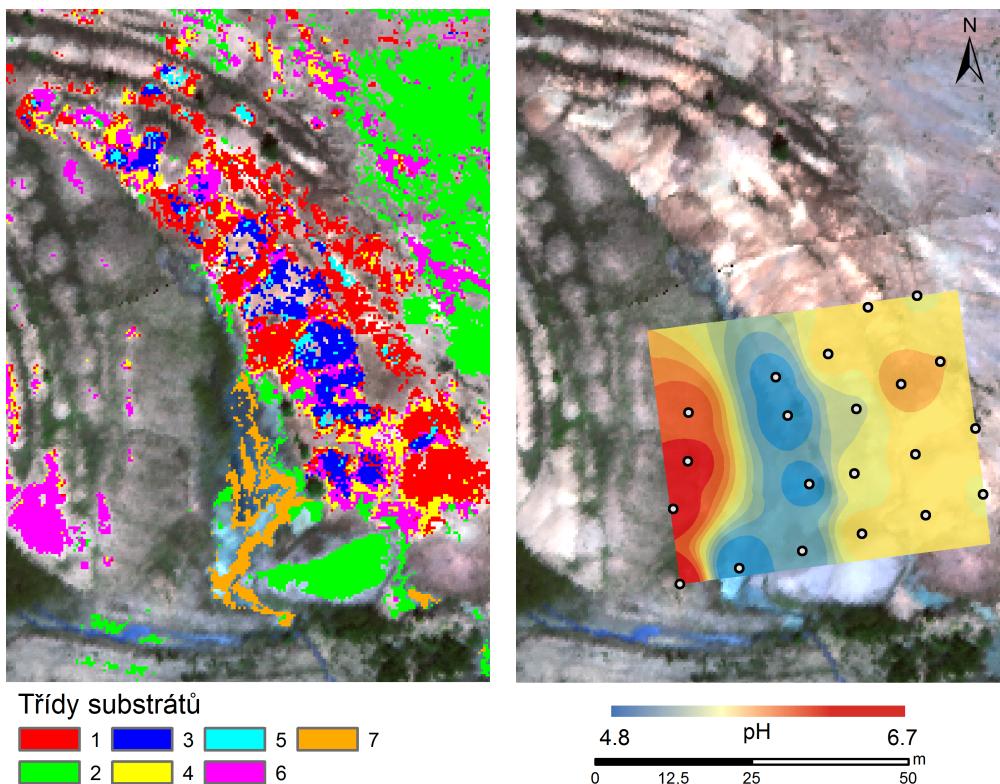
Důvod, proč hyperspektrální mapování je v tomto případě mnohem úspěšnější při predikci toxicity, souvisí se způsobem vzniku výsypky. Při jejím nasypávání vznikají hromady různých tvarů a velikostí a rozlišení vzorkovací sítě 25 × 25 m není dostatečně pro jejich přesné zmapování. Hranice těchto hromad jsou velice ostré a v podstatě neodhadnutelné klasickými interpolačními přístupy.

**Tabulka 6.2** Přesnost klasifikace jednotlivých výsypkových substrátů na Podkrušnohorské výsypce u Sokolova.

Substrát	Producer Accuracy <sup>a</sup> [%]	User Accuracy <sup>b</sup> [%]
uhelné jíly	97,76	51,82
jíly cyprisového souvrství – žluté	100,00	99,76
tufity	48,85	100,00
kaolinitové jíly	76,49	99,48
podložní zeminy	27,27	25,53
jíly cyprisového souvrství – šedé	93,42	85,34
uhelné směsi	50,00	97,40
uhlí	60,89	100,00
jarositové krusty na jílech	49,02	100,00

<sup>a</sup> Producer Accuracy – udává podíl pixelů správně klasifikovaných v oblasti označené jako určitá třída.

<sup>b</sup> User Accuracy – udává podíl pixelů správně klasifikovaných jako určitá třída vůči celkovému počtu pixelů klasifikovaných jako tato třída.



**Obrázek 6.2** Obrázek vlevo: mapa klasifikace substrátů získaná z hyperspektrálních dat, číselné kódy substrátů: 1 – uhlerné jíly; 2 – jíly cyprisového souvrství žluté; 3 – tufity; 4 – podložní zeminy; 5 – kaolinitové jíly; 6 – jíly cyprisového souvrství šedé; 7 – jarosit. Obrázek vpravo: pH interpolované z terénních měření.

### 6.3.3 Můžeme pomocí infračervené spektrometrie odlišit recentní a fosilní organickou hmotu v půdách výsypek?

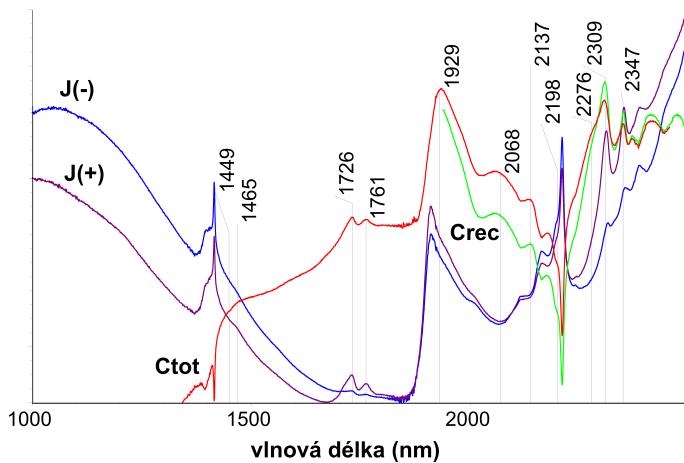
Abychom zjistili, zda můžeme odhadnout z hyperspektrálních dat obsah recentního a fosilního uhlíku, porovnávali jsme odhadované hodnoty recentního a celkového organického uhlíku s jejich známými hodnotami (zjištěnými radiouhlíkovým datováním a elementární analýzou).

Kalibrační modely sestavené pouze na základě umělých směsí nedokázaly dobře předpovědět ani recentní, ani celkový uhlík v půdách. Nicméně, po přidání spekter půd do kalibrace, se predikční schopnost kalibračních modelů významně zlepšila – jak ukazují parametry pro hodnocení úspěšnosti odhadu: směrodatná odchylka křížové validace (RMSECV) a účinnost modelování (EF). Modely poskytly velmi dobrý odhad uhlíku jak recentního (RMSECV=0,70, EF=0,95), tak celkového (RMSECV=0,85, EF=0,94) (Loague & Green, 1991; Michel et al. 2009). Parametry těchto modelů jsou srovnatelné nebo lepší než ty, které uvádějí jiní autoři do-

poručující použití infračervené spektrometrie pro stanovení různých frakcí uhlíku (Bornemann et al. 2008; Michel et al. 2009).

Přidání půd do kalibrací mělo významný zlepšující efekt na úspěšnost kalibrací, neboť spektra směsí a půd jsou přece jen odlišná, tzn. mají odlišné spektrální charakteristiky. To je pochopitelné, protože se dá předpokládat, že organická hmota v půdách je relativně starší a tedy i více přeměněná než organická hmota přidaná do směsí. Zároveň fosilní organická hmota v půdách může být již pozměněna zvětráváním a dekompozicí. Vzorky půd mohou být také různorodější ve svém minerálním složení, jež má vliv na spektra v blízké infračervené oblasti.

Spektrální charakteristiky, které byly nejvýznamnější pro predikci obsahů recentního a celkového organického uhlíku, jsou patrné z grafů záteží prvního faktoru v Obrázku 6.3, kde jsou uvedeny spolu se spektry dvou jílovčů. Jednotlivé vrcholky (lokální extrémy) dobře odpovídají již dříve popsaným absorpčním pásmům charakteristickým pro půdní organickou hmotu v blízké infračervené oblasti (Ben-Dor et al. 1997; Michel et al. 2009; Stenberg et al. 2010); jejich popis je uveden v Tabulce 6.3. I vizuální interpretaci si můžeme všimnout, že absorpcie typické pro alifatické struktury (1726 a 1761 nm) jsou výraznější ve spektru jílovce bohatšího na uhlík. Shodné vrcholky najdeme i v grafu záteží pro celkový uhlík ( $C_{tot}$ ). To ve studované oblasti odpovídá alifatické povaze fosilní organické hmoty, kterou tvoří převážně kerogen řasového původu (Kříbek et al. 1998).



**Obrázek 6.3** Graf záteží prvního faktoru pro kalibrace na celkový ( $C_{tot}$ ) a recentní uhlík ( $C_{rec}$ ) spolu se spektry jílovčů s vysokým (J(+)) a nízkým (J(-)) obsahem uhlíku. Popis vrcholků je uveden v Tabulce 6.3.

**Tabulka 6.3** Popis absorpčních vrcholků (dle Ben-Dor et al. 1997; Michel et al. 2009; Stenberg et al. 2010)

Vlnová délka (nm)	Původ absorpce	Odpovídající látky
1449	$4\nu$ C=O	karboxylové kyseliny
1465	OH ve vodě ( $\nu_2 + \nu_3$ ); CH <sub>2</sub>	celulóza/lignin/škrob/ pektin
1582	OH ve vodě (2 $\nu$ ); OH skupina vázaná přes H	pektin/škrob/celulóza
1726	2 $\nu$ valenční vibrace alifatické C-H	celulóza/lignin/škrob/ pektin/vosk/huminová kyselina
1761	2 $\nu$ valenční vibrace alifatické C-H	celulóza/lignin/škrob/ pektin/vosk/huminová kyselina
1929	OH ve vodě ( $\nu_1 + \nu_3$ ); 3 $\nu$ -C=O a -COOH, C=O ketonů, CONH <sub>2</sub>	celulóza/lignin/glukan/ pektin/vosk/huminová kyselina
2068	3 $\nu$ aromatické C=C, COO-H vazba, C=O	celulóza/glukan/pektin
2137	3 $\nu$ aromatické C=C, COO-H vazba, C=O	celulóza/glukan/pektin
2198	3 $\nu$ aromatické C=C	škrob/lignin/vosk/taniny
2276	kombinace O-H valenční vibrace a C-O celulózy; kombinace C-H valenční vibrace a CH <sub>2</sub> deformace škrobu	celulóza/škrob
2309	3 $\nu$ of aliphatic C-H, aromatic ring stretch	huminová kyselina/ vosk/škrob
2347	3 $\nu$ of aliphatic C-H	celulóza/lignin/glukan

## 6.4 Závěry

V tomto příspěvku jsme představili využití dálkového průzkumu Země pro studium výsypek a velký potenciál tohoto přístupu pro praktické aplikace. Spektrální měření čistých substrátů je možno využít pro hodnocení jejich pH. Použití samostatné spektroskopie pro odhad toxicity substrátů dostatečně nepostihuje její komplexní charakter. Naopak klasifikace substrátů pomocí hyperspektrálních dat vede k mnohem přesnějšímu odhadu toxicity substrátů než interpolace chemických vlastností vzorků stanovených v laboratoři.

Infračervená spektrometrie v kombinaci s metodou částečných nejmenších čtverců přináší přesné odhady recentního a celkového uhlíku v půdách výsypek. Tato metoda je jednodušší, rychlejsí a levnější alternativou k finančně a časově náročnému datování pomocí radioaktivního uhlíku.

### Doporučená literatura

- Ben-Dor, E., Chabrillat, S., Dematte, J.A.M., Taylor, G.R., Hill, J., Whiting, M.L. & Sommer, S. 2009. Using Imaging Spectroscopy to study soil properties. *Remote Sensing of Environment* 113: S38–S55.
- Boettinger, J.L., Howell, D.W., Moore, A.C., Hartemink, A.E. & Kienast-Brown, S. 2010. *Digital Soil Mapping*. Springer, 473 p.
- Brady, N.C. & Weil, R.R. 1999. *The nature and properties of soils*. Prentice Hall, Upper Saddle River.
- Mulder, V.L., de Bruin, S., Schaepman, M.E. & Mayr, T.R. 2011. The use of remote sensing in soil and terrain mapping – A review. *Geoderma* 162: 1–19.
- Stenberg, B., Viscarra Rossel, R.A., Mouazen, A.M. & Wetterlind, J. 2010. Chapter Five - Visible and Near Infrared Spectroscopy in Soil Science. *Advances in Agronomy* 107: 163–215.
- Ussiri, D.A.N., Jacinthe, P.-A. & Lal, R. 2014. Methods for determination of coal carbon in reclaimed minesoils: A review. *Geoderma* 214–215: 155–167.

# 7

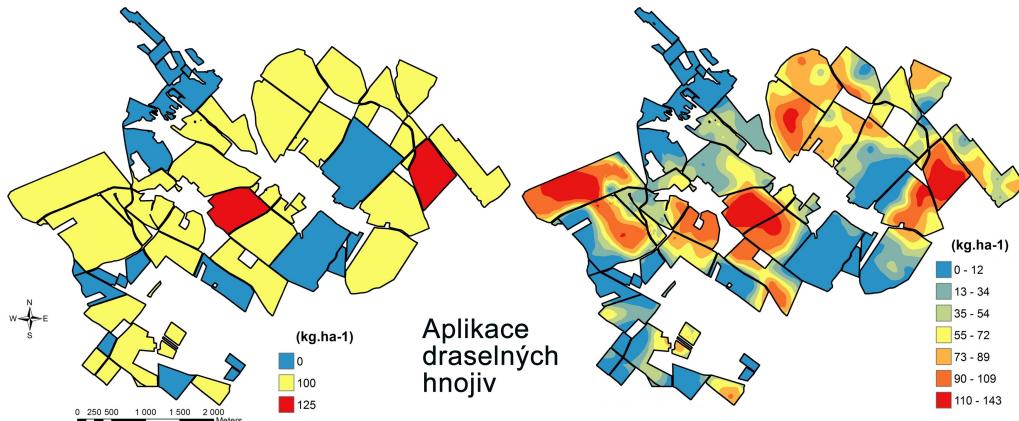
## APLIKACE DPZ V PRECIZNÍM ZEMĚDĚLSTVÍ

*Vojtěch Lukas, Fernando Rodriguez Moreno, František Zemek,  
Petr Hlavinka, Jan Křen, Daniela Semerádová a Zdeněk Žalud*

Zemědělské podniky v současnosti obhospodařují 4.264 tis. ha zemědělské půdy v České republice, to je přibližně polovinu (54 %) celkové výměry země. Převážnou část této plochy tvoří orná půda, na které jsou pěstovány zemědělské plodiny. Více než 54 % zemědělské půdy obhospodařují zemědělské podniky s výměrou nad 1000 ha (Ministry of Agriculture 2010). Z výsledků statistického hodnocení údajů v Registru půdy (LPIS) vyplývá, že přes 40 % plochy orné půdy tvoří pozemky s výměrou nad 20 ha. Úspěšná rostlinná produkce v takto definovaných podmínkách se neobejde bez pokročilých postupů rozhodování.

Lokálně cílené hospodaření, častěji označované jako precizní zemědělství, je mezinárodně přijatý název pro směr hospodaření na zemědělské půdě, který využívá nové technologie vyvinuté v 80. a 90. letech 20. století. Cílem precizního zemědělství je optimalizace produkčních vstupů (hnojiva, pesticidy, pohonné hmoty apod.) na základě lokálních požadavků rostlin a půdních podmínek. Tímto způsobem je možno při pěstování rostlin dosáhnout efektivního využívání agrochemikálů a minimalizovat rizika ohrožení životního prostředí.

Optimalizace produkčních vstupů, zohledňující prostorovou variabilitu jednotlivých honů (Obrázek 7.1), svou podstatou naplňuje cíle trvale udržitelného zemědělství (Corwin & Plant 2005).



**Obrázek 7.1** Příklad uniformní (a) a variabilní (b) aplikace draselných hnojiv na pozemcích zemědělského podniku o výměře 1500 ha. Dávka hnojiv je stanovena podle zásoby živin v půdě (adaptováno z práce autorů: Lukas et al. 2011b).

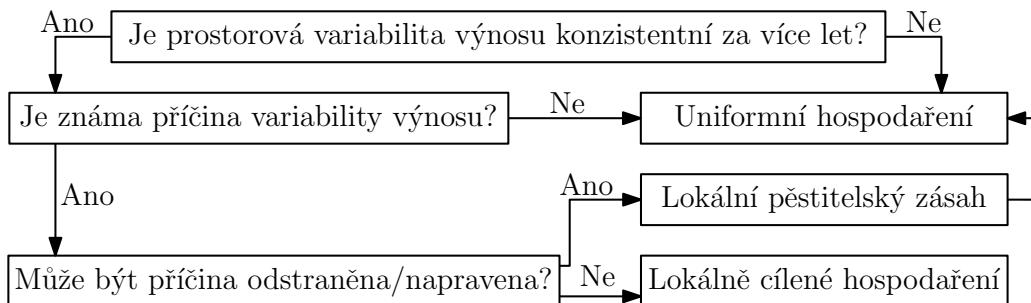
Základní principy precizního zemědělství nejsou nové; pěstitelé již před staletími věděli, že půda i porost se mohou lišit i v měřítku jednotlivých pozemků. Menší výměra pozemků a manuální zásahy umožňovaly eliminaci lokálních rozdílů. S vytvářením větších půdních celků, intenzifikací produkce a rostoucí mechanizací v polovině 20. století však nebylo možné heterogenitu pozemků zohlednit bez moderních technologií. Až teprve rozvoj globálních navigačních družicových systémů (GNSS), informačních a komunikačních technologií (ICT), dálkového průzkumu Země (DPZ) a geografických informačních systémů (GIS) významně přispěly ke sběru a zpracování dat nezbytných pro precizní hospodaření.

#### *Význam stanovení prostorové variability pozemků*

Pierce & Nowak (1999) považují zjištění prostorové variability pozemků za první kritický krok k optimalizaci rostlinné výroby, neboť nelze optimalizovat něco, co neznáme. Faktory působící na růst rostlin a následný výnos se mění v prostoru a čase. Čím je výraznější heterogenita půdních podmínek nebo porostů, tím spíše je možno očekávat potenciální uplatnění technologií precizního zemědělství a s ním spojené přínosy.

Heterogenita pozemků se nejvíce projevuje na výnosu plodin. Variabilita výnosu stanovená z výnosových map poskytuje významnou informaci pro rozhodování o variabilní aplikaci pěstebních metod. Pokud není známa příčina variability výnosu, je doporučeno uniformní hospodaření (Adamchuk et al. 2010, Obrázek 7.2). Lokálně cílené hospodaření je možné v případě, kdy jsou oblasti

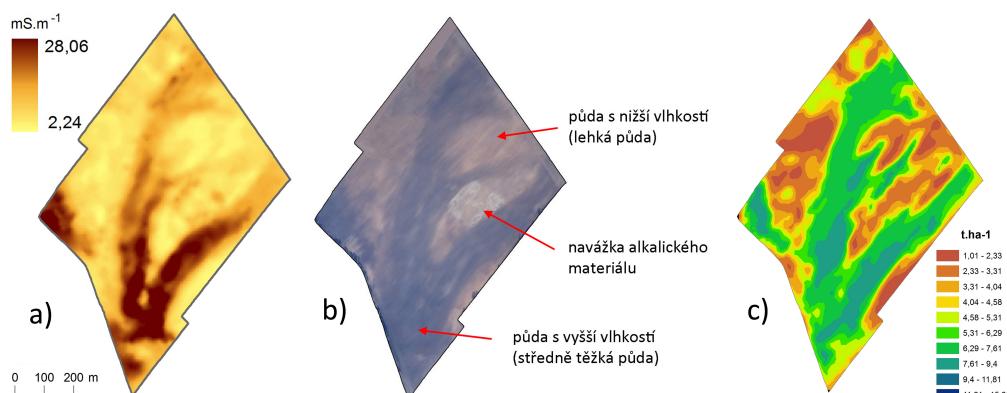
s rozdílným výnosem konzistentní po více let a korespondují s nějakou agronomický významnou vlastností pozemku, například zásobou živin, topografií, historií užívání půdy atd.).



**Obrázek 7.2** Rozhodovací diagram o aplikaci lokálně cíleného hospodaření na základě variability výnosu (adaptováno podle: Adamchuk et al. 2010).

## 7.1 Mapování prostorové variability půdních vlastností

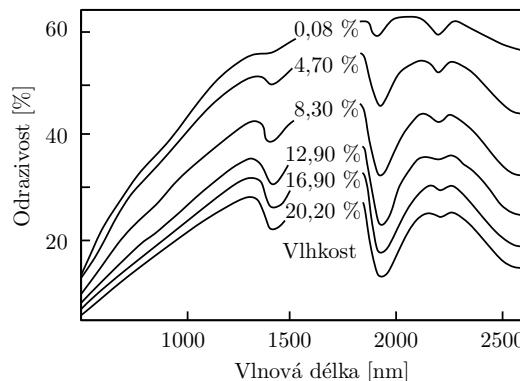
Tradiční postupy mapování variability půdních podmínek jsou postupně nahrazovány nepřímými metodami, jako je on-the-go měření (přehled viz Adamchuk et al. 2004) nebo dálkový průzkum. Menší přesnost stanovení půdních vlastností, v porovnání s tradičními laboratorními rozbory, je kompenzována širokým prostorovým pokrytím (Christy 2008).



**Obrázek 7.3** (a) Mapa elektrické vodivosti půdy, (b) totéž v leteckém snímku ve viditelném spektru, a (c) mapa variability výnosu na 52 ha pozemku. Zobrazené hodnoty mají obdobné prostorové rozložení (adaptováno podle: Lukas 2011a).

Elektrická půdní vodivost (EC), mapovaná na základě bodové sítě měření, patří k nejčastěji používaným parametrym precizního zemědělství, který charakterizuje variabilitu půdních podmínek (Corwin & Lesch 2003). Pro elektrickou vodivost půdy je rozhodující kombinace fyzikálních a chemických vlastností půdy, zahrnující podíl rozpustných solí v půdním roztoku, zastoupení jílových částic, vlhkost půdy, objemovou hmotnost půdy, obsah organické hmoty a teplotu půdy (Corwin & Lesch 2005). Komplexní působení těchto faktorů znesnadňuje přímé využití EC pro lokálně cílené hospodaření kvůli obtížnému stanovení jednotlivých půdních vlastností (Obrázek 7.3).

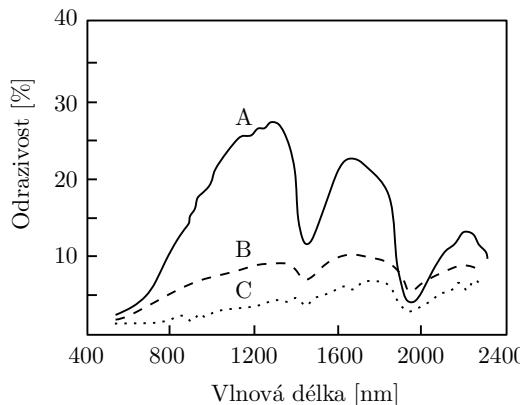
Mapování půdních vlastností pozemků a vegetace pomocí dálkového průzkumu Země se v zemědělství vyvídí dlouhodobě s rozvojem nástrojů a metod DPZ. Tyto postupy rozpoznávají rozdílné půdní podmínky na základě spektrálních vlastností půdního povrchu. Baumgardner et al. (1985) popisují základní spektrální vlastnosti půdy. Podobně jako u geofyzikálních metod nelze pomocí dálkového snímání stanovit specifické půdní vlastnosti bez dodatečného terénního průzkumu. Spektrální projevy půdy jsou výslednicí většího počtu vlastností půdy. K nejvýznamnějším patří obsah organické hmoty, vlhkost půdy, zrnitost a struktura půdy, zastoupení oxidů železa (Lilienthal 2003), případně hrubost povrchu (Lillesand et al. 2008). Podrobný popis působení těchto faktorů podávají např. Baumgardner et al. (1985), Lilienthal (2003), van der Meer & de Jong (2006) a Ben-Dor et al. (2009).



**Obrázek 7.4** Vliv půdní vlhkosti na odrazivost půdy (adaptováno podle: Lilienthal 2003).

Zvyšující se půdní vlhkost obecně snižuje odrazivost, zejména ve viditelném spektru (400–700 nm). Vlhčí půda se proto v porovnání se suchou jeví tmavší. Pro spektrální křivku půdy je charakteristická absorpcie záření ve 1400 a 1900 nm, způsobená obsahem vody v půdě (Obrázek 7.4). Zvýšený obsah organické hmoty snižuje odrazivost v celém spektru (Obrázek 7.5) (Baumgardner et al. 1985).

Pro zrnitost půdy obecně platí, že se vzrůstem velikosti půdních částic vzrůstá odrazivost ve viditelné části spektra. Jílovité půdy se jeví tmavší než půdy písčité. Zrnitost půdy podmiňuje některé další půdní vlastnosti, zejména vlhkost půdy



**Obrázek 7.5** Spektrální charakteristiky půdy při rozdílném obsahu organické hmoty: A – fibrické půdy s menším podílem rozložitelné organické hmoty; B – hemické půdy; C – saprické půdy s větším podílem organické půdy (adaptováno podle Baumgardner et al. 1985).

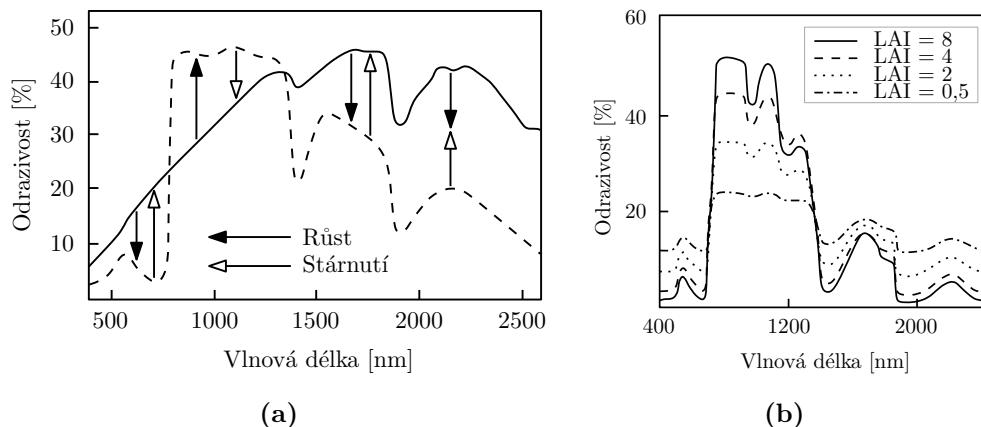
a její strukturu, jež se projevují na celkové odrazivosti půdy. Exaktní stanovení vlivu zrnitosti půdy je proto obtížné (van der Meer & de Jong 2006). Přesnost klasifikace zrnitosti půdy z hyperspektrálních dat se zvýší správným načasováním měření za optimálních vlhkostních podmínek, kdy rozdíly mezi půdními typy jsou nejvízrazenější (Casa et al. 2013).

Ačkoliv dálkový průzkum a geofyzikální mapování jsou dvě odlišné metody pracující na zcela rozdílných fyzikálních principech, mohou poskytovat obdobné výsledky. Jak ukazuje De Benedetto et al. (2013), kombinace těchto metod umožňuje úspěšnou identifikaci části pozemků se shodnými produkčními vlastnostmi, tzv. managementové zóny.

## 7.2 Zjišťování variability porostů dálkovým průzkumem

Hodnocení porostů pomocí DPZ je využíváno pro klasifikaci využívání zemědělské půdy a identifikaci zemědělských plodin, dále pak pro diagnostiku stavu výživy rostlin, detekce stresu rostlin a predikci výnosu zemědělských plodin. Základní popis spektrálních vlastností rostlin a porostů je uveden v Kapitolách 1 a 2. Tento popis platí zejména pro zdravou (zelenou) vegetaci. Pro stresované nebo stárnuoucí rostliny je typické zvýšení odrazivosti v červené a blízké infračervené části spektra (Obrázek 7.6). Spektrální měření umožňuje rozpoznávat stresové projevy rostlin, ale obvykle bez určení jejich příčiny (deficit vláhy, živin, napadení chorobami aj.).

Mnoho odborných studií popisuje spektrální odrazivost v oblasti viditelné a blízké infračervené (NIR) části elektromagnetického záření. Tato odrazivost je vhodná pro stanovení biofyzikálních parametrů rostlin na základě vegetačních in-



**Obrázek 7.6** Změny spektra záření odráženého vegetací (podle práce: Lilienthal 2003): (a) v průběhu růstu a stárnutí rostlin; (b) vlivem rozdílných množství biomasy porostu hodnocené podle pokryvnosti listoví (LAI).

dexů. Například Li et al. (2014) uvádí větší počet hyperspektrálních vegetačních indexů využitelných pro stanovení obsahu dusíku v porostu ozimé pšenice. V případové studii uvedené v této kapitole, byly použity čtyři vegetační indexy pro popis heterogenity porostu jarního ječmene: 1) NDVI (z anglického Normalized Difference Vegetation Index); 2) REIP (Red Edge Inflection Point); 3) PRI (Photochemical Reflectance Index); 4) WBI (Water Band Index). Informace o dalších vegetačních indexech měřených v úzkých spektrálních pásmech obsahuje Kapitola 8 (Tabulka 8.1).

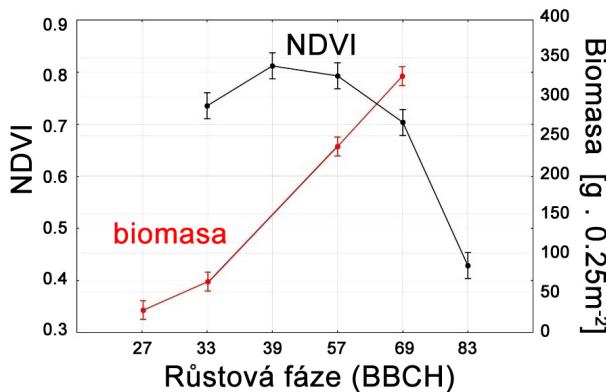
1. NDVI byl původně vyvinut pro stanovení zastoupení vegetace v území ze širokopásmových satelitních snímků (Rouse et al. 1974). Normovaný výpočet, na rozdíl od jednoduchých poměrových indexů, umožňuje redukovat některé rušivé prvky v obrazu, jako jsou rozdílné osvětlení snímané scény, stíny a atmosférické vlivy, neboť jejich působení je v rozdílných pásmech odrazivosti zpravidla podobné. Rovnice pro výpočet NDVI ze širokopásmových senzorů je:

$$\text{NDVI} = \frac{R_{NIR} - R_{Red}}{R_{NIR} + R_{Red}}, \quad (7.1)$$

kde,  $R_{NIR}$  a  $R_{Red}$  jsou hodnoty odrazivosti v blízkém infračerveném a v červeném pásmu EM. Při použití hyperspektrálních dat se výpočet provede z vybraných vlnových délek, obvykle  $R_{665}$  a  $R_{801}$ . Výsledek výpočtu NDVI je bezrozměrná veličina nabývající hodnot v intervalu  $(-1, 1)$ .

Výsledky polních pokusů s ozimou pšenicí a jarním ječmenem ukázaly, že vyšší hodnoty NDVI indikují větší množství biomasy, vyšší hmotnost rostlin, větší hustotu porostu (počet rostlin na  $m^2$ ), více odnoží na rostlinu a lepší stav výživy rostlin (vyšší obsah chlorofylu). Tyto vlastnosti porostů se následně projeví ve vyšším výnosu plodin (Křen et al. 2009).

Vztah mezi hustotou porostu a NDVI není lineární, neboť NDVI vykazuje tzv. nasycení ve velmi hustém porostu (s vysokou hodnotou LAI) (Baret & Guyot 1991). Od dosažení jisté hodnoty LAI (nebo množství nadzemní biomasy) se již NDVI nemění. Nastane zmíněné nasycení a NDVI proto není použitelný (Obrázek 7.7).



**Obrázek 7.7** Vztah mezi širokopásmovým NDVI a biomasou ozimé pšenice v průběhu vegetačního období 2013.

2. Perspektivním indexem pro hodnocení využití dusíku porostem je Red Edge Inflection Point (REIP), který udává vlnovou délku inflexního bodu spektrální křivky v tzv. „red edge“ oblasti. Umístění tohoto bodu se zpravidla pohybuje v oblasti 700–740 nm. Zvýšení koncentrace chlorofylu v rostlinách nebo přírůst biomasy způsobují jeho posun do vyšších vlnových délek (Heege et al. 2008). Pozitivní vlastnosti REIP je jeho menší citlivost k rušivým faktorům, jako jsou odražené záření od půdního pozadí a atmosférické vlivy. Zároveň je index REIP vysoko citlivý k požadovaným porostním charakteristikám (obsah chlorofylu a hustota porostu). Na rozdíl od NDVI u REIP nenastane jeho nasycení při vyšším LAI.

Výpočet REIP je možný více způsoby, z nichž zde uvedeme dva: 1) numerickým výpočtem druhé derivace křivky odrazivosti porostu (Miller et al. 1990; Cho & Skidmore 2006); 2) lineární interpolací ze čtyř spektrálních pásem podle empirické rovnice (Guyot et. al. 1988):

$$\text{REIP} = 700 + 40 \frac{(R_{670} + R_{780})/2 - R_{700}}{R_{740} - R_{700}} [\text{nm}]. \quad (7.2)$$

Citlivost vegetačních indexů na koncentraci dusíku v listech rostlin byla sledována v četných odborných studiích. Mariotto et al. (2013) uvádějí, že úzkopásmové hyperspektrální senzory zachycují o 25 % vyšší variabilitu při modelování růstu rostlin a mají o 20 % vyšší přesnost rozlišení druhů plodin ve srovnání s širokopásmovými senzory. Současně platí, že 3–7 úzkých pásem vysvětluje přes 90 % variability v modelech výnosu plodin. Výsledky studie Heege et al. (2008) ukazují,

že změna REIP o 1 nm indikovala rozdíl  $15 \text{ kg ha}^{-1} \text{ N}$  dodaných hnojením 6 týdnů před vlastním měřením. Pro určení výchozí dávky v porostu pomocí optických metod je však nutná kalibrace pro jednotlivé druhy plodin, odrůdy, růstové fáze a specifické stanoviště podmínky.

3. Gamon et al. (1990) navrhli fotochemický reflektanční index PRI:

$$\text{PRI} = \frac{R_{531} - R_{570}}{R_{531} + R_{570}}, \quad (7.3)$$

kde  $R_{531}$  a  $R_{570}$  znamenají odrazivost vegetace v uvedených vlnových délkách. PRI se často považuje za nositele informace o účinnosti využití světelného záření LUE (z anglického Light Use Efficiency) při aktuální rychlosti fotosyntézy vegetace. LUE odráží strukturu porostu a vitální stav rostlin v daných stanovištích podmínkách. LUE je důležitým vstupním parametrem pro modelový výpočet hrubé primární produkce ekosystému a bilance uhlíku (Hilker et al. 2008).

4. Index vodního pásma, WBI, využívá vlnové délky 900 a 970 nm, které jsou citlivé na změny obsahu vody v rostlinách (Penuelas et al. 1993):

$$\text{WBI} = \frac{R_{970}}{R_{900}}. \quad (7.4)$$

Se vzrůstem obsahu vody v rostlinách se zvyšuje absorpcie záření o vlnové délce 970 nm v poměru k záření vlnové délky 900 nm. Vegetační index WBI se využívá při rozpoznávání vodního stresu suchem, odhadem produkce a jejím modelování, analýze rizika požárů a v některých ekofiziologických studiích.

## 7.3 Případová studie

Cílem studie je ukázat využití informace z leteckého hyperspektrálního snímkování pro stanovení nadzemní biomasy porostu obilnin, stavu výživy porostu dusíkem a jeho zásobení vodou. Informace o množství nadzemní biomasy jsou významné pro poznání tvorby výnosu, zejména v raných stádiích vývoje porostu (Křen et al. 2014). Pro růst rostlin, tvorbu výnosu a kvalitu zrna je dusík nejvýznamnější živinou pro obilniny. Je však nutné přihlédnout k jeho negativnímu působení na životní prostředí při jeho nadmerném dávkování. Vizuální analýza spektrálních charakteristik porostů může sloužit k rozpoznávání rozdílů v živinném stavu porostů. Pro podporu agronomického rozhodování je však nezbytné tyto rozdíly kvantifikovat, např. v podobě vegetačních indexů. Předmětem studie je využití spektrálních charakteristik porostů plodin v podobě vegetačních indexů získaných z leteckých HS dat pro stanovení porostních parametrů významných pro tvorbu výnosu obilnin.

### 7.3.1 Data a metody

Pro tyto účely byl vybrán pozemek s jarním ječmenem o výměře 62 ha na jižní Moravě (lokalita Otnice) s převládajícím půdním typem černozem. V roce 2014

proběhlo na počátku sloupkování porostu (BBCH 32) letecké hyperspektrální snímkování a stanovení množství nadzemní biomasy z odebraných rostlin. Vzorky byly odebrány na 10 místech porostu odpovídajících rozpoznané heterogenitě půdních podmínek na pozemku. Současně s odběry rostlinného materiálu byl diagnostikován výživný stav rostlin pomocí chlorofylmetru (Yara N-Tester, viz Obrázek 7.8). Přístroj je obdobou chlorofylmetru Minolta SPAD 502 a měří světelné záření propouštěné listem, ve vlnových délkách 650 a 940 nm (Arregui et al. 2006). V zemědělské praxi je tento nástroj často využíván pro zjištění stavu dusíkaté výživy rostlin a pro následné doporučení úrovně dusíkatého hnojení. Pro každý záznam bylo třeba 30 měření na listech k získání reprezentativní hodnoty na každém místě, jež vždy odpovídalo oblasti porostu ve tvaru kruhu o průměru 5 m.



**Obrázek 7.8** (a) Odběr rostlinného materiálu ječmene jarního na počátku sloupkování a (b) měření chlorofylmetrem Yara N-Tester pro diagnostiku stavu výživy rostlin.

Letecké snímky byly získány z hyperspektrálního senzoru CASI-1500 (Itres, Kanada) s 96 spektrálními pásmi (365–1050 nm) a prostorovým rozlišením 1 m na pixel. Obrazová data byla předzpracována pomocí radiometrické, atmosférické a geometrické korekce. Pro bližší údaje o zpracování hyperspektrálních dat viz Kapitola 2. Pro účely této studie byly vybrány čtyři vegetační indexy: NDVI, REIP, PRI a WBI (podrobněji viz Kapitola 7.2). Hodnoty vegetačních indexů pro místa pozemního pozorování byly vypočteny pomocí nástrojů zonální statistiky.

Pro určení topografických charakteristik sledovaného území byla zpracována data leteckého laserového skenování do podoby digitálního modelu terénu (DMT) o prostorovém rozlišení 5 m na pixel. Kromě základních topografických parametrů, jako je nadmořská výška, sklon, zakřivení a expozice terénu, byl vypočten také topografický vlhkostní index TWI (z anglického Topographic Wetness Index). Tento index vypovídá o rozložení potenciální půdní vlhkosti v daném pixelu na

základě stanovení odtokových parametrů podle rovnice:

$$\text{TWI} = \ln\left(\frac{A}{\tan b}\right), \quad (7.5)$$

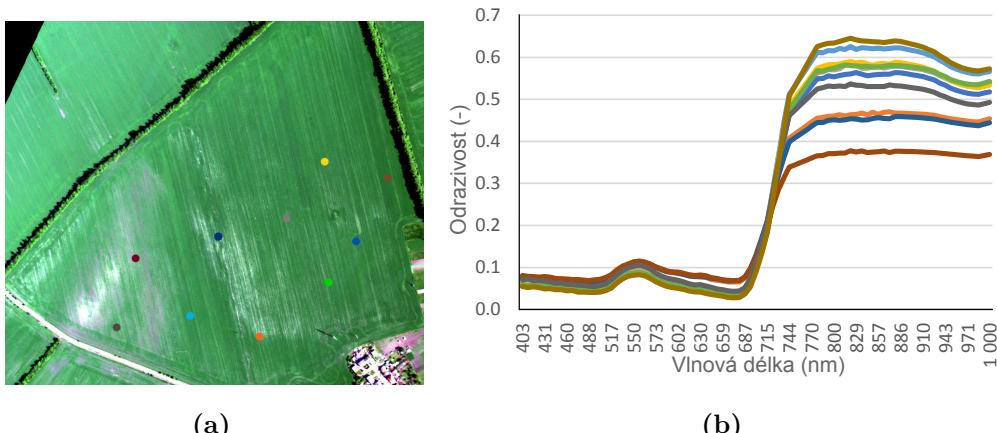
kde  $A$  představuje hodnotu akumulace vody v daném pixelu a  $b$  je sklon terénu pro každý pixel.

Pro podrobnější popis půdních vlastností na sledovaném pozemku sloužily mapy bonitovaných půdně-ekologických jednotek (BPEJ). Zpracování prostorových dat probíhalo v programech ESRI ArcGIS 10.2 a Exelis ENVI 5.1.

### 7.3.2 Výsledky a diskuse

Na Obrázku 7.9 jsou znázorněna místa terénního průzkumu na pozemku a graf s rozdíly odrazivosti porostu jarního ječmene z hyperspektrálního snímkování v těchto místech. Nejpodstatnější rozdíly byly zaznamenány v blízce infračervené a červené části spektra, která se nejlépe hodí k hodnocení růstu rostlin a stupně vývoje porostu.

Pro hodnocení závislosti mezi sledovanými parametry (množství nadzemní biomasy, hodnota získaná při měření chlorofylmetrem, topografické charakteristiky a vybrané vegetační indexy) byla využita korelační analýza, jejíž výsledky uvádí Tabulka 7.1. Výsledky prokázaly statisticky významné vztahy ( $p < 0,05$ ) mezi pozemním měřením rostlin a vegetačními indexy, s výjimkou REIP a množstvím nadzemní biomasy. Výsledky měření chlorofylmetrem byly ve statisticky průkazné korelací ( $p < 0,05$ ) se všemi sledovanými vegetačními indexy.



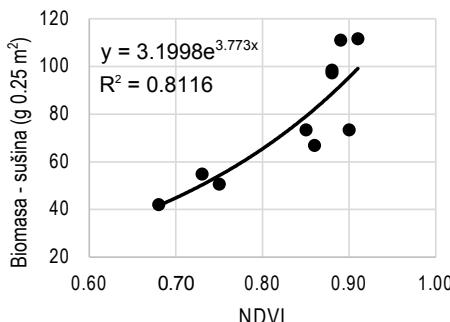
**Obrázek 7.9** (a) CASI snímek pozemku s jarním ječmenem s barevným vyznačením odběrových míst; (b) rozdíly ve spektrálních vlastnostech s odpovídajícím barevným označením.

Nalezení statisticky významné korelace ( $p < 0,05$ ) mezi vegetačními indexy a měřením porostu na 10 místech umožnilo výpočet regresních rovnic. V prvním

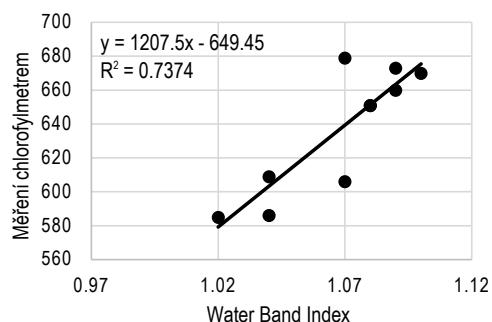
**Tabulka 7.1** Výsledky korelační analýzy (Pearsonův korelační koeficient) porostních parametrů jarního ječmene, topografických charakteristik a vegetačních indexů (\* značí statistickou průkaznost při  $\alpha = 0,05$ )

	Nadm. výška	TWI	NDVI	REIP	PRI	WBI
Chlorofylmetr	-0,671*	0,859*	0,825*	0,637*	0,696*	0,859*
Biomasa	-0,845*	0,713*	0,851*	0,311	0,731*	0,846*

NDVI – Normalizovaný diferenční vegetační index, REIP – Red Edge Inflection Point, PRI – fotochemický reflektanční index, WBI – Water Band Index (index vodního pásma)



(a)



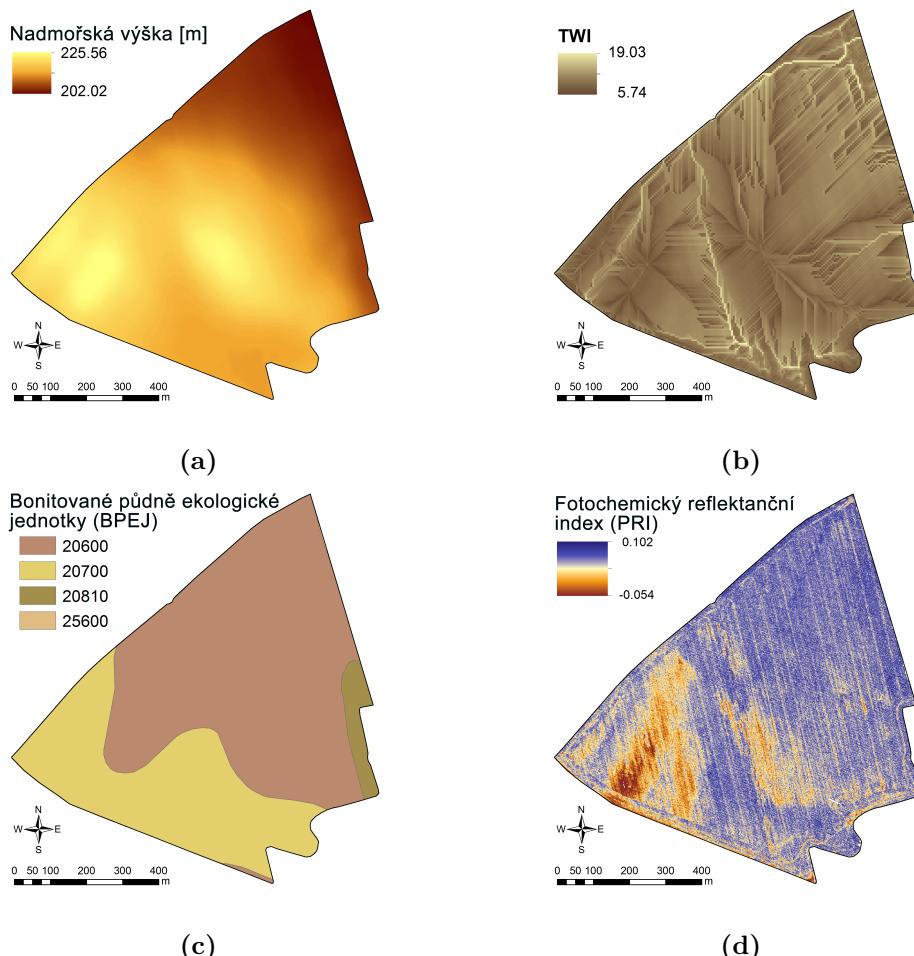
(b)

**Obrázek 7.10** Grafy vzájemné závislosti porostních parametrů a vegetačních indexů: (a) nadzemní biomasa (sušina) versus NDVI; (b) hodnoty získané chlorofylmetrem (Yara N-Tester) versus WBI.

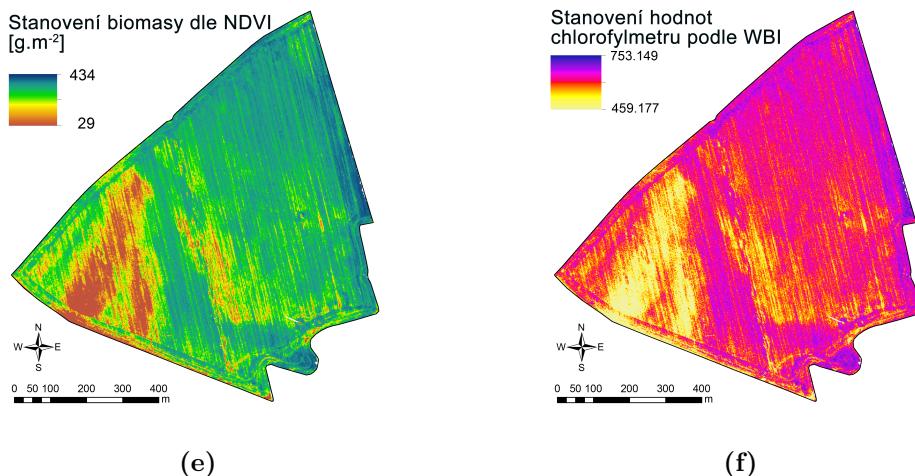
případě šlo o rovnici mezi množstvím nadzemní biomasy (hmotnosti rostlinné sušiny) a NDVI (Obrázek 7.10a), v druhém případě o stanovení stavu výživy rostlin (zprostředkován přes hodnoty měření chlorofylmetrem) a WBI (Obrázek 7.10b). Na základě takto definovaných vztahů bylo možné odvodit do mapové podoby pro celé sledované území prostorové rozložení biomasy porostu (Obrázek 7.11e) a stavu výživy porostu (Obrázek 7.11f).

Statisticky významná korelace ( $p < 0,05$ ) mezi WBI a TWI ( $r = 0,814$ ) vyplývá o pozitivním vlivu oblastí pozemku s vyšší půdní vlhkostí (vyšší hodnota TWI) na růst a vývoj porostu, reprezentovaný v tomto případě vegetačním indexem WBI. Tento efekt je zvláště patrný při výskytu období sucha v průběhu vegetačního období, jako se tomu stalo na sledovaném území v roce 2014. Vliv topografie byl také významný pro jednotlivé porostní parametry (TWI v Tabulce 7.1 a na Obrázku 7.11c). Tyto výsledky odpovídají závěrům studie, kterou prezentovali Godwin & Miller (2003), kde reliéf terénu je zmíněn jako jedna z nejvýznamnějších příčin variability porostů na pozemcích. Reliéf zásadně formuje půdní vlastnosti, které mají vliv na růst rostlin. V mnoha případech slouží

jako vysvětlení příčiny nalezených rozdílů. Z praktického hlediska jsou to neměnné vlastnosti pozemků. Příklad vývoje metodického postupu pokročilé interpretace stavu výživy porostů na základě analýzy topografických parametrů a půdních vlastností uvádějí Rodriguez-Moreno et al. (2014). Podobně PRI index byl v korelací s množstvím nadzemní biomasy, stejně jako s měřením chlorofylmetrem (Tabulka 7.1). Mapové znázornění (Obrázek 7.11d) vykazuje obdobné prostorové členění jako oba sledované porostní parametry.



**Obrázek 7.11** Mapy sledovaného pozemku s jarním ječmenem: (a) digitální elevační model (DEM) z laserového skenování; (b) topografický vlhkostní index TWI vypočtený z DEM; (c) vymezení půdních jednotek dle BPEJ; (d) fotochemický reflektanční index PRI z hyperspektrálních dat; (e) množství nadzemní biomasy zjištěné na základě vegetačního indexu NDVI; (f) celoplošná diagnostika stavu výživy rostlin na základě měření chlorofylmetrem a hodnot vegetačního indexu WBI.

**Pokračování obrázku 7.11**

Míra závislosti mezi porostními parametry a vegetačními indexy ukazuje na možnost využití leteckého průzkumu pomocí hyperspektrálního senzoru pro celoplošné hodnocení stavu porostů, nahrazujícího tradiční pozemní měření, a to i při malém počtu kalibračních míst.

## 7.4 Závěry

Pomocí hyperspektrálního snímkování bylo možno rozpoznat prostorovou variabilitu porostních parametrů jarního ječmene, významných pro tvorbu výnosu této plodiny. Ve studii byly využity úzkopásmové vegetační indexy pro celoplošné stanovení nadzemní biomasy porostu a diagnostiku stavu výživy rostlin z deseti kalibračních bodů. Takto získané mapové podklady mohou být dále využity pro plánování cílených místních zásahů ve prospěch výživy a ochrany rostlin v precizním zemědělství.

### **Poděkování:**

Experimentální část studie byla podpořena výzkumným projektem NAZV QI111A133 „Zlepšení využití odrůdového potenciálu obilnin na základě časové a prostorové analýzy spektrálních charakteristik porostu“ a MŠMT LD14121 „Možnosti dálkového průzkumu Země pro stanovení aktuální evapotranspirace vybraných polních plodin“.

### Doporučená literatura

- Heege, H.J. 2013. *Precision in crop farming. Site Specific Concepts and Sensing Methods: Applications and Results.* Springer.
- Oerke, E.-C., Gerhards, R., Menz, G. & Herbert, G. W. 2010. *Precision crop protection - the challenge and use of heterogeneity.* Springer, Dordrecht; Heidelberg.
- Oliver, M., Bishop, T. & Marchant, B. 2013. *Precision Agriculture for Sustainability and Environmental Protection.* Taylor & Francis.
- Pierce, F.J. & Nowak, P. 1999. Aspects of Precision Agriculture. *Advances in Agronomy* 67: 1–85.

# 8

## MAPOVÁNÍ OBSAHU CHLOROFYLU V LESNÍCH POROSTECH

*Lucie Homolová, Růžena Janoutová, Jan Hanuš a Zbyněk Malenovský*

### 8.1 Úvod

Většina života na naší planetě je řízen procesem fotosyntézy. Běh fotosyntézy, kterou zajišťují bakterie, řasy a vyšší rostliny, je z velké části ovlivněn přítomností a koncentrací fotosynteticky aktivních pigmentů, jako jsou chlorofyly, karotenoidy a antokyaniny. Nejznámější, a zároveň nejdůležitější pigmenty, jsou chlorofyly *a* a *b* ( $C_{ab}$ ), které regulují množství dopadajícího slunečního záření použitelného pro proces fotosyntézy. Nízké koncentrace  $C_{ab}$  mohou limitovat výtěžnost fotosyntézy. Obsah  $C_{ab}$  může být tudíž považován za indikátor fotosyntetické aktivity a tím pádem i celkového zdravotního stavu rostlin. Dále pak může sloužit jako indikátor nutričního stavu rostlin, zejména pak obsahu dusíku, protože velká část dusíku rostlin je zabudována právě v molekulách chlorofylu. U různých druhů rostlin existuje různý vztah mezi obsahem  $C_{ab}$  a dusíku (Homolová et al. 2013).

Pro dálkový průzkum Země je obsah  $C_{ab}$  v živých částech rostlin velmi atraktivní indikátor. Díky tomu, že  $C_{ab}$  silně absorbuje dopadající sluneční záření ve

viditelné části elektromagnetického spektra, je možné obsah  $C_{ab}$  stanovovat nedestruktivně pomocí analýzy dat DPZ (Filella & Penuelas 1994; Datt 1998; Ustin et al. 2009).

Metody využívající data DPZ ke kvantitativnímu stanovení obsahu  $C_{ab}$  v rostlinách mohou být rozdeleny do dvou základních skupin: empiricky a fyzikálně založené metody (Liang 2004). Empirické metody jsou založeny na tom, že se ustanoví statistický vztah mezi obsahem  $C_{ab}$ , který je přímo změřen v terénu, a hodnotami odrazivosti z dat DPZ (Curran et al. 2001; Gitelson et al. 2003; Main et al. 2011). Fyzikálně založené metody využívají modelů radiativního přenosu (RT z anglického radiative transfer), tj. fyzikálních modelů, které simulují přenos slunečního záření nějakým prostředím. V tomto kontextu se jedná o matrice, které nahrazují prostředí a strukturu jednotlivých listů i celého vegetačního zápoje. Tyto modely dávají do souvislosti biochemické a strukturální vlastnosti porostu a jeho dílčích součástí (tj. listy), s množstvím odraženého slunečního záření od daného porostu (Jacquemoud et al. 2009). Obsah  $C_{ab}$  v listech je jedním z klíčových vstupních parametrů modelů RT a tudíž může být kvantitativně získán z dat DPZ pomocí inverze modelů RT (Baret & Buis 2008). V této kapitole nejprve shrneme různé přístupy odhadu  $C_{ab}$  z dat DPZ. Některé z nich posléze představíme detailněji v případové studii odhadu  $C_{ab}$  smrkových ekosystémů z hyperspektrálních leteckých dat DPZ (na základě studie Malenovského et al. (2013)).

## 8.2 Přehled metod DPZ pro odhad chlorofylu

Empiricky založené metody používají statistiku k tomu, aby ustanovily vztah mezi naměřenými hodnotami  $C_{ab}$  v terénu a spektrálními daty DPZ. Spektrální data se používají buď ve formě hodnot odrazivosti anebo ve formě transformovaných veličin. Nejčastějším příkladem transformace hyperspektrálních dat je první nebo druhá derivace, transformace kontinua spektrální křivky (CR z anglického Continuum Removal) anebo kombinace několika spektrálních pásem do formy vegetačního indexu (le Maire et al. 2008; Schlerf et al. 2010). V odborné literatuře je zdokumentováno velké množství vegetačních indexů (VI), které byly vyvinuty buď na úrovni listu anebo na úrovni celých porostů. Např. le Maire et al. (2004) a následovně Main et al. (2011) otěstovali kolem 70 VI, které byly speciálně vyvinuty pro mapování obsahu  $C_{ab}$ . V Tabulce 8.1 prezentujeme pouze malý výběr několika indexů a naším cílem je spíše představit širokou škálu různých matematických vyjádření. Obzvláště ty indexy, které využívají tvar křivky odrazivosti, fungují celkem spolehlivě pro odhad  $C_{ab}$ .

Další spektrální indikátor, který se často využívá pro studium zdravotního stavu porostů, je pozice inflexního bodu spektrální křivky v blízké infra-červené části spektra (REIP z anglického red-edge inflection point) (Mutanga & Skidmore 2007). Přímé použití REIP pro mapování obsahu  $C_{ab}$  se zdá nejednoznačné, neboť některé závěry vědeckých prací přichází s protichůdnými výsledky. Broge a Le-

blanc (2001) srovnali několik VI, které zahrnovali i tři různé metody vyjádření REIP, a zjistili, že právě REIP indikátory jsou mnohem citlivější na strukturální změny v porostu, vliv podkladu a atmosférických parametrů, než jednoduché VI kombinující několik spektrálních pásem. Indikátory REIP fungovaly spolehlivě pouze v porostech s vysokou hustotou. K podobným závěrům došel ve své práci i le Maire et al. (2004). Naopak jiná srovnávací studie zdůraznila to, že právě REIP fungovaly jako robustní a konzistentní indikátory obsahu  $C_{ab}$  (Main et al. 2011).

Obecně lze říci, že velkou výhodou empiricky založených metod je to, že jsou výpočetně jednoduché a rychlé, a v lokálních měřítcích fungují obvykle dobře. Nevýhodou zůstává to, že empiricky stanovené vztahy nejsou univerzální a tudíž jsou těžko přenositelné na jiný druh ekosystému či jiný typ vstupních dat DPZ (Colombo et al. 2003; Gökkaya et al. 2014).

Již zmíněné nevýhody empiricky založených metod částečně řeší metody fyzikálně založené, které využívají modely RT (Asner et al. 2003). Modely RT jsou dvojího typu, a to na úrovni listu a na úrovni porostu. Na úrovni listu simuluji optické vlastnosti, tj. odrazivost a propustnost světla listovím. Nejznámějším a nejvíce používaným modelem RT na úrovni listu je model PROSPECT (Jacquemoud & Baret 1990; Feret et al. 2008). Hlavní důvod jeho širokého využití je malé množství vstupních parametrů (jejich přehled je uveden na Obrázku 8.2 a v Kapitole 8.3). Jiné modely, jako např. LIBERTY (Dawson et al. 1998), LEAFMOD (Ganapol et al. 1998), SLOP (Maier et al. 1999) nebo DLM (Stuckens et al. 2009), jsou mnohem méně používány.

Modely na úrovni porostu používají optické vlastnosti listoví jako vstup a simulují interakce slunečního záření v celém vegetačním zápoji (např. lesní porosty, zemědělské plodiny). V odborné literatuře se můžeme setkat s velkým množstvím modelů RT na úrovni porostu, od relativně jednoduchých, které značně zjednodušují vegetační médium a k jeho popisu používají omezené množství vstupních parametrů, až po ty složité a výpočetně náročné, které dokáží věrohodně zachytit 3D strukturu vegetace. Přehled modelů RT na úrovni porostu, s nimiž se může čtenář běžně setkat v odborné literatuře, nabízí například internetová stránka věnovaná mezinárodnímu srovnávání modelů RT (Radiation Transfer Model Intercomparison – RAMI, [www.rami-benchmark.jrc.ee.europa.eu](http://www.rami-benchmark.jrc.ee.europa.eu)). Asi nejčastěji se můžeme setkat s modelem SAIL (Verhoef & Bach 2007; Jacquemoud et al. 2009), který bývá obvykle propojen s modelem PROSPECT. Důvod jejich častého použití tkví opět v jednoduchosti a malém množství vstupních parametrů v porovnání s ostatními modely (Jacquemoud et al. 2009) a v poměrně dobrých výsledcích v případě porostů s jednoduchou a homogenní strukturou (Widlowski et al. 2007). SAIL byl původně navržen pro relativně jednoduché ekosystémy, jako jsou monokulturní zemědělské plodiny. Avšak s postupem času se můžeme setkat stále častěji s jeho využitím i v případě lesních porostů. V těchto případech je třeba předpokládat, že struktura lesních porostů je blízká případu homogenního média, což můžeme pozorovat například u dat DPZ s hrubým pro-

storovým rozlišením v kombinaci s hustými a druhově chudými lesními porosty (Sampson et al. 2003; Laurent et al. 2011). Jiné modely RT, které se snaží lépe vystihnout 3D architekturu lesních porostů, jsou mnohem vhodnější pro interpretaci DPZ dat z lesních ekosystémů než model SAIL. Do této skupiny 3D modelů RT patří např. DART (Gastellu-Etchegorry et al. 1996; Gastellu-Etchegorry et al. 2004), který představíme podrobněji v dalších částech této kapitoly, FLIGHT (North 1996), Raytran (Govaerts & Verstraete 1998) a mnoho dalších, které čtenář může podrobněji prostudovat na internetových stránkách RAMI.

Data DPZ interpretujeme pomocí modelů RT tak, že pomocí inverzních metod jsme schopni odhadnout některé vstupní parametry modelů RT, jako je např. obsah  $C_{ab}$  (Baret & Buis 2008; Croft et al. 2013). Proto v následující části představíme metody inverze modelů RT, které obecně můžeme rozdělit na inverze přímé a nepřímé.

Přímé metody inverze modelů RT pracují tak, že pomocí optimalizačních kroků minimalizují (případně maximalizují) nějakou nákladovou funkci v rámci jistých omezujících podmínek. Každou novou RT simulací dochází ke zpřesnění vstupních parametrů. Namátkou zde uvádíme dva optimalizační algoritmy, se kterými se můžeme častěji setkat v odborné literatuře zabývající se kvantitativním DPZ. Jsou to tzv. Quasi-Newtonova optimalizace (Combal et al. 2002) a simplexová metoda (Gascon et al. 2004). Přímé inverze modelů RT čelí dvěma závažným nedostatkům. Zaprvé, je nutné odhadnout počáteční hodnoty vstupních proměnných parametrů modelu, což může vést pouze k lokálně správnému výsledku. Zadruhé, přímá inverze komplexních RT modelů může být výpočetně velmi náročná, protože při každém optimalizačním kroku se znova simuluje radiativní transfer na základě aktualizovaných vstupních parametrů. Z tohoto důvodu jsou přímé inverze vhodné jenom pro jednoduché, výpočetně nenáročné modely a méně objemná data DPZ (Combal et al. 2002; Kimes et al. 2002).

V kvantitativním DPZ se mnohem častěji můžeme setkat s metodami nepřímé inverze modelů RT, které převážně používají tzv. vyhledávací look-up tabulky (LUT z anglického look-up tables). V tomto případě model RT nejprve spočítá možné kombinace vstupních parametrů. Výsledné hodnoty odrazivosti společně se vstupními parametry uloží do databáze, které se říká LUT. Následně se dopočítají hodnoty nákladové funkce mezi simulovanými a měřenými hodnotami odrazivosti. Poté se celá LUT srovná vzestupně či sestupně podle nákladové funkce, což umožňuje najít globální řešení celého matematického problému. Nákladová funkce tak představuje statistickou vzdálenost mezi hodnotami odrazivosti měřenými, tj. z dat DPZ ( $R_{MES}$ ), a hodnotami simulovanými ( $R_{LUT}$ ) v danné vlnové délce  $\lambda$ . Klasickým příkladem jednoduché nákladové funkce, která se často používá v DPZ, je střední kvadratická chyba ( $RMSE$  z angl. Root Mean Square Error):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_{MES,\lambda} - R_{LUT,\lambda})^2}. \quad (8.1)$$

**Tabulka 8.1** Ukázka vybraných vegetačních indexů, které jsou citlivé k různým obsahům chlorofylu v rostlinách. Vyčerpávající přehled indexů je k dispozici v le Maire et al. (2004) a Main et al. (2011). Zkratky:  $R_\lambda$  – hodnota odrazivosti pro danou vlnovou délku  $\lambda$ ,  $D_\lambda$  – hodnota první derivace křivky odrazivosti ve vlnové délce  $\lambda$ , P – úroveň porostu, L – úroveň listu.

#### 1. Jednoduché poměrové indexy

Index	Úroveň	Reference
$R_{750}/R_{710}$ , $D_{730}/D_{706}$ , $D_{705}/D_{722}$	P	(Zarco-Tejada et al. 2003; Zarco-Tejada et al. 2004)
$R_{695}/R_{420}$ , $R_{695}/R_{760}$ , $R_{710}/R_{760}$ , $R_{695}/R_{670}$	L	(Carte, 1994)
$R_{750}/R_{550}$ , $R_{750}/R_{700}$	L	(Gitelson & Merzlyak 1994)

#### 2. Indexy založené na normalizaci rozdílu dvou spektrálních pásem

Index	Úroveň	Reference
$(R_{925} - R_{710})/(R_{925} + R_{710})$	P	(le Maire et al. 2008)
$(R_{800} - R_{550})/(R_{800} + R_{550})$	P	(Gitelson et al. 1996)
$(R_{680} - R_{430})/(R_{680} + R_{430})$	L	(Penuelas et al. 1994)

#### 3. Indexy ze tří spektrálních pásem

Index	Úroveň	Reference
$R_{672}/(R_{550}R_{708})$ ,		
$(R_{850} - R_{710})/(R_{850} - R_{680})$	L	(Datt 1998; Datt 1999)
$(R_{734} - R_{747})/(R_{715} + 726)$	L	(Vogelmann et al. 1993)
MRCI: $(R_{754} - R_{708})/(R_{708} - R_{681})$	P	(Dash & Curran 2004)
mND <sub>705</sub> :		
$(R_{750} - R_{705})/(R_{750} + R_{705} - 2R_{445})$	P	(Sims & Gamon 2002)
mSR <sub>705</sub> : $(R_{750} - R_{445})/(R_{705} - R_{445})$		

#### 4. Kombinované indexy

Index	Úroveň	Reference
TCARI/OSAVI, TCARI: $3[(R_{700} - R_{670}) - 0.2(R_{700} - R_{550})(R_{700}/R_{670})]$ , OSAVI: $1.16(R_{800} - R_{670})/(R_{800} - R_{670} + 0.16)$	P	(Haboudane et al. 2002)
MCARI/OSAVI, MCARI: $[(R_{700} - R_{670}) - 0.2(R_{700} - R_{550})](R_{700}/R_{670})$	P	(Daughtry et al. 2000)

### Pokračování tabulky 8.1

#### 5. Indexy založené na kontinuu křivky odrazivosti

Index	Úroveň	Reference
$\int_{400}^{700} R_\lambda d\lambda$	P	(Zarco-Tejada et al. 2001)
$\int_{680}^{780} D_\lambda d\lambda$	L	(Filella & Penuelas 1994)
$\int_{705}^{750} \frac{R_\lambda}{R_{705}-1} d\lambda$	L	(Gitelson & Merzlyak 1994)
NAOC <sub>643–795</sub>	P	(Delegido et al. 2010)

#### 6. Inflexní bod křivky v oblasti „Red Edge“ (tj. 680–730 nm)

Index	Úroveň	Reference
REIP – four point interpolation: $700 + 40[(\frac{R_{670}+R_{780}}{2} - R_{700}) / (R_{740} - R_{700})]$	L	(Guyot & Baret 1988)
REIP – inverted Gaussian fitting	L/P	(Miller et al. 1990)
REIP – Lagrangian technique	L	(Dawson & Curran 1998)
REIP – linear extrapolation	L	(Cho & Skidmore 2006)

#### 7. Další typy indexů

Index	Úroveň	Reference
Curvature index: $R_{675}R_{690}/R_{683}^2$	P	(Zarco-Tejada et al. 2003)
Double difference: $(R_{749}-R_{720})-(R_{701}-R_{672})$	L	(le Maire et al. 2004)
Red edge symmetry: $(R_{718}-R_{675})/(R_{755}-R_{675})$	P	(Chang-Hua et al. 2010)
$(R_{750}-R_{800}/R_{695}-R_{740})-1$	L	(Gitelson et al. 2003)

Často se stává, že vztah mezi vstupními parametry modelu a simulovanou odrazivostí není čistě lineární, což porušuje základní předpoklad pro použití *RMSE* jako nákladové funkce (Leonenko et al. 2013). Z tohoto důvodu Leoneno et al. (2013) a Rivera et al.(2013) vyzkoušeli jiné nákladové funkce. Výsledky obou studií naznačují, že alternativní nákladové funkce poskytují lepší a konzistentnější výsledky pro odhad kvantitativních vlastností vegetace.

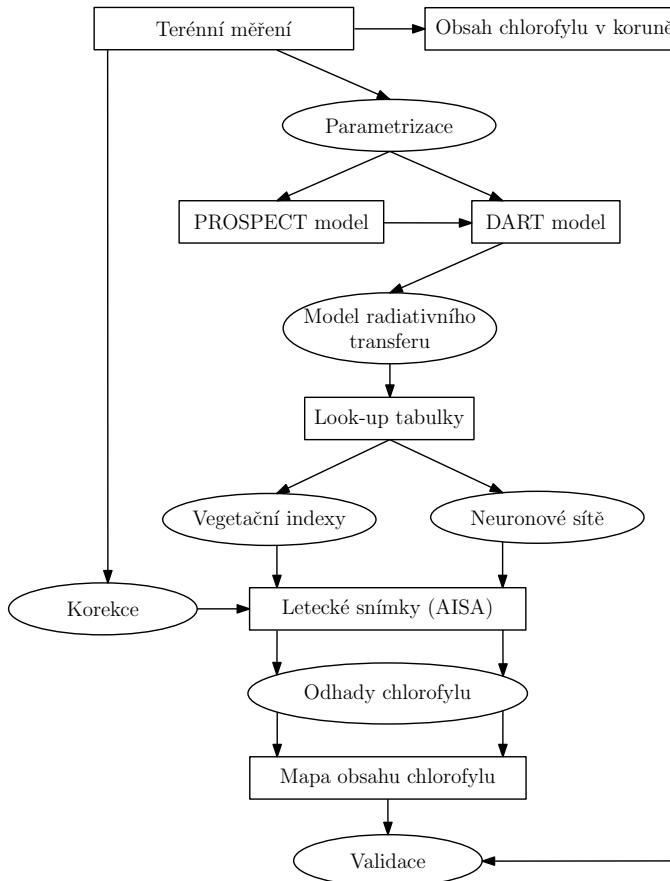
Dozajista největší výhodou LUT inverzí je to, že se jedná o relativně jednoduchý a výpočetně efektivní přístup. Cobmal et al. (2002) srovnali tři inverzní postupy (optimalizaci pomocí Quasi-Newtonova algoritmu, LUT inverzi a inverzi pomocí neuronových sítí) k tomu, aby získali čtyři vegetační charakteristiky ( $C_{ab}$ , index listové plochy, vegetační zápoj a podíl fotosynteticky aktivního záření, které je absorbováno rostlinami) ze simulovaných dat DPZ pomocí modelů RT. Právě inverze pomocí LUT byla vyhodnocena jako metoda nejrychlejší a nejfektivnější, obzvláště v případech, kdy velikost LUT byla zredukována na základě omezujících

podmínek. Nevýhodou LUT inverzí může být to, že výsledné řešení není zdaleka jednoznačné, neboť může nastat to, že kombinace různých vstupních parametrů modelu RT má za výsledek téměř identické hodnoty odrazivosti korunového zápoje (Combal et al. 2002). Tento problém může být do jisté míry eliminován pomocí různých opatření. Např. variabilita vstupních proměnných se omezí na základě dostupných znalostí o tom, jakých možných hodnot daná proměnná může nabývat (Combal et al. 2002) nebo můžeme využít doplňkovou radiometrickou informaci ze sousedních pixelů (Atzberger 2004; Houborg et al. 2009; Laurent et al. 2013). Dalšími důležitými faktory, jak stabilizovat výsledky inverze, jsou zvolit optimální velikost LUT (Weiss et al. 2000), nebrat v úvahu jedno nejlepší řešení, ale raději zvolit průměr  $n$  nejlepších řešení (Weiss et al. 2000; Darvishzadeh et al. 2008; Rivera et al. 2013), popřípadě brát v úvahu pouze klíčová spektrální pásma, která mezi sebou nekorelují (Schlerf & Atzberger 2006; Darvishzadeh et al. 2008).

Další velkou skupinou inverzních postupů, které se v poslední době častěji objevují v analýzách DPZ dat, jsou postupy tzv. strojového učení. Dříve se metody strojového učení téměř výhradně používaly pro klasifikace obrazu (Mas & Flores 2008). Dnes se tyto metody úspěšně používají právě pro kvantitativní mapování parametrů vegetace z dat DPZ (Schlerf & Atzberger 2006; Verrelst et al. 2012). Obvykle se metody strojového učení aplikují na LUT, které jsou vytvořené pomocí modelů RT. Mezi nejpoužívanější metody strojového učení v oblasti DPZ patří umělé neuronové sítě (ANN z anglicky Artificial Neural Networks) (Atzberger 2004). Neuronové sítě si například dovedou velmi dobře poradit s případným šumem, který může být přítomen v DPZ datech. Výběr správné architektury neuronové sítě a její správné naučení mohou být komplikované a vyžadují určitou míru zkušenosti. Jiné metody strojového učení, které se používají v menší míře, jsou např. Support Vector Machines, Kernel Ridge Regression a Gaussian Processes (Verrelst et al. 2012). Na základě výsledků z nedávné studie Verrelst et al. (2012b; 2012a) vyplývá, že právě metoda Gaussian Processes dává velmi dobré výsledky pro odhad kvantitativních parametrů vegetace ve srovnání s ostatními metodami strojového učení.

### 8.3 Odhad obsahu chlorofylu smrkových porostů z dat DPZ

Cílem této kapitoly je prakticky ukázat některé z výše popsaných metodických postupů k zjištování obsahu chlorofylu v lesních porostech. V této ukázce budeme vycházet z práce Malenovského et al. (2013), kteří využili modely RT, neuronové sítě a vegetační indexy k tomu, aby zmapovali variabilitu v obsahu  $C_{ab}$  ve smrkových porostech z hyperspektrálních leteckých snímků. Abychom lépe ilustrovali jednotlivé metodické kroky, které budou postupně popsány v následujících sekcích, nejprve odkazujeme na přehledný metodický diagram na Obrázku 8.1.



**Obrázek 8.1** Vývojový diagram metodiky odhadu obsahu  $C_{ab}$  z leteckých hyperspektrálních snímků za pomocí modelů radiativního transferu.

### 8.3.1 Popis lokality a terénních šetření

Vybraným porostem je smrková monokultura, jež je součástí experimentálního ekologického pracoviště Bílý Kříž, které spravuje CzechGlobe. Lokalita se nachází v Moravsko-Slezských Beskydech ( $18.54^{\circ}\text{V}$ ,  $49.50^{\circ}\text{S}$ , 936 m n.m.). Smrkový porost je charakterizován následujícími parametry, které odpovídají stavu v roce 2004: průměrná výška přibližně 12 m, průměrná výčetní tloušťka 13 cm a hodnota indexu listové plochy byla rovna osmi. V roce 2004 proběhlo na Bílém Kříži intenzivní terénní šetření, která bylo podpořeno leteckým snímkováním. Během pozemního šetření byly podrobně změřeny optické, strukturální a biochemické vlastnosti jehlic z deseti vzorníkových stromů. Z každého stromu byly odebrány dvě větve, jedna z vrcholu (osluněné) a druhá ze spodní (zastíněné) části koruny. Z každé větve pak byly odebrány vzorky ze tří posledních ročníků jehlic. Tímto způsobem bylo odebráno z každého stromu šest sad vzorků jehlic, které byly následně zpracovány v laboratoři. Zde byla stanovena listová plocha,

množství sušiny a obsah  $C_{ab}$  dle standardních laboratorních protokolů (Lhotáková et al. 2007). Průměrná hodnota obsahu  $C_{ab}$  pro celou korunu byla vypočtena jako vážený průměr dílčích měření a váhy byly stanoveny na základě rozmístění listové biomasy v koruně.

### 8.3.2 Letecké snímkování

Letecké hyperspektrální snímky byly pořízeny 18. září 2004 leteckým spektroradiometrem AISA Eagle (Specim Ltd., Finsko). Snímky pokrývaly viditelnou a infračervenou část spektra (400–980 nm, 64 pásem po kroku 10 nm) a velikost prostorového pixelu byla 0,4 m. AISA snímky byly následně radiometricky korigovány pomocí programu CaliGeo (nástroj speciálně vyvinutý pro korekce AISA snímků, Specim, Ltd., Finsko). Atmosférické korekce a nadirová normalizace snímků byly provedeny v programu ATCOR-4 (Richter & Schlapfer 2002). Při těchto korekcích bylo využito pozemních spektroskopických měření pěti umělých povrchů s různým stupněm odrazivosti. Vysoké prostorové rozlišení (0,4 m) umožnilo rozlišit jednotlivé koruny a dokonce i oddělit jejich osluněné a zastíněné části. Právě osluněné části korun s vysokým signálem odrazivosti byly dále analyzovány a využity pro odhad  $C_{ab}$ .

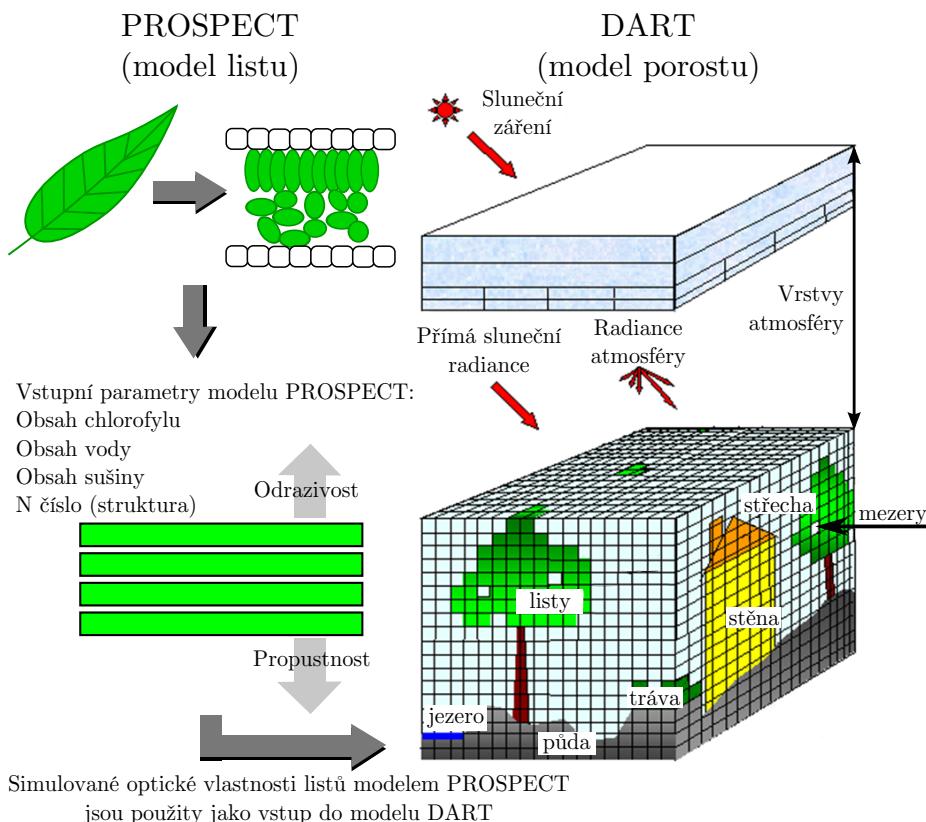
### 8.3.3 Modely přenosu slunečního záření

Pro interpretaci leteckých hyperspektrálních snímků smrkových porostů bylo použito dvou modelů přenosu slunečního záření RT (z angl. Radiative Transfer). Model PROSPECT (Jacquemoud a Baret 1990) byl upraven tak, aby lépe simuloval optické vlastnosti smrkových jehlic (Malenovský et al. 2006) a byl následně propojen s modelem DART (Gastellu-Etchegorry et al., 1996), který pracuje na úrovni celého porostu. Pro lepší orientaci na Obrázku 8.2 prezentujeme zjednodušenou vizualizaci toho, jak oba modely fungují. V Tabulce 8.2 pak přinášíme přehled nejdůležitějších vstupních parametrů obou modelů. Detailní popis toho, jak byly jednotlivé parametry odvozeny z pozemních měření, je uveden v publikacích Malenovský et al. (2008; 2013). Modely byly použity k tomu, aby vytvořili vyhledávací databázi LUT s různými hodnotami odrazivosti korunového zápoje pro různé kombinace vstupních parametrů (Tabulka 8.2).

### 8.3.4 Metody odhadu chlorofylu

Pro odhad obsahu  $C_{ab}$  z leteckých snímků byly implementovány tři postupy, které využívají LUT databázi simulovaných hodnot odrazivosti pomocí modelů RT. První postup využívá klasické vegetační indexy založené na individuálních spektrálních pásmech. Druhý postup je založen také na vegetačním indexu, avšak tento index plně využívá potenciál hyperspektrálních dat, neboť analyzuje tvar spektrální křivky odrazivosti. Třetí postup je založen na metodě strojového učení, konkrétně na neuronových sítích. V prvních dvou případech look-up tabulky

sloužily k tomu, aby se vztah mezi indexem a spektrální odrazivostí nakalibroval a posléze aplikoval na celý letecký snímek. V posledním případě look-up tabulky sloužily k natrénování vybrané neuronové sítě.



**Obrázek 8.2** Zjednodušená vizualizace modelů radiativního transferu: PROSPECT a DART. (Zdroj: Schéma modelu DART bylo volně přepracováno z CESBIO (2013) a schéma modelu PROSPECT bylo načrtvuto autory.)

#### *Vegetační indexy založené na poměru spektrálních pásem*

V této studii byly otestovány tři vegetační indexy, které byly již dříve navrženy jako indexy senzitivní vůči změnám chlorofylu. První index je založen na normalizovaném podílu dvou spektrálních pásem, tzv. Normalized Difference optical index ( $ND_{925\&710}$ ), který doporučil ve své studii le Maire et al. (2008) jako nejlepší index pro odhad  $C_{ab}$  listnatých lesních porostů z dat satelitního systému Hyperion. Druhý index je poměr dvou spektrálních pásem, tzv. Simple reflectance Ratio ( $SR_{750/710}$ ), který otestoval Zarco-Tejada et al. (2004) na porostech borovice Banksovy. Třetí index je poměr dvou indexů TCARI a OSAVI. Tento složený index byl vyvinut a otestován na zemědělských plodinách (Haboudane et al. 2002). Matematické vyjádření těchto tří indexů je uvedeno v Tabulce 8.1.

**Tabulka 8.2** Přehled vstupních parametrů modelů PROSPECT-DART, které sloužily pro modelování odrazivosti lesních porostů.

	Vstupní parametry (F/V) <sup>a</sup>	Symbol	Jednotky	Hodnoty
<b>Pozice slunce (DART)</b>	Zenitový úhel (F)	$\theta_s$	[°]	47,8
	Azimutový úhel (F)	$\Phi_s$	[°]	183,4
<b>Parametry virtuální scény (DART)</b>	Velikost jednotkového voxelu (F)		[m]	0,2
	Rozměry scény (F)	$x, y$	[m]	6,0; 6,0
	Sklon scény (F)		[°]	13,5
	Poč. stromů ve scéně (F)			4–7
	Korunový zápoj (V)	CC	[%]	75–95 (po kroku 10)
<b>Průměrné parametry stromů zadány jako průměr (sm. odch.)</b>	Index listové plochy (V)	LAI	[ $m^2 m^{-2}$ ]	4,0–9,0 (po kroku 1,0)
	Výška kmene pod korunou (F)		[m]	0,38 (0,13)
	Výška kmene v koruně (F)		[m]	8,08 (0,76)
	Průměr kmene pod korunou (F)		[m]	0,17 (0,02)
	Průměr kmene v koruně (F)		[relat]	0,41 (0,03)
	Celková výška stromu (F)		[m]	10,45 (0,88)
	Tvar koruny (F)			Kónický
	Výška koruny (F)		[m]	10,08 (0,76)
	Poloměr koruny (F)		[m]	1,60 (0,24)
	Počet vrstev v koruně (F)			10
<b>Vstupní parametry modelu PROSPECT pro simulaci optických vlastností jehlic</b>	Průměrné natočení listoví (F)	ALA	[°]	37 (7)
	Index ploch větví (F)	TAI	[ $m^2 m^{-2}$ ]	0,082 (0,017)
	Průměrné natočení větví (F)	ATA	[°]	35
	Procento plných voxelů v koruně (F)		[%]	48
	Obsah chlorofylu (V)	$C_{ab}$	[ $\mu\text{g} \cdot \text{cm}^{-2}$ ]	10–100 (po kroku 10)
	Obsah vody (F)	$C_w$	[cm]	0,036–0,048
	Obsah sušiny (F)	$C_m$	[ $\text{g} \cdot \text{cm}^{-2}$ ]	0,012–0,023
<b>Simulovaná spektrální pásma</b>	N číslo odpovídající tloušťce jehlice (F)	N	[-]	2
	Střední vlnová délka pro pásmá ve viditelné části spektra (F)	$\lambda_{VIS}$	[nm]	652,1; 661,4; 670,7; 680,1; 689,4
	Střední vlnová délka pro pásmá v Infra-červené části spektra (F)	$\lambda_{NIR}$	[nm]	698,7; 708,1; 717,4

<sup>a</sup> F/V značí, zda byl daný parametr zafixován (F), tj. konstanta, nebo byl ponechán jako volný (V), tj. proměnná.

### *Vegetační index založený na tvaru spektrální křivky odrazivosti*

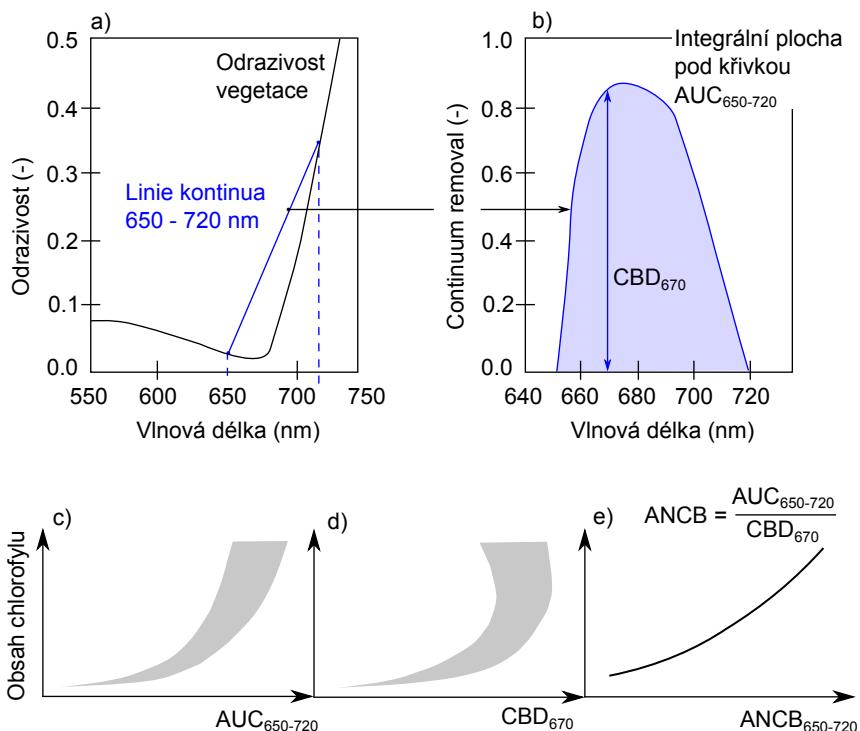
Tento index využívá tvaru hyperspektrální křivky odrazivosti (Malenovský et al. 2013). Konstrukce indexu je ilustrována na Obrázku 8.3. Při výpočtu indexu se využívá tzv. metody Continuum Removal (CR), která dokáže zvýraznit a normalizovat tvar spektrální křivky v oblasti s nejvyšší absorpcí řízenou obsahem  $C_{ab}$  (Kokaly & Clark 1999) (viz. Obrázek 8.3). V případě Continuum Removal je nejdůležitější zahrnout jenom tu část, kde se absorpcie  $C_{ab}$  projevuje nejsilněji, a zároveň minimalizovat vliv struktury porostu, která nejvíce ovlivňuje blízké infra-červené pásmo. Z tohoto důvodu začíná continuum removal uprostřed absorpčního pásu chlorofylu (650 nm) a končí zhruba uprostřed tzv. „Red Edge“ oblasti (720 nm). Index je spočítán jako podíl plochy pod křivkou Continuum Removal v oblasti 650 až 720 nm ( $AUC_{650-720}$ ) a hloubky absorpčního pásu ve vlnové délce 670 nm ( $CBD_{670}$ ) (Obrázek 8.3c-e). Název indexu  $ANCB_{650-720}$  pochází z anglického Area Under Curve of CR Reflectance Normalized by the CR Band Depth.

### *Neuronové sítě*

Výběr a učení vhodné neuronové sítě bylo provedeno pomocí programu MATLAB a jeho speciálního modulu pro neuronové sítě (The MathWorks, Inc., USA). Po vyzkoušení několika druhů sítí byla vybrána tzv. feed-forward síť se dvěma vrstvami neuronů, tj. síť, kde spojení mezi jednotlivými neurony netvoří kruh. První, vstupní vrstva je tvořena šesti neurony, které odpovídají šesti spektrálním pásmům v rozmezí 650–720 nm. Tato vrstva je pomocí tan-sigmoidální přenosové funkce propojena s vrstvou výstupní, která je tvořena pouze jedním neuronem, jenž odpovídá  $C_{ab}$ . Nejdůležitějším faktorem při použití neuronových sítí je jejich natrénování. K tomu byl použit tzv. Levenberg-Marquard optimalizační algoritmus. Náhodně vybraná čtvrtina LUT byla použita pro učení sítě a další čtvrtina dat byla použita k ověření její výkonnosti. Síť s nastavením, které dávalo nejlepší výsledky, tzn. nejnižší hodnotu  $RMSE$  a nejvyšší  $R^2$ , byla pak použita na celý hyperspektrální snímek.

#### **8.3.5 Výsledky a diskuze**

Výsledky, které jsou pro zjednodušení pouze schematicky prezentovány (Obrázek 8.3c) naznačují, že vztah mezi plochou pod křivkou Continuum Removal ( $AUC_{650-720}$ ) a obsahem  $C_{ab}$  je exponenciální a pro vyšší hodnoty  $C_{ab}$  ( $> 40 \mu\text{g cm}^{-2}$ ) nejednoznačný. Tzn., že jedné hodnotě  $C_{ab}$  přísluší několik hodnot AUC, což je přičítáno na vrub proměnlivosti v korunovém zápoji a indexu listové plochy. Z tohoto nejednoznačného vztahu určení mezi  $C_{ab}$  a AUC vyplývá, že samotné hodnoty AUC nemohou sloužit jako spolehlivý identifikátor obsahu  $C_{ab}$ . Podobné chování můžeme najít i v případě hodnot odpovídajících hloubce Continuum Removal ve vlnové délce s nejsilnější absorpcí chlorofylu v 670 nm ( $CBD_{670}$ ) (Obrázek 8.3d). Avšak když spočítáme podíl mezi  $AUC_{650-720}$  a  $CBD_{670}$



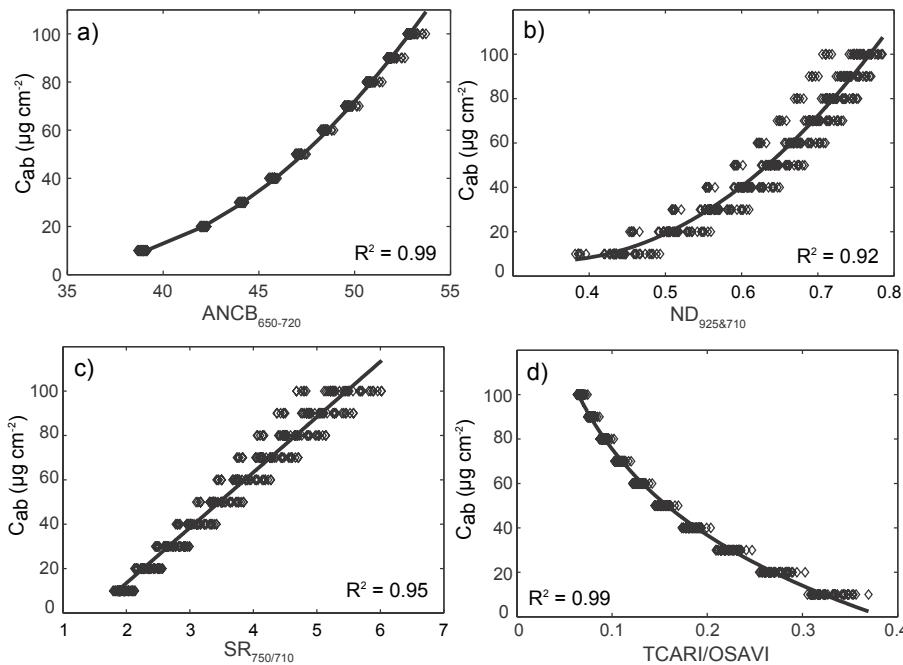
**Obrázek 8.3** Obrázky (a) a (b) ilustrují koncept continuum removal transformace. Zbývající obrázky pouze schematicky ilustrují, jaký byl vztah mezi obsahem chlorofylu a (c) plochou pod křivkou continuum removal  $AUC_{650-720}$ , (d) hloubkou continuum removal ve vlnové délce 670 nm ( $CBD_{670}$ ) a (e) samotným indexem  $ANCB_{650-720}$ .

(Obrázek 8.3e), výsledný vztah s obsahem chlorofylu je téměř lineární a jednoznačný. Právě tato formulace tvoří nový index pro odhad obsahu  $C_{ab}$ , který byl nazván „Area Under Continuum-Removed Curve Normalized to the Chlorophyll Absorption Band Depth Between 650 and 720 nm“ ( $ANCB_{650-720}$ ). Tento index je citlivý vůči změnám  $C_{ab}$  ve smrkových porostech, pokud je brán v potaz silný signál z osvícených částí korun, a zároveň se chová nezávisle vůči změnám indexu listové plochy. Rovnice mezi  $C_{ab}$  a  $ANCB_{650-720}$  je následující:

$$\ln(C_{ab}) = 7.40 - \frac{7984.01}{(ANCB_{650-720})^2}, \quad (R^2 = 0.99, p < 0.001). \quad (8.2)$$

Když byl  $ANCB_{650-720}$  index porovnán s ostatními vegetačními indexy, vykazoval výrazně vyšší přesnost odhadu  $C_{ab}$  (Obrázek 8.4). Ačkoliv veškeré vztahy mezi testovanými vegetačními indexy a obsahem  $C_{ab}$  byly statisticky významné, pouze  $ANCB_{650-720}$  a TCARI/OSAVI se chovaly nezávisle na změnách indexu listové plochy a hustoty korunového zápoje (to je indikováno úzkým rozptylem bodů pro jednotlivé úrovně  $C_{ab}$ ). Mapa obsahu chlorofylu celého zájmového území, tj.

monokultury smrku ztepilého, tak jak byla získána pomocí indexu  $\text{ANCB}_{650-720}$  index (rovnice 8.2) je ukázána na Obrázku 8.5.

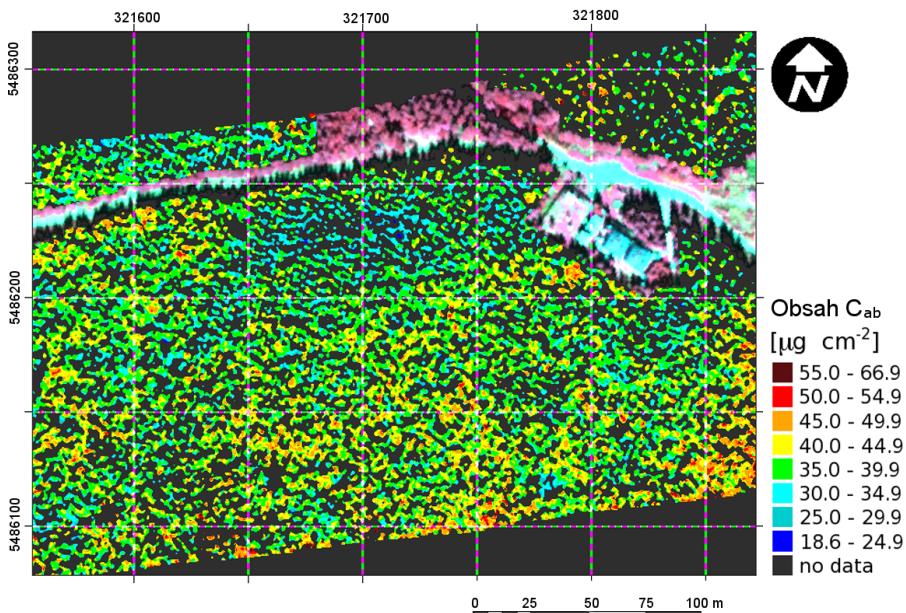


**Obrázek 8.4** Vztah mezi obsahem chlorofylu a vegetačními indexy (a)  $\text{ANCB}_{650-720}$ , (b)  $\text{ND}_{925\&710}$ , (c)  $\text{SR}_{750/710}$  a (d)  $\text{TCARI}/\text{OSAVI}$ .

Použitá neuronová síť byla trénována na datech zpracovaných pomocí transformace Continuum Removal. Neuronová síť produkovala výsledky (ve smyslu rozmezí hodnot a prostorové distribuce) podobné těm, které byly získány z indexu  $\text{ANCB}_{650-720}$  (Obrázek 8.5). Když se od sebe obě mapy odečtou ( $\text{ANN} - \text{ANCB}_{650-720}$ ), průměrný rozdíl činí pouze  $1,8 \mu\text{g cm}^{-2}$ . Rozdíly mezi ANN a ostatními vegetačními indexy byly mnohem větší, konkrétně  $-9,01 \mu\text{g cm}^{-2}$  pro index  $\text{ND}_{925\&710}$ ,  $-4,30 \mu\text{g cm}^{-2}$  pro index  $\text{SR}_{750/710}$ , a  $13,29 \mu\text{g cm}^{-2}$  pro index  $\text{TCARI}/\text{OSAVI}$ .

Porovnání mezi odhadnutým a naměřeným obsahem chlorofylu je znázorněno na Obrázku 8.6. Nejlepší výsledky, tzn. nejvyšší koeficient determinace ( $R^2 = 0,72$ ), a zároveň nejnižší střední kvadratická chyba odhadu ( $\text{RMSE} = 2,27 \mu\text{g cm}^{-2}$ ), vykazuje právě index  $\text{ANCB}_{650-720}$  (pro zjednodušení zde záměrně neuvádíme výsledky pro neuronové sítě, které byly obdobně výsledkům z  $\text{ANCB}_{650-720}$ ). Nejméně přesnou metodou pro odhad  $C_{ab}$  smrkových porostů se nakonec ukázalo být použití kombinovaného indexu  $\text{TCARI}/\text{OSAVI}$  ( $\text{RMSE} = 12,30 \mu\text{g cm}^{-2}$  a  $R^2 = 0,41$ ) a to i přesto, že na simulovaných spektrálních datech v databázi LUT fungoval relativně dobře (viz Obrázek 8.4d). Vizuální inspekce

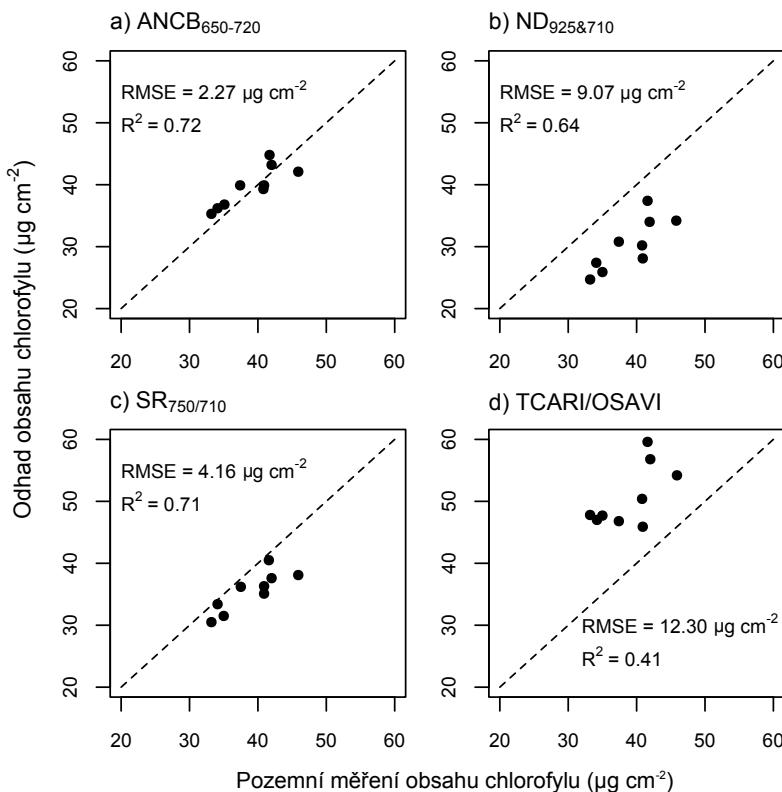
mapy  $C_{ab}$ , kterou jsme obdrželi pomocí indexu TCARI/OSAVI, odhalila to, že pixely s nižší reflektací, tzn. pixely nacházející se na okrajích korun stromů, mají nepřirozeně vysoké hodnoty  $C_{ab}$ . To vedlo k celkovému nadhodnocení odhadu  $C_{ab}$  pomocí metody TCARI/OSAVI.



**Obrázek 8.5** Mapa obsahu chlorofylu smrkového lesa, jak byla získána pomocí vegetačního indexu ANCB<sub>650–720</sub>.

## 8.4 Závěr

Tato kapitola ve své první, spíše teoretické části, nejprve obecněji shrnula metody a přístupy kvantitativního DPZ pro odhad parametrů vegetace, přičemž zvláštní důraz byl kláden na obsah chlorofylu v listoví, který je považován za dobrý indikátor zdravotního stavu rostlin. V druhé části byla hlouběji představena případová studie mapování obsahu  $C_{ab}$  v horských smrkových porostech. V této studii bylo konkrétně využito modelů radiativního transferu v kombinaci s různými vegetačními indexy a neuronovými sítěmi. Důraz byl kláden na plné využití hyperspektrálních dat, které umožňují tvarovou analýzu spektrální křivky odraznosti. Výsledky poukázaly na to, že jak neuronové sítě, tak i index ANCB<sub>650–720</sub>, tzn. dva přístupy, které využily Continuum Removal absorpčního pásu chlorofylu, produkovaly mnohem přesnější a realističtější výsledky než zbývající tři vegetační indexy. Ačkoliv neuronové sítě produkovaly poněkud lepší výsledky, z hlediska časové náročnosti a celkové implementace je využití indexu ANCB<sub>650–720</sub> mnohem jednodušší.



**Obrázek 8.6** Srovnání pozemních měření obsahu chlorofylu a odhadů  $C_{ab}$  pomocí vegetačních indexů: (a) ANCB<sub>650–720</sub>; (b) ND<sub>925&710</sub>; (c) SR<sub>750/710</sub>; (d) TCARI/OSAVI. Každý bod představuje průměrnou hodnotu  $C_{ab}$  pro jeden vzorníkový strom.

### Doporučená literatura

- Jacquemoud, S., Verhoef, W., Baret, F., Bacour, C., Zarco-Tejada, P.J., Asner, G.P., Francois, C. & Ustin, S.L. 2009. PROSPECT + SAIL models: A review of use for vegetation characterization. *Remote Sensing of Environment* 113: S56—S66.
- Liang, S. 2004. *Quantitative remote sensing of land surfaces*. John Wiley & Sons, Inc., Hoboken, New Jersey.
- Main, R., Cho, M.A., Mathieu, R., O'Kennedy, M.M., Ramoelo, A. & Koch, S. 2011. An investigation into robust spectral indices for leaf chlorophyll estimation. *ISPRS Journal of Photogrammetry and Remote Sensing* 66: 751–761.
- Malenovský, Z., Homolová, L., Zurita-Milla, R., Lukeš, P., Kaplan, V., Hanuš, J., Gastellu-Etchegorry, J.-P. & Schaepman, M.E. 2013. Retrieval of spruce leaf chlorophyll content from airborne image data using continuum removal and radiative transfer. *Remote Sensing of Environment* 131: 85–102.
- Ustin, S.L., Gitelson, A.A., Jacquemoud, S., Schaepman, M., Asner, G.P., Gamon, J.A. & Zarco-Tejada, P. 2009. Retrieval of foliar information about plant pigment systems from high resolution spectroscopy. *Remote Sensing of Environment* 113: S67—S77.

# 9

## VYUŽITÍ LETECKÉHO LASEROVÉHO SKENOVÁNÍ V LESNICTVÍ

*Jan Novotný, Tomáš Mikita, Martin Machala a Lucie Homolová*

### 9.1 Úvod

V oboru leteckého laserového skenování (LLS) probíhá v současnosti rychlý vývoj technologií. Nejen to z něj činí nejprogresivnější nové odvětví v lesnické praxi. Jsou vyvíjeny aplikace pracující v nejrůznějším měřítku, od sběru informací o jednotlivých stromech a porostních skupinách až po celkovou inventarizaci na celostátní úrovni. Data LLS vycházejí vítězně ze srovnání s jinými (optickými) daty používanými pro inventarizaci porostů (Hyppä & Hyppä 1999).

V lesnických aplikacích LLS pracujeme se dvěma kategoriemi dat. Diskrétní systémy zaznamenávají pozici jednotlivých odrazů od různých úrovní porostu a jejich intenzitu. Full-waveform systémy ukládají kompletní průběh odražené elektromagnetické vlny (Heinzel & Koch 2011; Wulder et al. 2012). Data LLS poskytují podklad pro širokou škálu aplikací. Nejběžnějším produktem odvozeným z dat LLS je digitální model terénu (DMT) – viz Kapitola 4.5. V lesnické praxi DMT pomáhá při návrhu a optimalizaci sítě cest, při plánování těžby a při přípravě

protierozních opatření. Data LLS samotná, případně v kombinaci s obrazovými daty, se dále používají při klasifikaci lesních porostů (Machala & Zejdová 2014) nebo též jednotlivých druhů dřevin (Yu et al. 2014). Pro management lesních porostů je nejužitečnější možnost přímo odvozovat inventarizační veličiny. Na úrovni porostních celků je možné vymezit jejich hranice, odhadnout průměrnou výšku, hustotu zápoje a další charakteristiky. Na úrovni jednotlivých stromů odvozujeme výšku, rozměry koruny a DBH (Heurich et al. 2003; Holopainen & Hyppä 2003; Maltamo 2004). Dá se tedy říci, že využití dat LLS efektivně nahrazuje časově a logisticky náročná terénní šetření. Veličiny odvozené z dat LLS pak dále umožňují odhad nadzemní biomasy v porostu, zásoby dřeva, a podobně.

Při odvozování inventarizačních veličin rozlišujeme dva přístupy. První z nich je plošný (z angličtiny zkratka ABA = Area Based Approach), druhý pracuje s detekcí jednotlivých stromů (z angličtiny zkratka ITD = Individual Tree Detection). Základní myšlenkou plošného přístupu je výpočet nejrůznějších geostatistických veličin popisujících prostorové rozložení odraženého laserového signálu. Tyto veličiny pak slouží k modelování parametrů porostu jako je průměrná výška stromů, tloušťka kmenů, výčetní základna, objem dřeva a biomasy. K nastavení modelu nicméně potřebujeme sběr pozemních dat v reprezentativních částech zkoumaného území (Yu et al. 2010). Přístup ABA je používán pro reálnou inventarizaci, například ve skandinávských zemích (Holopainen et al. 2014). Přístup ITD je založen na analýze rastrové mapy výšek (získané odečtením modelu terénu od modelu povrchu), na detekci jednotlivých stromů, jejich výšek a rozměrů koruny. Další inventarizační veličiny jsou vypočítány na základě druhově specifických alometrických rovnic. Nejčastějším vstupem těchto empirických modelů je právě výška stromů, případně hustota zápoje a další.

Lesní inventarizace založená na ITD je zatím méně častá, protože k přesnému určení polohy stromů a průmětů korun je zapotřebí bodové mračno vysoké hustoty (Vastaranta et al. 2011). V literatuře popsáne postupy obvykle požadují minimálně 5 až 10 bodů na  $m^2$ , což je výrazný rozdíl oproti hustotě cca 1 bod na  $m^2$ , požadované při plošném přístupu. Na druhou stranu právě určení prostorového rozložení stromů dává lepší podklad pro podrobné modelování zásoby dřevní hmoty a představuje tak výhodu přístupu ITD oproti ABA (Holopainen et al. 2010). Další výhodou přístupu ITD je menší nárok na terénní šetření, které zde slouží pouze k upřesnění specifických stanovištních podmínek. Obecně je pak jednodušší stanovit druhově specifické alometrické vztahy pro jediný strom než modelovat komplexní smíšený porostní celek. Současné studie srovnávající oba přístupy na datech z oblasti severských lesů ukazují podobnou úspěšnost odhadů porostních parametrů (průměrná výška, DBH a zásoba dřevní hmoty). O něco větší přesnost přístupu ITD je vyvážena menší ekonomickou náročností ABA při pořizování a zpracování dat (Yu et al. 2010).

Jak již bylo uvedeno, data LLS jsou reálně používána pro inventarizace, například ve Skandinávii (Carson et al. 2004; Næsset 2004). Situace v České republice je odlišná, využití metod LLS je limitováno z hlediska technologického i legisla-

tivního. Úplná inventarizace je podle zákona 289/1995 Sb. součástí lesních plánů, které jsou aktualizovány pro desetiletá období na základě intenzivního terénního šetření, při němž je odhadováno druhové složení porostů, výšky stromů a DBH, a zásoba dřeva. Ani jeden z přístupů k inventarizaci na základě dat LLS nebyl u nás v širším měřítku ověřován. Jednou z překážek je absence prověřených alometrických rovnic pro objem dřeva a celkové biomasy. Oproti skandinávským lesům mají naše lesy také bohatší druhové složení, což činí přípravu empirických modelů ještě náročnější. Nicméně předpokládáme, že i v ČR dříve či později LLS najde svou cestu do lesnické praxe. Potenciál této technologie pro odhad inventarizačních veličin a obecně pro podporu lesního managementu je značný.

V následujících částech této kapitoly důkladnější představíme využití dat LLS pro: 1) klasifikaci porostních celků; 2) detekci a delineaci jednotlivých korun; 3) odhadu inventarizačních veličin (výška, DBH, objem dřeva). Jednotlivé příklady vybíráme z různých studií různých autorů, proto také zpracované lokality a použitá data se liší. Místo výčtu podrobností o pořízení a předzpracování dat předkládáme jednotlivá téma v obecné rovině. Technické podrobnosti k problematice klasifikací viz Machala & Zejdová (2014), k detekci a delineaci korun viz Novotný (2014) a k otázce odhadu inventarizačních veličin v lesích ČR viz Mikita et al. (2013).

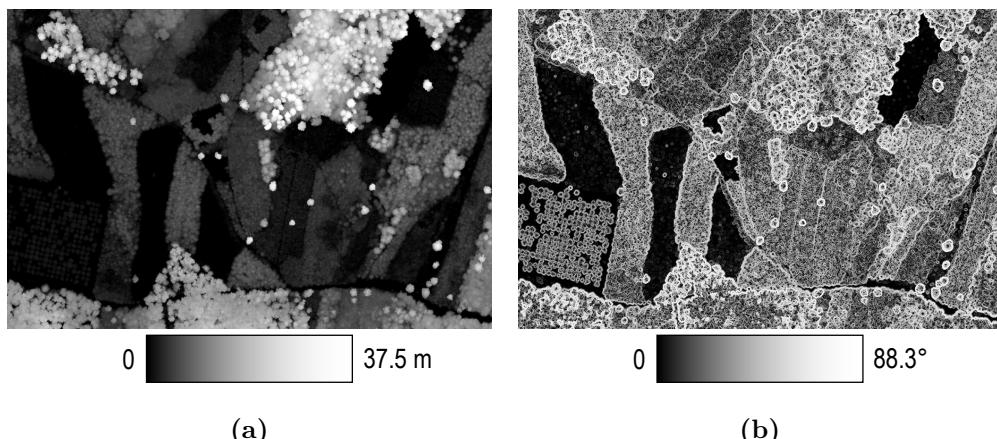
## 9.2 Segmentace a klasifikace porostu

Klasifikace je v dálkovém průzkumu velmi široké téma. Běžným vstupem jsou obrazová multispektrální či hyperspektrální data. V poslední době jsou stále častěji obrazová data kombinována s data LLS. Obecný úkol přiřazení tzv. informačních tříd má v lesnických aplikacích konkrétní podobu ve snaze rozlišovat typy porostu (např. jehličnatý vs. listnatý les), věkové složení porostu a nejpodrobněji i přesné druhové složení.

Klasifikační metody rozdělujeme do dvou základních skupin. Tzv. klasifikace per-pixel pracuje s hodnotami jednotlivých pixelů a na jejich základě přiřazuje informační třídu zase jednotlivým pixelům. Objektově orientovaný přístup (OBIA – z anglického Object-Based Image Analysis) napřed rozdělí obraz do tzv. segmentů, které mají společné vlastnosti, a teprve potom jednotlivým segmentům přiřazuje informační třídu. Při klasifikaci objektů je možné využít číselné charakteristiky objektů (průměrné hodnoty jednotlivých veličin, jejich směrodatnou odchylku, atd.) a také jejich tvarové charakteristiky. Takový přístup značně rozšiřuje prostor pro klasifikaci a lépe odpovídá lidskému myšlení při zařazování objektů do tematických tříd. Při lesnických klasifikacích se rozhodně vyplatí pracovat například s plochou koruny jako s jediným objektem.

Objektově orientovaného přístupu se v lesnických aplikacích zpravidla využívá pro klasifikaci rastrových obrazových dat založených na spektrální informaci – například pro odlišení jehličnatých a listnatých porostů (Alberti et al. 2013), pro odlišení zásahových a bezzálohových zón (Dickinson et al. 2014). Prosto-

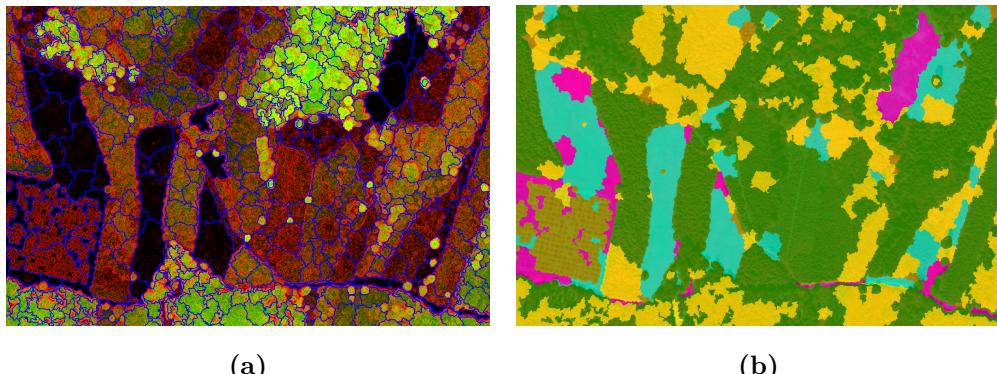
rová informace obsažená v datech LLS může dále podpořit kvalitu klasifikace. Na příkladu studie Machala & Zejdová (2014) budeme dokumentovat potenciál OBIA v případě klasifikace založené čistě na derivátech dat LLS (DMT, DMP, mapy výšek). V analýze se nespoleháme pouze na informaci o výšce (Obrázek 9.1a); z bodového mračna můžeme odvodit další tematické vrstvy. Příkladem může být model svažitosti (Obrázek 9.1b), model křivosti nebo model rozdílů mezi maximálními a minimálními hodnotami v sousedících buňkách. Všechny takové vrstvy slouží jako podklad pro klasifikaci, obdobně jako různá spektrální pásma u obrazových dat. Objektově orientovaný postup klasifikace se dá uskutečnit



**Obrázek 9.1** (a) Mapa výšek odvozená z dat LLS pořízených skenerem Leica ALS50-II ( $2,5 \text{ b/m}^2$ ) pro smíšený les v zájmovém území v okolí Bílovic nad Svitavou; (b) odpovídající model svažitosti vypočtený s prostorovým rozlišením 0,5 m.

v mnoha dostupných softwarech pro práci s obrazovými daty, např. Idrisi, ENVI, nebo ERDAS. Nicméně vůdčí postavení na poli OBIA má software eCognition (vyvinutý firmou Trimble Navigation Ltd.), který je výlučně zaměřen na objektově orientovanou analýzu. Typický postup práce v eCognition začíná víceúrovňovou segmentací, po níž následuje samotná klasifikace. Proces segmentace je řízen vstupy uživatele. Je možno dávat různou váhu různým vstupním vrstvám a dalšími parametry pozměňovat počet, tvar a kompaktnost výsledných segmentů. Výsledkem segmentace je obraz rozdělený do základních objektů (Obrázek 9.2a). Prvním krokem následné klasifikace je definice zájmových tříd a určení cvičných objektů pro jednotlivé třídy. Automatický klasifikátor pak přiřazuje vždy jednu z předdefinovaných tříd ke každému objektu v obraze. Přitom vybírá objekty metodou nejbližšího souseda podle hodnot ve zvolených vrstvách. Obrázek 9.2b ukazuje oblast smíšeného lesa rozdělenou do pěti tříd.

Nedílnou součástí klasifikace je posouzení její přesnosti pomocí srovnání se skutečným stavem ve zkoumané oblasti. Tento stav zjistíme terénním šetřením nebo např. interpretací ortofotosnímků. Ve výsledku sestavujeme chybovou matici, jež uvede počty pixelů té které třídy bylo zařazených správně/nesprávně.



**Obrázek 9.2** (a) Základní objekty (modré ohraničení) vytvoření víceúrovňovou segmentací v prostředí eCognition Developer; (b) výsledek objektově orientované klasifikace téhož území. Jednotlivé třídy jsou: listnatý porost – žlutá, jehličnatý porost – zelená, lesní školka – hnědá, mladý porost – modrá a holá půda – růžová.

Z výsledků studie v oblasti Bílovic (viz Obrázek 9.2) citujeme dosaženou přesnost 82 % a koeficient shody  $\kappa$  rovný 70 %. Pro úplnost dodejme, že při klasifikaci kombinující LLS vrstvy s obrazovými daty bylo dosaženo přesnosti 90 % a  $\kappa$  rovného 85 % (Machala & Zejdová 2014). Činíme závěr, že objektově orientovaný přístup kombinující obrazová data a data LLS, případně využívající data LLS samotná, vede k vysoce přesné klasifikaci porostních typů.

### 9.3 Detekce a delineace jednotlivých stromů

Snaha o detekci a delineaci jednotlivých stromů v datech dálkového průzkumu má počátek v devadesátých letech 20. století, odkdy byla k dispozici obrazová data s adekvátně vysokým prostorovým rozlišením. Trendem poslední doby pak je přechod od obrazových dat k datům LLS, která poskytují fyzikálně podloženou informaci o 3D struktuře porostu. Případně se pracuje s kombinací obou datových zdrojů. V Tabulce 9.1 přinášíme stručné shrnutí několika studií utříďených právě podle použitého datového zdroje, a také podle studovaného ekosystému.

Pro ujasnění, pojmem detekce máme na mysli určení pozice stromu (kmene/vrcholku) a pojmem delineace míníme určení hranice/projekce plochy koruny.

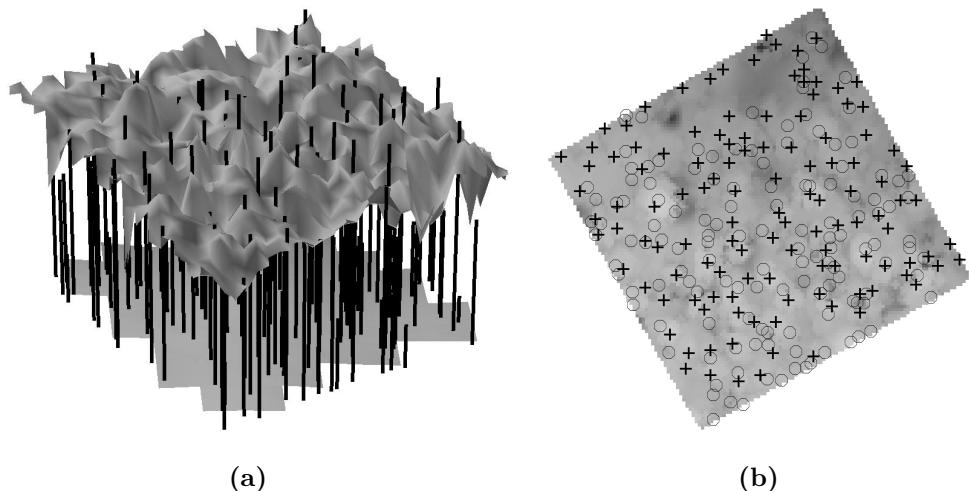
Základním vstupem pro detekci a delineaci bývá mapa výšek (též označovaná jako normalizovaný model povrchu), která vzniká odečtením modelu terénu od modelu povrchu. Obrázek 9.3a ukazuje příklad mapy výšek z oblasti bukového lesa. Na přesnost detekce a delineace má mimo jiné vliv prostorové rozlišení vstupní mapy výšek, odvozené od prostorového rozlišení modelů terénu a povrchu. Toto rozlišení volíme při tvorbě modelů a mělo by být v přiměřeném souladu s předpokládanou velikostí korun stromů v zájmové oblasti, a také musí odpovídat hustotě zdrojového bodového mračna. Dle našich zkušeností je možno

efektivně detekovat koruny stromů, jejichž rozměr v obrazovém znázornění je alespoň 4 pixely v průměru. Obdobně platí, že vrcholky stromů jsou detekovatelné správně, je-li hustota vstupního shluku bodů alespoň  $3 \text{ b/m}^2$  (optimum leží mezi 5 a  $10 \text{ b/m}^2$ ).

Mapa výšek jako přímý rozdíl DMP-DMT obvykle obsahuje šumové pixely, které doporučujeme odstranit vhodným low-pass filtrem (mediánový či gaussovský). Stejně tak se vyplatí předem odmaskovat rozlehlé nelesní plochy a neanalyzovat je ve zpracovávaném obraze. Detekce polohy stromů v mapě výšek je poměrně snadná. Vrcholky jednotlivých stromů hledáme jako lokální maxima výšky, případně minima, pracujeme-li s otočenými výškami. Maxima hledáme pomocí posuvného okolí, jeho velikost a tvar má pochopitelně vliv na výsledky detekce. S ohledem na obvyklé tvary korun doporučujeme dávat přednost kru-

**Tabulka 9.1** Přehled studií na téma detekce a delineace tříděný podle zdroje dat a zkoumaných dřevin.

Datové zdroje	Jednotlivé studie (zkoumané dřeviny; lokalita výzkumu)
Obrazová data (multispektrální či hyperspektrální)	Culvenor (2002) (Eucalyptus; Austrálie) Pitkänen (2001) (borovice lesní, smrk ztepilý, modřín opadavý, bříza spec.; Finsko) Erikson (2003) (borovice lesní, smrk ztepilý, modřín opadavý, topol osika, bříza spec.; Švédsko) Pouliot et al. (2005) (smrk sivý; Kanada) Bunting & Lucas (2006) (akácie a Eucalyptus spec.; Austrálie) Hirschmugl et al. (2007) (borovice lesní, smrk ztepilý, dub spec.; Rakousko)
Letecké laserové skenování	Brandtberg et al. (2003) (borovice lesní, javor červený, liliovník tulipánokvětý; USA) Chen et al. (2006) (dub modrý; USA) Koch et al. (2006) (dub anglický, habr obecný, douglaska tisolistá, buk lesní, jedle bělokorá, atd.; Německo) Gupta et al. (2010) (borovice lesní, dub spec., habr obecný, buk lesní, bříza bělokorá, smrk ztepilý; Německo) Korpela et al. (2010) (borovice lesní, smrk ztepilý, bříze spec.; Finsko)
Kombinace obrazových dat a LLS	Leckie et al. (2003) (douglaska tisolistá; Kanada) Breidenbach et al. (2010) (borovice lesní, smrk ztepilý, topol osika, bříza spec.; Norsko)

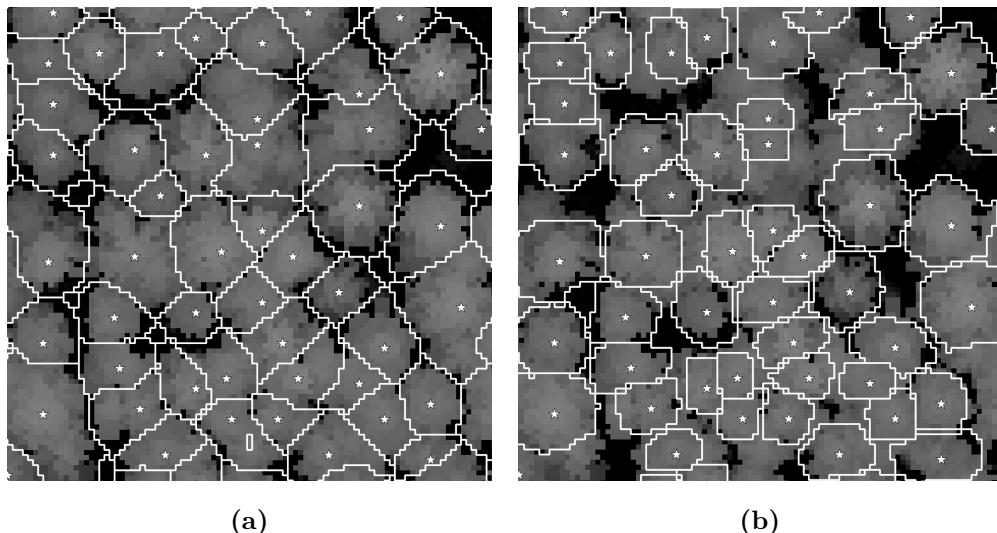


**Obrázek 9.3** (a) Příklad 3D vizualizace mapy výšek s označením poloh jednotlivých stromů; (b) Srovnání zjištěné polohy stromů (+) s výsledky pozemního šetření (o).

hovému tvaru okolí před programátorským snazším čtvercem. Velikost okolí je vhodné přizpůsobit očekávané velikosti korun: vyšší stromy mívají rozsáhlejší okolí, menší stromy je mívají omezenější. Předpokládaný průměr koruny se může odvodit z výšky stromu dosazené do druhově specifických alometrických rovnic. Jiný přístup je založen na čistě matematické analýze obrazu a pracuje například s podobností obrazu jeho původnímu vzhledu, anebo s místním sklonem odečteným z výškopisné mapy a určovaným v několika transektech napříč zkoumaným okolím.

Se znalostí poloh jednotlivých stromů (vrcholků) můžeme přejít ke druhému kroku, k delineaci průmětu plochy koruny. Představíme zde velmi stručně tři nejběžnější postupy popisované v odborné literatuře: 1) hydrologický přístup (Inverse Watershed); 2) metodu minimové sítě (Valley-Following); 3) růstový algoritmus (Seed Region Growing). Další přístupy shrnují např. Bunting & Lucas (2006). První metoda, obráceného povodí, je převzata z hydrologických aplikací, jak nazev napovídá, převracíme mapu výšek, z lokálních maxim se stanou minima a následně vzniklou 3D strukturu zaplavujeme z těchto minim. Hranice jednotlivých korun stanovujeme na hranicích dílčích povodí. Druhá metoda, minimové sítě, vychází z podobnosti mezi povrchem lesa a hornatou krajinou. Vrcholky stromů hledáme jako lokální maxima a hranice korun odvozujeme ze sítě minim obklopujících maxima. K propojení lokálních minim do uzavřené sítě, k odstranění slepých větví a dalším úpravám slouží komplexní sada pravidel. Více viz. Gougeon (1995). Třetí je metoda růstového algoritmu (Novotný 2014). Plocha každé koruny je založena od vrcholku (lokálního maxima). Sousedící pixely jsou připojovány, pokud splní předem definovaná pravidla, tzv. stopovací podmínky. Růst zastavíme, když výška poklesne pod určenou hodnotu, když se dotknou dvě sousedící koruny, a podobně. Právě kvůli správnému zpracování společné hranice dvou sousedících stromů je

nutné zvětšovat plochy všech korun současně. Obrázek 9.4 ilustruje rozdíly ve výsledném rozdělení plochy lesa při použití růstového algoritmu oproti metodě obráceného povodí. Účinnost růstového algoritmu pro detekci a delineaci korun jak v jehličnatém, tak v listnatém lese posoudil ve své studii Novotný (2014). Zdrojová data pořízená systémem Riegl Q680i se vyznačovala velkou bodovou hustotou ( $10\text{--}50 \text{ b/m}^2$ ); zpracovány byly tři lokality s různými typy porostu. Výsledky shrnuté v Tabulce 9.2 ukazují, že bez ohledu na rozdílnou hustotu růstový algoritmus vykazuje konzistentní chování a solidní přesnost pro různou jak věkovou, tak druhovou skladbu porostu.



**Obrázek 9.4** Srovnání výsledků delineace (a) metodou obráceného povodí; (b) růstovým algoritmem. Zobrazen je výřez z oblasti bukového lesa v Bílých Karpatech. Vstupní shluk bodů měl hustotu  $50 \text{ b/m}^2$  a mapa výšek byla zpracována v rozlišení  $0,5 \text{ m}$ .

## 9.4 Určování inventarizačních veličin z dat LLS

K určení inventarizačních veličin na úrovni jednotlivých stromů předpokládáme správnou detekci a určení výšky každého stromu. Pro určení dalších charakteristik stromu, jako je DBH či objem dřeva ( $V$ ), pak používáme druhově specifické alometrické rovnice. Získané hodnoty můžeme následně agregovat pro úroveň porostních celků. Přesnost modelované dřevní zásoby a dalších veličin závisí pochopitelně na přesnosti zjištění jednak počtu stromů, jednak jejich výšek. Nezávislé studie potvrzují přesnost určení výšky stromů z dat LLS s odchylkou 1 m (van Leeuwen & Nieuwenhuis 2010), obvykle bývá výška podhodnocena, oproti skutečnosti je nižší o 1 až 5 m (Hyppä & Inkkinen 1999; Kwak et al. 2007; Mikita et al. 2013). Úspěšnost detekce je především dána hustotou bodů vstupních dat. Při jejich nižší hustotě vzrůstá pravděpodobnost, že některé vrcholky nebudou vůbec zjištěny.

**Tabulka 9.2** Výhodnocení výsledků detekce a delineace metodou růstového algoritmu ve třech různých typech porostů. Uvádíme celkový počet detekovaných jedinců stromů, přesnost detekce a delineace.

Lokalita	Typ porostu	Charakteristika lokality a porostu		Vstupní data	Přesnost detekce a delineace		
		Výška porostu [m]	Bodová hustota [b/m <sup>2</sup> ]		Počet stromů	Detekce	Delineace
Bílý Kříž (Beskydy)	Mladý smrkový	11,9 ± 3,8	50	5305	85,1 %	76,8 %	
Rájec (Vysočina)	Dospělý smrkový	27,6 ± 4,1	10	4538	87,5 %	79,0 %	
Štítná nad Vláří (Bílé Karpaty)	Dospělý bukový	26,9 ± 2,6	50	6204	83,5 %	80,8 %	

Bez ohledu na hustotu není navíc snadné zjišťovat z dat LLS stromy podúrovňové (Yu et al. 2010; Mikita et al. 2013). Z ostatních inventarizačních veličin, přesnost modelované hodnoty DBH bývá v rozmezí 0,025 až 0,065 m (Korpela et al. 2010; Holopainen et al. 2010). Chyba v odhadu dřevní zásoby na úrovni porostních celků se obvykle pohybuje mezi 5 % a 35 % (Maltamo et al. 2009; Vauhkonen et al. 2010; Tonoli et al. 2011).

Konkrétní příklad výpočtu inventarizačních veličin (výška, DBH, objem dřeva) zakládáme na studii Mikita et al. (2013). Zpracováno bylo území Školního lesního podniku Křtiny (Mendelu), jedná se o smíšené lesy s převahou buku. Data LLS byla pořízena systémem Leica ALS50-II, hustota bodového mračna byla 4 b/m<sup>2</sup>. Paralelně s přeletem proběhlo terénní šetření zaměřené na inventarizaci a geodetické zaměření vybraných stromů. Výsledkem byla databáze pozic, výšek a DBH pro cca 600 stromů.

K detekci stromů byla použita metoda obráceného povodí. Chyba v určení poloh stromů byla přibližně 0,6 m a celková odchylka v odhadu jejich výšek byla mínus 5,5 m. Tuto relativně vyšší hodnotu můžeme přisoudit právě neschopnosti LLS postihnout nižší porostní patra. Při omezení analýzy pouze na vysoké stromy ( $h > 25$  m) chyba v odhadu výšky klesá na 1,4 m. Vliv na přesnost detekce měla také volba prostorového rozlišení mapy výšek a zvolená metoda interpolace modelů terénu a povrchu.

Zbývající veličiny (DBH,  $V$ ) byly vypočítány s použitím známých alometrických rovnic, které byly parametrisovány na základě terénního šetření. Obě rovnice používají výšku stromu jako jedinou vstupní veličinu. Pro výpočet DBH byla použita upravená Michajlovova funkce (9.1):

$$DBH = \frac{12.29}{3.78 - \ln(h - 1.3)}. \quad (9.1)$$

Model pro výpočet objemu dřeva byl přebrán z práce slovenských autorů (Petráš & Pajtík 1991). Vzhledem k převaze buku ve zkoumaném porostu jsou převzaty právě koeficienty pro buk:

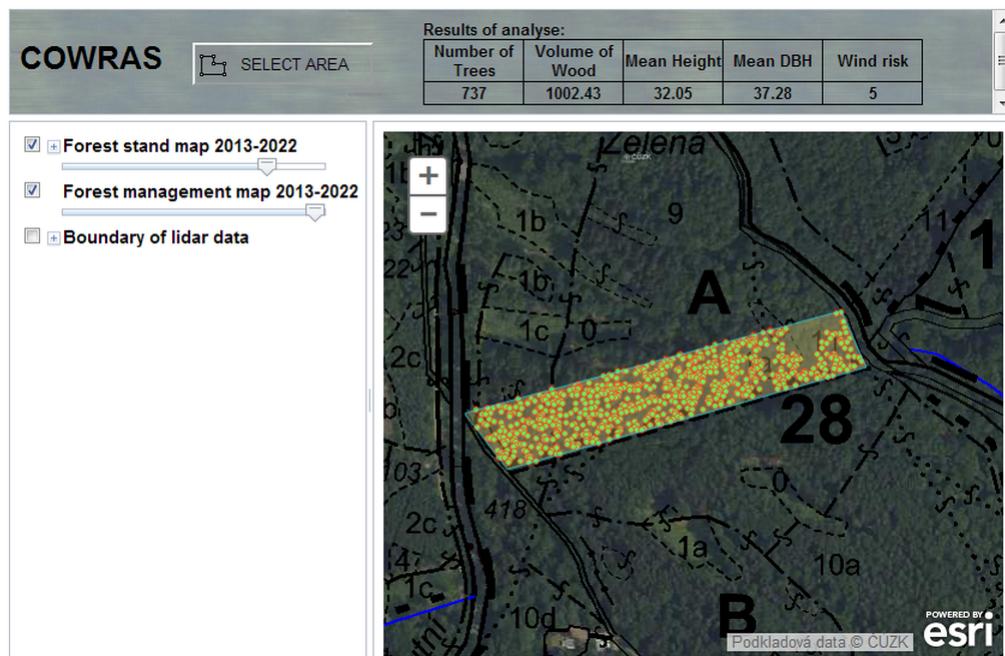
$$\begin{aligned} V = & \left[ 0.54 - \frac{0.31}{h} + \frac{44.33}{h^2} - \frac{235.97}{DBH} - \frac{0.001DBH}{h} - 1.86 \cdot 10^{-5} \frac{h^2}{DBH} - \right. \\ & \left. - 8.8 \cdot 10^{-7} hDBH^2 - 6.0 \cdot 10^{-9} hDBH^3 \right] \frac{\pi h DBH}{40000}. \end{aligned} \quad (9.2)$$

Pozemní (destruktivní) šetření k objemu dřeva nebylo bohužel k dispozici. Nicméně hrubé srovnání s lesním hospodářským plánem potvrdilo shodu s hodnotami zásoby dřeva uvedenými v plánu pro jednotlivé porostní celky.

## 9.5 Výhled do budoucna

Česká republika zatím nevyužívá plně potenciál LLS pro lesnické aplikace. Jak jsme ukázali v předchozích odstavcích, dosud byly provedeny pouze lokální studie,

především výzkumného charakteru a jen pro omezená území. K širšímu využívání dat LLS a dálkového průzkumu obecně možná chybí širší povědomí o těchto metodách a obecná znalost práce s obrazovými daty a systémy GIS. Proto ani není snadné představovat produkty dálkového průzkumu zástupcům veřejné správy. Pro práci s daty LLS existuje několik softwarů s přiměřeným uživatelským rozhraním, např. freeware Fusion (<http://forsys.cfr.washington.edu/fusion/fusionlatest.html>) nebo komerční ENVI Lidar ([http://www.exelisvis.com/docs/using\\_envi\\_lidar\\_Home.html](http://www.exelisvis.com/docs/using_envi_lidar_Home.html)). Nicméně pro zpracování některé konkrétní aplikace neúplně poučeným operátorem může být užitečné připravit samostatné aplikace. Jako příklad zmiňme aplikaci COWRAS (Clearcut Optimization and Wind Risk Assessment, Obrázek 9.5 <http://arcgis.mendelu.cz/topex/>), která je nadstavbou v prostředí ArcGIS. Cílem je optimalizace zakládání pasek s ohledem na ohrožení obnažených porostních stěn větrem. Vstupními daty jsou modely terénu, povrchu a mapa výšek. COWRAS zjišťuje jednotlivé stromy a jejich parametry (viz Kapitola 9.4). Informace o dřevě vhodném k těžbě mohou být exportovány. Následně proběhne analýza polohy porostních stěn vůči potenciálnímu ohrožení větrem. Zpracování ve formě webové aplikace umožňuje práci i uživatelům bez hlubší zkušenosti s LLS.



**Obrázek 9.5** Ukázka uživatelského prostředí skriptu COWRAS (s analýzou jednotlivých stromů a ohrožení větrem v uvedené tabulce).

**Poděkování:**

V textu jsou publikovány výsledky, které vznikly za podpory z projektu Lesnické a dřevařské fakulty Mendelovy univerzity v Brně IGA 68/13 „Vývoj vlastního řešení dálkového průzkumu Země prostřednictvím bezpilotního letounu a jeho praktické využití v lesnictví“.

**Doporučená literatura**

- Maltamo, M., Næsset, E. & Vauhkonen, J. 2014. *Forestry Applications of Airborne Laser Scanning*. Springer
- van Leeuwen, M. & Nieuwenhuis, M. 2010. Retrieval of forest structural parameters using LiDAR remote sensing. *European Journal of Forest Research* 129: 749–770.

# 10

## DENNÍ DYNAMIKA POVRCHOVÉ TEPLOTY RŮZNÝCH TYPŮ KRAJINNÉHO POKRYVU

*Petra Hesslerová a Jan Pokorný*

### 10.1 Úvod

Teplota je stavová veličina charakterizující, zda při kontaktu dvou těles dojde k tepelné rovnováze. To znamená, zda bude jedno z těles teplo přijímat, odevzdávat, nebo k tepelné výměně nedojde. Nedojde-li mezi tělesy k tepelné výměně, mají obě stejnou teplotu.

Pro účely této kapitoly je nutno rozlišovat povrchovou radiační teplotu a teplotu vzduchu měřenou standardním způsobem v meteorologii (viz Kapitola 3 a Norman & Becker 1995). Za slunného dne může být radiační teplota povrchu bez vegetace i o  $20^{\circ}\text{C}$  vyšší nežli teplota vzduchu měřená standardním způsobem.

Disipace je v klasické termodynamice ztrátou části energie; je nevratnou přeměnou na jiný druh energie, zejména na teplo. Klasická termodynamika popisuje stroj, ve kterém se tepelná energie přeměňuje v pohyb za cenu nevratných ztrát – neužitečné disipace. Carnot popisoval účinnost stroje a rozlišoval „užitečnou“ výměnu energie a „disipovanou“ energii, která je nevratně ztracená (entropie).

Carnotův stroj, pracující jako uzavřený systém, spěje k termodynamické rovnováze – teploty se vyrovnejí, stroj se zastaví. Stroj je možno uvést do pohybu dodáním další energie zvnějšku.

Zemská biosféra dostává energii zvnějšku od Slunce, na vnější povrch atmosféry přichází v průběhu roku  $1321\text{--}1412 \text{ W m}^{-2}$ . Živé systémy se vyvíjely jako otevřené systémy a díky příkonu sluneční energie jsou vzdáleny od termodynamické rovnováhy, utvářejí se, zdokonalují se. Na rozdíl od Carnotova stroje se živé systémy propojují do stálé organizovanějších struktur. Prigogine v 60. letech minulého století vytvořil novou nelineární (nerovnovážnou) termodynamiku k popisu samo-organizace otevřených systémů vzdálených od termodynamické rovnováhy. Zavedl pojem „disipativní struktura“, aby zdůraznil rozdíl (paradox) mezi uzavřeným systémem (strojem) a živým systémem. V klasické termodynamice je disipace energie na teplo vždy spojena s odpadem a degradací systému. V otevřených systémech, a zejména v systémech živých, se disipace stává zdrojem pořádku, procesem narůstající organizace. Průkopnickou prací v tomto oboru je slavná Schrödingerova řeč na téma „What is life“ (Schrödinger 1944).

Živé systémy, ekosystémy (disipativní struktury), vyrovňávají teplotní rozdíly, obecně vyrovňávají gradienty („life abhors gradients“) (Schneider & Sagan 2005). Tyto teplotní rozdíly, které vznikají v důsledku nerovnoměrného příkonu slunečního záření, jsou podmínkou rozvoje života. Schopnost ekosystémů vyrovňávat teploty vidíme na příkladu rozdílu teplot mezi dnem a nocí na poušti oproti teplotním rozdílům v lesích stejného zeměpisného pásma. Relativně nízké teploty povrchu a vyrovnané teploty mezi místy i mezi dnem a nocí (v prostoru a čase) jsou projevem aktivní činnosti ekosystémů. Ripl (1995) navrhl koncepční (pojmový) model Energie-Transport-Reakce (ETR model), zahrnující tři základní procesy disipace sluneční energie (vyrovňávání teplot) zprostředkováné vodou:

- evaporace a kondenzace,
- rozpouštění a precipitace solí,
- rozklad vody na kyslík a vodík a zpětná tvorba molekuly vody (fotosyntéza a respirace).

### *Které procesy ovlivňují teplotu ekosystémů?*

Sluneční energie přichází na každé místo zemského povrchu v denních pulsech (noc a den) a v sezónních pulsech. K dlouhodobým periodickým změnám dochází též následkem změn tvaru oběžné dráhy Země kolem Slunce i změn sluneční aktivity. Krátkodobě má zásadní význam oblačnost – za jasného dne přichází až  $1000 \text{ W m}^{-2}$ , při zatažené obloze klesá množství dopadajícího slunečního záření pod  $100 \text{ W m}^{-2}$ , tedy na desetinu. Sluneční záření, které přichází na zemský povrch, se částečně odráží, částečně ohřívá povrch Země. Od ohřátého povrchu Země se potom ohřívá vzduch, který proudí vzhůru (zjevné teplo), část sluneční energie se spotřebuje na výpar vody (latentní/skryté teplo evapotranspirace) a část

přechází do země (tok tepla do půdy). Poměrně malá část sluneční energie se váže procesem fotosyntézy do biomasy. V Tabulce 10.1 jsou uvedeny rozsahy hodnot energetických toků hlavních procesů v ekosystémech. Intenzita těchto procesů se mění v průběhu sezóny i v průběhu dne podle příkonu sluneční energie. Procesy jsou navzájem provázány a spějí ke snižování gradientů, tedy i ke zmenšování teplovních rozdílů. Evapotranspirace je nejmohutnějším procesem přeměny sluneční energie: dosahuje hodnot stovek  $\text{W m}^{-2}$ . Na jednu molekulu přijatého oxidu uhličitého se vyloučí jedna molekula kyslíku a až několik set molekul vody ve formě vodní páry. Teplota v krajině je výsledkem odrazu slunečního záření, radiační

**Tabulka 10.1** Hodnoty energetických toků v ekosystémech

Odraz krátkovlnného slunečního záření	5–25 % z dopadajícího záření
Primární produkce (photosyntéza na úrovni tvorby rostlinné biomasy)	jednotky $\text{W m}^{-2}$
Evapotranspirace (transpirace vody rostlinami a výpar z povrchu porostu a půdy)	stovky $\text{W m}^{-2}$
Dekompozice organických látek v půdě při negativní bilanci primární produkce	jednotky až desítky $\text{W m}^{-2}$
Ohřev biomasy porostu	jednotky až desítky $\text{W m}^{-2}$
Energie slunečního záření na vnějším povrchu atmosféry v průběhu roku	1321–1412 $\text{W m}^{-2}$
Radiative forcing (radiační zesílení) od roku 1750 (začátek průmyslové revoluce, data IPCC)	1–3 $\text{W m}^{-2}$ (0.2 $\text{W m}^{-2}$ se očekává do roku 2025)

výměny mezi tělesy navzájem a oblohou, a mohutnými toky energie v biosféře zprostředkovánými vodou. Rozložení a dynamika teplot jsou indikátorem účinnosti využívání sluneční energie.

## 10.2 Cíle

Tato studie, která je založena na práci Hesslerová et al. (2013), sleduje denní dynamiku povrchové teploty  $T_s$  na lokalitách s rozdílnými typy krajinného pokryvu a porovnává ji s chodem teploty vzduchu  $T_a$ . Studie je založena na teplotních datech získaných termovizním snímkováním ze vzducholodi a meteorologické stanice. Konkrétním cílem tak je:

1. zaznamenat a kvantifikovat časoprostorové rozdíly a dynamiku povrchové teploty  $T_s$  v průběhu horkého letního dne v kulturní krajině s heterogenním krajinným pokryvem,

2. porovnat denní dynamiku povrchové teploty  $T_s$  modelových lokalit s chodem teploty vzduchu  $T_a$ ,
3. v diskusi zdůraznit význam sledování povrchové teploty a zodpovědnost subjektů hospodařících v krajině za lokální klima, prostřednictvím nakládání s vodou a vegetací.

## 10.3 Metody

### 10.3.1 Popis lokalit

Studium denní dynamiky povrchové teploty různých typů krajinného pokryvu bylo uskutečněno v rovinatém terénu v okolí obce Domanín u Třeboně. Bylo vybráno sedm různých typů krajinného pokryvu:

- lokalita 1 (PL) — posečená louka pokrytá uschlou trávou, cca 10 cm vysokou, s dominantními druhy *Alopecurus pratensis* L. a *Arrhenatherum elatius* (L.) J. Presl & C. Presl,
- lokalita 2 (ML) — mokrá louka s vysokou hladinou podzemní vody; dominantní druhy: *Phalaris arundinacea* L. a *Carex* sp., výška porostu cca 1 m,
- lokalita 3 (O) – olšina, s dominantním společenstvem *Alnus glutinosa* L. a *Prunus avium* L., křoviny a menší stromy do výšky 3 m,
- lokalita 4 (L) – smíšený les s dominantními druhy *Pinus sylvestris* L. a *Quercus robur* L.; odhadované stáří porostu 60 let; průměrná výška 10–15 m,
- lokalita 5 (P) – pole (jílovitohlinitá půda) ležící ladem, s řídkou travinnou vegetací (pokryvnost menší než 50 %),
- lokalita 6 (V) – vodní plocha; mělký rybník, s maximální hloubkou 1,5 m; intenzivní chov ryb,
- lokalita 7 (A) – asfaltový povrch silnice.

### 10.3.2 Měření povrchové teploty $T_s$ metodami dálkového průzkumu Země

Snímání termovizní kamerou bylo uskutečněno 9. července 2010 na platformě devítimetrové řiditelné vzducholodi, která je vybavená inerciálním a globálním navigačním systémem IMU/GNSS pro autonomní let, umožňující snímání podle předem definované trasy (detaily viz patent a užitný vzor Jirka et al. 2011). Letová výška byla stanovena na 250 m, se šířkou záběru 200 m. Vybrané modelové území bylo opakovaně snímáno během dne, v časech: 04:50, 05:30, 06:00, 07:10, 08:10, 09:10, 10:40, 13:15, 14:00, 15:10, 16:10, 17:10, 18:10, 18:40, 19:10, 20:10 GMT+1, a to ve viditelné i termální části spektra. Termografická kamera ThermaCAM

TM PM695 (Flir System Sweden), zavěšená na jednosměrném gravitačním závěsu, měří a zaznamenává infračervené záření emitované objektem ve spektrálním intervalu  $7,5 \mu\text{m}$  až  $13 \mu\text{m}$ , s rozlišením  $320 \times 240$  pixelů a termální citlivostí  $0,08^\circ\text{C}$  při  $30^\circ\text{C}$ . Velikost pixelu byla stanovena na 30 cm. Záření, které kamera snímá, není pouze vyzařování snímaného objektu. Kamera rovněž zachycuje emitované záření okolních objektů; vliv má i absorpcie a vyzařování atmosféry. Přesná měření teploty závisí na způsobu vyrovnání těchto různých zdrojů záření. Proto je nebytné zadat do kamery správné kalibrační parametry: emisivitu objektu, relativní vlhkost vzduchu, vzdálenost snímaného objektu, (efektivní) teplotu okolí objektu, teplotu atmosféry a teplotu externí optiky (detailly viz. Kapitola 3.3.2). Kalibrační parametry byly změny na meteorologických stanicích. Hodnoty emissivity pro jednotlivé lokality byly zadány jako standardní tabulkové hodnoty.

### 10.3.3 Meteorologická data

Teplota vzduchu byla měřena standardním způsobem ve 2 m nad zemí ( $T_a$ ,  $^\circ\text{C}$ ,  $T + R_h$  senzor, přesnost  $\pm 0,1^\circ\text{C}$ ). Referenční  $T_a$  byla vypočtena jako průměrná hodnota z pěti meteorologických stanic, umístěných buď přímo na monitorovaných lokalitách, anebo v jejich blízkosti, na nichž byla teplota měřena v desetiminutových intervalech.

Lokalita „posečená louka“ byla vybavena net radiometrem CNR-1 (Kipp & Zonen) pro analýzu radiační bilance (ve  $\text{W m}^{-2}$ ). Dopadající ( $R_{down}$ ) a odražené ( $R_{up}$ ) globální záření ve spektrálním rozsahu  $0,31$ – $2,8 \mu\text{m}$  bylo měřeno CM3 pyranometrem (Kipp & Zonen), dlouhovlnná radiace (5–50  $\mu\text{m}$ ) dvěma CG3 pyrgeometry měřícími dlouhovlnné vyzařování oblohy ( $R_{ldown}$ ) a emitované záření povrchu ( $R_{lup}$ ).

### 10.3.4 Zpracování dat

Při hodnocení denní dynamiky povrchové teploty (v čase 4:50–20:10 GMT+1) jsme se zaměřili na sledování těchto proměnných na jednotlivých lokalitách:

- průměrná denní povrchová teplota ( $T_{savrg}$ ), tedy průměrná povrchová teplota dané lokality vypočtená z 16 náletů v době 04:50–20:10,
- průměrná denní povrchová teplota lokality v čase  $t$  ( $T_{st}$ ),
- průměrná minimální povrchová teplota, průměrná maximální povrchová teplota ( $T_{smin}$ ,  $T_{smax}$ ) – teplotní extrémy zaznamenané v čase měření,
- maximální rozdíl povrchové teploty ( $D_s$ ) – rozdíl mezi  $T_{smax}$  a  $T_{smin}$ ,
- odchylka povrchové teploty (vyjádřená pomocí hodnot směrodatné odchylky) – ukazuje variabilitu teploty na lokalitě v daný čas ( $SD_{st}$ ) či v průběhu dne ( $SD_{sd}$ ).

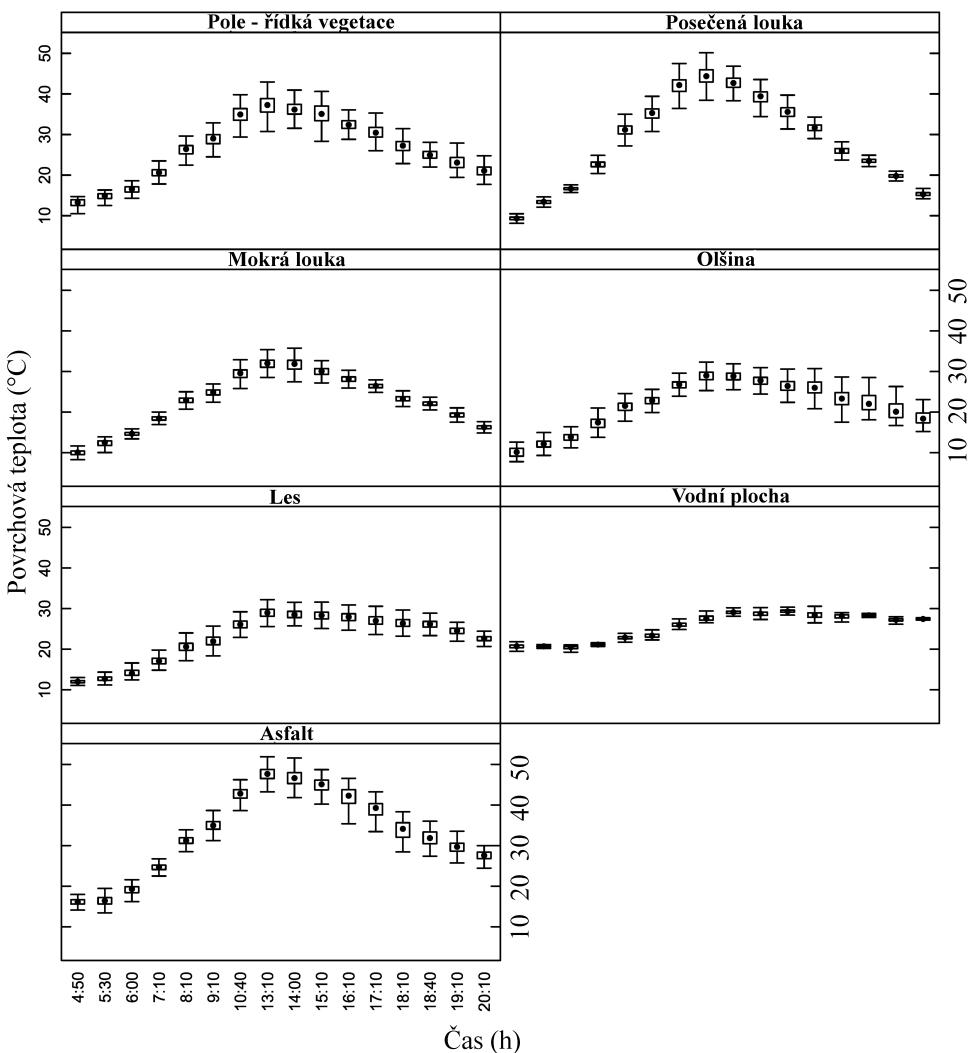
Vzhledem ke skutečnosti, že termální snímky představují velké objemy dat, byl vybrán reprezentativní vzorek pixelů pro každou lokalitu. Pro náhodný výběr byla zvolena metoda náhodné permutace prvků ‘x’ (respektive ‘1: x’). Reprezentativní vzorek představuje 1000 pixelů pro každou lokalitu a čas.

## 10.4 Výsledky a diskuse

Denní dynamika povrchové teploty v průběhu slunného letního dne se významně liší mezi všemi sledovanými lokalitami (Tabulka 10.2; Obrázek 10.1). Největší rozdíly byly zaznamenány mezi lokalitami s řídkou a suchou vegetací (posečená louka:  $T_{smax}$  44,2°C;  $D_s$  34,8°C) a strukturovanou vegetací dobře zásobenou vodou (les:  $T_{smax}$  29,0°C;  $D_s$  17,0°C). Teplotní charakteristiky ekosystémů bez funkční vegetace se podobají asfaltovému povrchu ( $T_{smax}$  44,2°C;  $D_s$  34,8°C), zatímco charakteristiky ekosystémů se zelenou a vertikálně strukturovanou vegetací byly podmíněny přítomností vody, která je díky fázovému přechodu (proces transpirace) schopna snižovat teplotu a vyrovnávat teplotní rozdíly (vodní plocha:  $T_{smax}$  29°C a  $D_s$  pouze 9°C v důsledku značné tepelné kapacity vody). Lokality s hustou křovinnou nebo stromovou vegetací charakterizuje vyrovnaná teplotní dynamika bez výrazných extrémů (Obrázek 10.1), s pomalým dopoledním zvyšováním i odpoledním poklesem teploty. Vliv vegetace a přítomnost vody na dynamiku povrchové teploty ekosystému byl demonstrován na lokalitě „mokrá louka“, jež vykazuje vyrovnané a nižší teploty oproti posečené louce pokryté suchou vegetací. Význam vody pro teplotní rovnováhu ekosystému je spojen nejen s fyzičkálními vlastnostmi kapalné vody, ale také s velkou spotřebou latentního tepla při přechodu z kapalné na plynnou fázi. Tento proces probíhající prostřednictvím evapotranspirace poskytuje živým systémům vysoce účinný termoregulační mechanismus (2,5 MJ kg<sup>-1</sup> při 20°C se spotřebuje během evapotranspirace a uvolňuje se při kondenzaci vodní páry). Na jedné straně chladící a na druhé straně účinky fázové přeměny vody zesiluje přítomnost vegetace, zvláště má-li dobré vyvinutou vertikální strukturu, jakou mají lesní porosty (Makarieva et al. 2006; Eiseliová et al. 2012; Pokorný et al. 2010; Hesslerová & Pokorný 2010a, 2010b; Kedziora 2010).

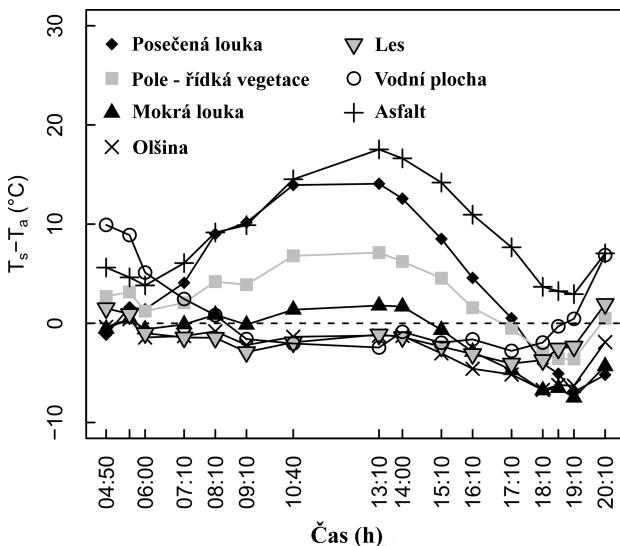
$T_a$  měřená na pěti meteorologických stanicích rozmístěných v celém modelovém území se během dne výrazněji nelíšila (Tabulka 10.2). V průběhu dne se rozdíly mezi jednotlivými stanicemi pohybovaly do 1°C; největší rozdíly byly zaznamenány před západem slunce (19:10 a 20:10 h), kdy dosáhly 6°C (mezi stanicemi na lokalitě „asfalt“ a „mokrá louka“) a 4,6°C („asfalt“ a „pole“). Zatímco se teplota vzduchu na jednotlivých lokalitách výrazněji nelíšila (kromě uvedených časů), největší rozdíly  $T_s$  mezi jednotlivými lokalitami dosahovaly v odpoledních hodinách téměř 20°C (Tabulka 10.3; Obrázek 10.2).

Při velké intenzitě dopadajícího slunečního záření je povrchová teplota vyšší, než teplota vzduchu ve 2 m nad povrchem (Pal Arya 2001; Katsiabani et al.



**Obrázek 10.1** Denní chod  $T_s$  na modelových lokalitách. Hodnoty v grafu jsou vypočteny z 1000 náhodně vybraných pixelů. Krabicové grafy jsou definovány shora třetím kvartilem Q3 a zdola prvním Q1, střední bod představuje medián datového souboru, antény jsou dány maximální a minimální hodnotou.

2009; Gallo et al. 2011). Rozdíl  $T_s - T_a$  se výrazně liší v závislosti na typu krajinného pokryvu a může dosahovat i záporných hodnot. Stejně tak se liší i denní chod obou veličin. Zatímco povrchová teplota dosahuje maxima okolo 12:30 h, současně s nejvyšší intenzitou dopadajícího slunečního záření, teplota vzduchu má své maximum posunuto na pozdní odpoledne mezi 16:00–17:00 h (Tabulka 10.3; Obrázek 10.2). Největší rozdíly  $T_s - T_a$  (témař o 15 °C) byly zaznamenány na lokalitách „pole“ a „posečená louka“, tedy na místech témař bez vegetace, nebo



**Obrázek 10.2** Rozdíly v denním průběhu teplot  $T_s$  a  $T_a$  na modelových lokalitách.

**Tabulka 10.2** Průměrné charakteristiky povrchové teploty ( $T_s$ ) modelových lokalit měřené termovizní kamerou v době 4:50–20:10 h v 16 snímaných horizontech.  $T_{smin}$  změřená minimální teplota,  $T_{smax}$  maximální teplota,  $D_s$  rozdíl obou mezních teplot,  $T_{savrg}$  průměrná teplota ve sledovaném časovém horizontu,  $SD_{sd}$  variabilita teploty vyjádřená směrodatnou odchylkou.

Lokalita <sup>a</sup>	$T_{smin}$	$T_{smax}$	$D_s$	$T_{savrg}$	$SD_{sd}$
PL	9,3	44,2	34,8	28,0	10,98
ML	10,0	31,9	21,9	22,6	6,78
O	10,1	28,9	18,8	21,7	5,95
L	12,0	29,0	17,0	22,8	5,77
P	13,2	37,2	24,0	26,4	7,70
V	20,4	29,3	8,9	25,6	3,41
A	16,1	47,6	31,4	33,0	10,19

<sup>a</sup> PL – posečená louka, ML – mokrá louka, O – olšina, L – les, P – pole, V – vodní plocha, A – asfalt

s vegetací suchou, a to v době maximální intenzity slunečního záření. Naopak na lokalitách s vegetací dobře zásobenou vodou (mokrá louka, olšina, les), jsou povrchové teploty  $T_s$  nižší, než je teplota vzduchu  $T_a$ .

V klimatologických a meteorologických učebnicích je rozdíl mezi oběma teplotami  $T_s$  a  $T_a$  často zmiňován a je všeobecně známou skutečností. Avšak důsledky, které z tohoto rozdílu vyplývají, jsou zcela opomíjeny v diskusích o klimatu a klimatické změně a nejsou obsaženy v doporučeních, jak tyto změny mírnit. Odvodněná krajina zbavená trvalé vegetace se přehřívá, ohřátý vzduch pojme velké

**Tabulka 10.3** Porovnání průměrných teplot vzduchu  $T_a$  a povrchových teplot  $T_s$  na jednotlivých lokalitách;  $SD_a$  – směrodatná odchylná teploty vzduchu;  $T_a$  průměr teploty vzduchu z pěti meteorologických stanic.

Čas	Průměrná $T_a$ ve 2 m [°C]	Průměrná povrchová teplota na modelových lokalitách [ $T_s$ , °C]							
		$SD_a$	Posečená louka	Mokrá louka	Olsina	Les	Pole	Voda	Asfalt
4:50	10,5	1,13	9,3	10,0	10,1	12,0	13,2	20,4	16,1
5:30	11,8	0,81	13,4	12,2	12,9	12,7	14,9	20,7	16,4
6:00	15,2	0,68	16,7	14,6	13,8	14,3	16,5	20,4	19,1
7:10	18,5	1,16	22,6	18,4	17,2	17,1	20,6	21,0	24,7
8:10	22,0	1,02	31,0	23,0	21,2	20,6	26,2	22,9	31,2
9:10	25,0	0,71	35,1	25,0	22,8	22,0	28,8	23,4	34,8
10:40	28,0	0,49	42,0	29,4	26,7	26,1	34,9	26,0	42,6
13:10	30,1	0,51	44,2	31,9	28,9	29,0	37,2	27,7	47,6
14:00	30,0	0,97	42,6	31,7	28,7	28,6	36,2	29,1	46,6
15:10	30,7	0,64	39,9	30,0	27,6	28,3	35,2	28,7	44,9
16:10	31,0	0,52	35,5	28,9	26,4	27,9	32,5	29,3	41,9
17:10	31,1	0,88	31,6	26,4	26,0	27,1	30,6	28,3	38,8
18:10	31,0	0,64	26,0	23,3	23,4	26,4	27,1	28,1	33,8
18:40	28,6	1,62	23,5	22,1	22,4	26,1	25,0	28,3	31,9
19:10	26,7	2,11	19,8	19,2	20,4	24,4	23,1	27,2	29,7
20:10	20,6	1,62	15,4	16,2	18,7	22,5	21,1	27,4	27,6

množství vodní páry a vynáší ji vzhůru, kde se setká se vzduchem chladným. Teplotní rozdíly/energetické potenciály se vyrovnávají až v atmosféře, protože na povrchu země chybí voda a vegetace. Velká teplotní variabilita mezi lokalitami způsobuje výrazné horizontální teplotní gradienty, jejichž důsledkem je zvýšený turbulentní tok tepla, vyšší rychlosť větru a následné vysoušení krajiny. V krajině bez vody se přeměňuje většina dopadajícího slunečního záření na tzv. pociťové teplo, které ji ohřívá. Uvolněné teplo z plochy  $2\text{--}3 \text{ km}^2$  odvodněného pole je za slunného dne srovnatelné s výkonem 2000 MW elektrárny. Výsledky studie ukazují, že přítomnost vody v krajině, a to nejen v podobě vodních ploch, ale především její obsah ve vegetaci a v půdě, je nezbytná pro vyrovnávání teplotních rozdílů a snižování povrchové teploty. Vegetace zásobená vodou vyrovnává teploty mezi místy, chladí sebe i své okolí. Např. strom o průměru koruny 10 m vypaří za den 400 l vody a ochladí tak svoje okolí o 270 kWh; tato energie vázaná jako skupenské teplo vodní páry se uvolní na chladných místech při její kondenzaci. Strom tedy klimatizuje dvojnásobně: chladí výparem vody a vodní pára se následně sráží na chladných místech, kde se uvolňuje teplo přenesené z místa jeho nadbytku. Stromy/ekosystémy přitom rostou, resp. se zdokonalují.

Clověk hospodařením s vodou a vegetací mění teploty v krajině více než zaznamenává standardní měření teplot vzduchu. Rozhoduje o distribuci sluneční energie, oběhu vody a teplotách svým způsobem hospodaření na rozsáhlých plochách, a tím má přímý vliv na klima. Zpráva IPCC však tento přímý efekt vody a vegetace na klima neuvažuje. Intenzifikace zemědělství a urbanizace negativně zasahují do toků a distribuce energie v krajině. Odvodnění a odstranění trvalé a funkční vegetace (nejen lesních porostů, ale i mokřadů a vlhkých luk), upřednostňování suchomilných a teplomilných plodin, to vše vede k přehřívání krajiny a její degradaci. Tato skutečnost se následně odráží i ve zvýšené erozi a ztrátě živin (Procházka et al. 2009; Ripl 2003). Teplota zemědělské krajiny v době vrcholné fáze zrání plodin a po sklizni je stejná, jako teplota industriální a urbanizované krajiny (Hesslerová & Pokorný 2010b). Proto by subjekty hospodařící v krajině, rozhodující o jejím využívání a tvorbě (zemědělci, lesníci, rybáři, apod.), měly být považovány za významné „ovladače“ distribuce sluneční energie, tzn. za tvůrce lokálního klimatu. Jejich nástrojem je rozumné hospodaření s vodou a vegetací v krajině.

### Doporučená literatura

- Hesslerová, P., Pokorný, J., Brom, J. & Rejšková-Procházková, A. 2013. Daily dynamics of radiation surface temperature of different land cover types in a temperate cultural landscape: Consequences for the local climate. *Ecological Engineering* 54: 145–154.
- Quattrochi, D.A. & Luval, J.C. 2004. *Thermal Remote Sensing in Land Surface Processing*. CRC Press.

# CITOVANÁ LITERATURA

- Adamchuk, V.I., Ferguson, R.B. & Herbert, G.W. 2010. Soil heterogeneity and crop growth. *Precision Crop Protection - the Challenge and Use of Heterogeneity*, editors E.C. Oerke, R. Gerhards, G. Menz & R.A. Sikora, 3–16, Springer, Dordrecht; Heidelberg [u.a].
- Adamchuk, V.I., Hummel, J.W., Morgan, M.T. & Upadhyaya, S.K. 2004. On-the-go soil sensors for precision agriculture. *Computers and Electronics in Agriculture* 44: 71–91.
- Adler-Golden, S.M., Matthew, M.W., Bernstein, L.S., Levine, R.Y., Berk, A., Richtsmeier, S.C., Acharya, P.K., Anderson, G.P., Felde, J.W., Gardner, J.A., Hoke, M.L., Jeong, L.S., Pukall, B., Ratkowski, A.J. & Burke, H.H.K. 1999. Atmospheric correction for shortwave spectral imagery based on MODTRAN4. *SPIE Proceedings on Imaging Spectrometry*, vol. 3753, 61–69.
- Alberti, G., Boscutti, F., Pirotti, F., Bertacco, C., De Simon, G., Sigura, M., Cazorzi, F. & Bonfanti, P. 2013. A LiDAR-based approach for a multipurpose characterization of alpine forests: an italyan case study. *iForest - Biogeosciences and Forestry* 6: 156–168.
- Arregui, L.M., Lasa, B., Lafarga, A., Irañeta, I., Barroja, E. & Quemada, M. 2006. Evaluation of chlorophyll meters as tools for N fertilization in winter wheat under humid mediterranean conditions. *European Journal of Agronomy* 24: 140–148.
- Asner, G., Hicke, J. & Lobell, D.B. 2003. Per-pixel analysis of forest structure: Vegetation indices, spectral mixture analysis and canopy reflectance modeling. *Remote sensing of forest environments. Concepts and case studies*, editors M. Wulder & S. Franklin, 209–254, Kluwer Academic Publishers, Boston.
- Atzberger, C. 2004. Object-based retrieval of biophysical canopy variables using artificial neural nets and radiative transfer models. *Remote Sensing of Environment* 93: 53–67.
- Axelsson, P. 2000. DEM generation from laser scanner data using adaptive TIN models. *International Archives of Photogrammetry and Remote Sensing* 33: 110–117.
- Baldridge, A., Hook, S., Grove, C. & Rivera, G. 2009. The ASTER spectral library version 2.0. *Remote Sensing of Environment* 113: 711–715.
- Baltsavias, E.P. 1999. Airborne laser scanning: existing systems and firms and other resources. *ISPRS Journal of Photogrammetry and Remote Sensing* 54: 164–198.
- Baret, F. & Buis, S. 2008. Estimating canopy characteristics from remote sensing observations: Review of methods and associated problems. *Advances in Land Remote Sensing: System, Modeling, Inversion and Application*, editor S. Liang, 173–201, Springer.
- Baret, F. & Guyot, G. 1991. Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment* 35: 161–173.
- Barnsley, M., Settle, J., Cutter, M., Lobb, D. & Teston, F. 2004. The PROBA/CHRIS mission: a low-cost smallsat for hyperspectral multiangle observations of the earth surface and atmosphere. *IEEE Transactions on Geoscience and Remote Sensing* 42: 1512–1520.
- Baumgardner, M.F., Silva, L.F., Biehl, L.L., Stoner, E.R. & Brady, N.C. 1985. Reflectance properties of soils. *Advances in Agronomy*, vol. Volume 38, 1–44, Academic Press.
- Beal, D. & Eamon, M. 2009. Preliminary results of testing and a proposal for radiometric error correction using dynamic, parabolic linear transformations of "stepped" data (PCORRECT.EXE). Tech. rep., Analytical Spectral Devices, Inc.
- Bell, F. & Donnelly, L. 2006. *Mining and its Impact on the Environment*. Taylor & Francis, London.
- Ben-Dor, E., Chabirillat, S., Dematt, J.A.M., Taylor, G.R., Hill, J., Whiting, M.L. & Sommer, S. 2009. Using imaging spectroscopy to study soil properties. *Remote Sensing of Environment* 113: S38–S55.
- Ben-Dor, E., Imbar, Y. & Chen, Y. 1997. The reflectance spectra of organic matter in the visible near-infrared and short wave infrared region (400–2500 nm) during a controlled decomposition process. *Remote Sensing of Environment* 61: 1–15.
- Berk, A., Anderson, G., Acharya, P., Bernstein, L.S.,

- Muratov, L., Lee, J., Fox, M., Adler-Golden, S.M., Chetwynd, J.H., Hoke, M.L., Lockwood, R., Gardner, J.A., Cooley, T., Borel, C.C., Lewis, P.E. & Shettle, E. 2006. MODTRAN5: 2006 update. *Proc. SPIE* Vol. 6233, 62331F.
- Berk, A., Bernsten, L. & Robertson, D. 1989. MODTRAN: A moderate resolution model for LOWTRAN7. Tech. rep., Air Force Geophysics Laboratory, Hanscom AFB, MA.
- Bo, Z., Wei, G., Shuo, S. & Shalei, S. 2011. A multi-wavelength canopy LiDAR for vegetation monitoring: System implementation and laboratory-based tests. *Procedia Environmental Sciences* 10, Part C: 2775–2782.
- Bornemann, L., Welp, G., Brodowski, S., Rodionov, A. & Amelung, W. 2008. Rapid assessment of black carbon in soil organic matter using mid-infrared spectroscopy. *Organic Geochemistry* 39: 1537–1544.
- Bradshaw, A. 1997. Restoration of mined lands—using natural processes. *Ecological Engineering* 8: 255–269.
- Brady, N.C. & Weil, R.R. 1999. *The nature and properties of soils*. Prentice Hall, Upper Saddle River.
- Brandberg, T., Warner, T.A., Landenberg, R.E. & McGraw, J.B. 2003. Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density lidar data from the eastern deciduous forest in north america. *Remote Sensing of Environment* 85: 290–303.
- Breidenbach, J., Næsset, E., Lien, V., Gobakken, T. & Solberg, S. 2010. Prediction of species specific forest inventory attributes using a nonparametric semi-individual tree crown approach based on fused airborne laser scanning and multispectral data. *Remote Sensing of Environment* 114: 911–924.
- Broge, N.H. & Leblanc, E. 2001. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of Environment* 76: 156–172.
- Brázdil, J. 2012. Technická zpráva k digitálnímu modelu reliéfu 5. generace (DMR 5G). (in Czech). Tech. rep., Český zeměměřický úřad (Czech Office for Surveying, Mapping and Cadastre).
- Bunting, P. & Lucas, R. 2006. The delineation of tree crowns in australian mixed species forests using hyperspectral compact airborne spectrographic imager (CASI) data. *Remote Sensing of Environment* 101: 230–248.
- Campbell, J.B. & Wynne, R.H. 2011. *Introduction to remote sensing (5th edition)*. The Guilford Press, 72 Spring Street, New York NY 10012.
- Carson, W.W., Andersen, H.E., Reutebuch, S.E. & McGaughey, R.J. 2004. LiDAR applications in forestry: An overview. *Annual ASPRES Conference Proceedings*, Denver, USA.
- Carter, G. 1994. Ratios of leaf reflectances in narrow wavebands as indicators of plant stress. *International Journal of Remote Sensing* 15: 697–703.
- Casa, R., Castaldi, F., Pascucci, S., Palombo, A. & Pignatti, S. 2013. A comparison of sensor resolution and calibration strategies for soil texture estimation from hyperspectral remote sensing. *Geoderma* 197–198: 17–26.
- CESBIO 2013, DART user's manual (release may 24, 213).
- Chang-Hua, J., Yong-Chao, T., Xia, Y., Wei-Xing, C., Yan, Z. & Hannaway, D. 2010. Estimating leaf chlorophyll content using red edge parameters. *Pedosphere* 20: 633–644.
- Chen, Q., Baldocchi, D., Gong, P. & Kelly, M. 2006. Isolating individual trees in a savanna woodland using small footprint lidar data. *Photogrammetric Engineering & Remote Sensing* 72: 923–932.
- Cheng, C., Wei, Y., Sun, X. & Zhou, Y. 2013. Estimation of chlorophyll-a concentration in turbid lake using spectral smoothing and derivative analysis. *International Journal of Environmental Research and Public Health* 10: 2979–2994.
- Cho, M.A. & Skidmore, A.K. 2006. A new technique for extracting the red edge position from hyperspectral data: The linear extrapolation method. *Remote Sensing of Environment* 101: 181–193.
- Choi, K.Y. & Milton, E.J. 2001. A model-based approach to correcting spectral irradiance data using and upward-looking airborne sensor (CASI ILS).
- Chorus, I. 2001. *Cyanotoxins: occurrence, causes, consequences*. Springer-Verlag Berlin Heidelberg.
- Chorus, I., Bartram, J., Falconer, I.R. & Salas, H.J. 2000. Health risks caused by freshwater cyanobacteria in recreational waters. *Journal of Toxicology and Environmental Health, Part B* 3: 323–347.
- Christy, C.D. 2008. Real-time measurement of soil attributes using on-the-go near infrared reflectance spectroscopy. *Computers and Electronics in Agriculture* 61: 10–19.
- Cibulka, M. & Mikita, T. 2011. Přesnost digitálního modelu reliéfu vytvořeného z dat leteckého laserového skenování v lesních porostech (in Czech). *Geodetický a kartografický obzor* 57: 264–267.
- Cohen, W.B. & Goward, S.N. 2004. Landsat's role in ecological applications of remote sensing. *BioScience* 54: 535–545.
- Colombo, R., Bellingeri, D., Fasolini, D. & Marino, C.M. 2003. Retrieval of leaf area index in different vegetation types using high resolution satellite data. *Remote Sensing of Environment* 86: 120–131.
- Combal, B., Baret, F., Weiss, M., Trubuil, A., Mace, D., Pragnere, A., Myneni, R., Knyazikhin, Y. & Wang, L. 2002. Retrieval of canopy biophysical variables from bidirectional reflectance: Using prior information to solve the ill-posed inverse problem. *Remote Sensing of Environment* 84: 1–15.
- Corwin, D.L. & Lesch, S.M. 2003. Application of soil electrical conductivity to precision agriculture: Theory, principles, and guidelines. *Agronomy Journal* 95: 455–471.
- Corwin, D.L. & Lesch, S.M. 2005. Apparent soil electrical conductivity measurements in agriculture. *Computers and Electronics in Agriculture* 46: 11–43.
- Corwin, D.L. & Plant, R.E. 2005. Applications of apparent soil electrical conductivity in precision agriculture. *Computers and Electronics in Agriculture* 46: 1–10.
- Croft, H., Chen, J.M., Zhang, Y. & Simic, A. 2013. Modelling leaf chlorophyll content in broadleaf and needle leaf canopies from ground, CASI, landsat TM 5 and MERIS reflectance data. *Remote Sensing of Environment* 133: 128–140.
- Culvenor, D.S. 2002. TIDA: an algorithm for the delineation of tree crowns in high spatial resolution remotely sensed imagery. *Computers & Geosciences* 28: 33–44.
- Curran, P.J., Dungan, J.L. & Peterson, D.L. 2001. Estimating the foliar biochemical concentration of leaves with reflectance spectrometry testing the kohaly and clark methodologies. *Remote Sensing*

- of Environment* 76: 349–359.
- Darvishzadeh, R., Matkan, A. & Dashti Ahangar, A. 2012. Inversion of a radiative transfer model for estimation of rice canopy chlorophyll content using a lookup-table approach. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 5: 1222–1230.
- Dash, J. & Curran, P.J. 2004. The MERIS terrestrial chlorophyll index. *International Journal of Remote Sensing* 25: 5403–5413.
- Datt, B. 1998. Remote sensing of chlorophyll a, chlorophyll b, chlorophyll a+b, and total carotenoid content in eucalyptus leaves. *Remote Sensing of Environment* 66: 111–121.
- Datt, B. 1999. Visible/near infrared reflectance and chlorophyll content in eucalyptus leaves. *International Journal of Remote Sensing* 20: 2741–2759.
- Daughtry, C.S.T., Walthall, C.L., Kim, M.S., de Colstoun, E.B. & McMurtrey, J.E. 2000. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote Sensing of Environment* 74: 229–239.
- Dawson, T.P. & Curran, P.J. 1998. Technical note a new technique for interpolating the reflectance red edge position. *International Journal of Remote Sensing* 19: 2133–2139.
- Dawson, T.P., Curran, P.J. & Plummer, S.E. 1998. LIBERTY: Modeling the effects of leaf biochemical concentration on reflectance spectra. *Remote Sensing of Environment* 65: 50–60.
- De Benedetto, D., Castrignanò, A., Rinaldi, M., Ruggieri, S., Santoro, F., Figitto, B., Gualano, S., Diacono, M. & Tamborrino, R. 2013. An approach for delineating homogeneous zones by using multi-sensor data. *Geoderma* 199: 117–127.
- Delegido, J., Alonso, L., González, G. & Moreno, J. 2010. Estimating chlorophyll content of crops from hyperspectral data using a normalized area over reflectance curve (NAOC). *International Journal of Applied Earth Observation and Geoinformation* 12: 165–174.
- Dickinson, Y., Zenner, E. & Miller, D. 2014. Examining the effect of diverse management strategies on landscape scale patterns of forest structure in pennsylvania using novel remote sensing techniques. *Canadian Journal of Forest Research* 44: 301–312.
- Duan, H., Ma, R., Xu, X., Kong, F., Zhang, S., Kong, W., Hao, J. & Shang, L. 2009. Two-decade reconstruction of algal blooms in china's lake taihu. *Environmental Science & Technology* 43: 3522–3528.
- Eiseitová, M., Pokorný, J., Hesslerová, P. & Ripl, W. 2012. Evapotranspiration – a driving force in landscape sustainability. *Evapotranspiration - Remote Sensing and Modeling*, 305 – 328, In-Tech.
- Erikson, M. 2003. Segmentation of individual tree crowns in colour aerial photographs using region growing supported by fuzzy rules. *Canadian Journal of Forest Research* 33: 1557–1563.
- Fargasova, A. 1994. Effect of Pb, Cd, Hg, As, and Cr on germination and root-growth of sinapis-alba seeds. *Bulletin of Environmental Contamination and Toxicology* 52: 452–456.
- Fargasova, A. 1998. Root growth inhibition, photosynthetic pigments production, and metal accumulation in Sinapis alba as the parameters for trace metals effect determination. *Bulletin of Environmental Contamination and Toxicology* 61: 762–769.
- Feret, J.B., Francois, C., Asner, G.P., Gitelson, A.A., Martin, R.E., Bidel, L.P.R., Ustin, S.L., le Maire, G. & Jacquemoud, S. 2008. PROSPECT-4 and 5: Advances in the leaf optical properties model separating photosynthetic pigments. *Remote Sensing of Environment* 112: 3030–3043.
- Fernandez-Diaz, J., Glennie, C., Carter, W., Shrestha, R., Sartori, M., Singhania, A., Legleiter, C. & Overstreet, B. 2014. Early results of simultaneous terrain and shallow water bathymetry mapping using a single-wavelength airborne LiDAR sensor. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7: 623–635.
- Filella, I. & Peñuelas, J. 1994. The red edge position and shape as indicators of plant chlorophyll content, biomass and hydric status. *International Journal of Remote Sensing* 15: 1459–1470.
- Frouz, J., Dvorčík, P., Vindušková, O. & Cienciala, E. 2014. Plant production, carbon accumulation and soil chemistry at post-mining sites. *Soil Biota and Ecosystem Development in Post Mining Sites*, editor J. Frouz, 88–103, CRC press, Boca Raton, FL.
- Frouz, J., Hrčková, K., Lána, J., Krištúfek, V., Mudrák, O., Lukešová, A. & Mihaljevič, M. 2011. Can laboratory toxicity tests explain the pattern of field communities of algae, plants, and invertebrates along a toxicity gradient of post-mining sites? *Applied Soil Ecology* 51: 114–121.
- Frouz, J., Krištúfek, V., Bastl, J., Kalčík, J. & Vaňková, H. 2005. Determination of toxicity of spoil substrates after brown coal mining using a laboratory reproduction test with enchytraeus crypticus (oligochaeta). *Water, Air, & Soil Pollution* 162: 37–47.
- Gallo, K., Hale, R., Tarpley, D. & Yu, Y. 2011. Evaluation of the relationship between air and land surface temperature under clear- and cloudy-sky conditions. *Journal of applied Meteorology and Climatology* 767 – 775.
- Gamon, J.A., Field, C.B., Bilger, W., Björkman, O., Fredeen, A.L. & Peñuelas, J. 1990. Remote sensing of the xanthophyll cycle and chlorophyll fluorescence in sunflower leaves and canopies. *Oecologia* 85: 1–7.
- Ganapol, B.D., Johnson, L.F., Hammer, P.D., Hlavka, C.A. & Peterson, D.L. 1998. LEAFMOD: a new within-leaf radiative transfer model. *Remote Sensing of Environment* 63: 182–193.
- Gao, B.C., Heidebrecht, K.B. & Goetz, A.F. 1993. Derivation of scaled surface reflectances from AVIRIS data. *Remote Sensing of Environment* 44: 165–178.
- Gao, B.C., Montes, M.J., Davis, C.O. & Goetz, A.F.H. 2009. Atmospheric correction algorithms for hyperspectral remote sensing data of land and ocean. *Remote Sensing of Environment* 113, Supplement 1: S17–S24.
- Gascon, F., Gastellu-Etchegorry, J.P., Lefevre-Fonollosa, M.J. & Dufrene, E. 2004. Retrieval of forest biophysical variables by inverting a 3-d radiative transfer model and using high and very high resolution imagery. *International Journal of Remote Sensing* 25: 5601–5616.
- Gastellu-Etchegorry, J.P., Demarez, V., Pinel, V. & Zagolski, F. 1996. Modeling radiative transfer in heterogeneous 3-d vegetation canopies. *Remote Sensing of Environment* 58: 131–156.
- Gastellu-Etchegorry, J.P., Martin, E. & Gascon, F. 2004. DART: a 3d model for simulating satellite images and studying surface radiation budget. *In-*

- ternational Journal of Remote Sensing* 25: 73–96.
- Giardino, C., Bresciani, M., Valentini, E., Gasperini, L., Bolpagni, R. & Brando, V.E. 2014. Airborne hyperspectral data to assess suspended particulate matter and aquatic vegetation in a shallow and turbid lake. *Remote Sensing of Environment* 143: 286–292.
- Gitelson, A. & Merzlyak, M. 1994. Spectral reflectance changes associated with autumn senescence of *ace-sulus hippocastanum* l. and *acer platanoides* l. leaves. spectral features and relation to chlorophyll estimation. *Journal of Plant Physiology* 143: 286–292.
- Gitelson, A.A., Gritz, Y. & Merzlyak, M.N. 2003. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology* 160: 271–282.
- Gitelson, A.A., Merzlyak, M.N. & Lichtenthaler, H.K. 1996. Detection of red edge position and chlorophyll content by reflectance measurements near 700 nm. *Journal of Plant Physiology* 148: 501–508.
- Gitelson, A.A., Schalles, J.F. & Hladik, C.M. 2007. Remote chlorophyll-a retrieval in turbid, productive estuaries: Chesapeake bay case study. *Remote Sensing of Environment* 109: 464–472.
- Gökkaya, K., Thomas, V., Noland, T., McCaughey, H. & Treitz, P. 2014. Testing the robustness of predictive models for chlorophyll generated from spaceborne imaging spectroscopy data for a mixedwood boreal forest canopy. *International Journal of Remote Sensing* 35: 218–233.
- Goddard, V., Baker, A., Davy, J., Adams, D., De Ville, M., Thackeray, S., Maberly, S. & Wilson, W. 2005. Temporal distribution of viruses, bacteria and phytoplankton throughout the water column in a freshwater hypereutrophic lake. *Aquatic Microbial Ecology* 39: 211–223.
- Godwin, R.J. & Miller, P.C.H. 2003. A review of the technologies for mapping within-field variability. *Biosystems Engineering* 84: 393–407.
- Gougeon, F.A. 1995. A crown-following approach to the automatic delineation of individual tree crowns in high spatial resolution digital images. *Canadian Journal of Remote Sensing* 21: 274–284.
- Govaerts, Y.M. & Verstraete, M.M. 1998. Raytran: A monte carlo ray-tracing model to compute light scattering in three-dimensional heterogeneous media. *IEEE Transactions on Geoscience and Remote Sensing* 36: 493–505.
- Gower, J.F.R., Borstad, G.A., Anger, G.D. & Edel, H.R. 1992. CCD-based imaging spectroscopy for remote sensing: The FLI and CASI programs. *Canadian Journal of Remote Sensing* 18.
- Gregor, J., Geriš, R., Maršálek, B., Hetěša, J. & Marvan, P. 2005. In situ quantification of phytoplankton in reservoirs using a submersible spectrophotometer. *Hydrobiologia* 548: 141–151.
- Gregor, J. & Maršálek, B. 2004. Freshwater phytoplankton quantification by chlorophyll a: a comparative study of in vitro, in vivo and in situ methods. *Water Research* 38: 517–522.
- Gregor, J., Maršálek, B. & Šípková, H. 2007. Detection and estimation of potentially toxic cyanobacteria in raw water at the drinking water treatment plant by in vivo fluorescence method. *Water Research* 41: 228–234.
- Gu, D., Gillespie, A., Kahle, A. & Palluconi, F. 2000. Autonomous atmospheric compensation (AAC) of high resolution hyperspectral thermal infrared remote-sensing imagery. *IEEE Transactions on Geoscience and Remote Sensing* 38: 2557–2570.
- Gupta, S., Weinacker, H. & Koch, B. 2010. Comparative analysis of clustering-based approaches for 3-d single tree detection using airborne fullwave lidar data. *Remote Sensing* 2: 968–989.
- Guyot, G. & Baret, F. 1988. Utilisation de la haute résolution spectrale pour suivre l'état des couverts végétaux. 279.
- Guyot, G., Baret, F. & Major, D. 1988. High spectral resolution: determination of spectral shifts between the red and the near infrared. *International Archives of Photogrammetry and Remote Sensing* 11: 750–760.
- Haboudane, D., Miller, J.R., Tremblay, N., Zarco-Tejada, P.J. & Dextraze, L. 2002. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of Environment* 81: 416–426.
- Hansen, M.C. & Loveland, T.R. 2012. A review of large area monitoring of land cover change using landsat data. *Remote Sensing of Environment* 122: 66–74.
- Hanuš, J., Fabiánek, T., Kaplan, V. & Homolová, L. 2014. Flying laboratory of imaging systems (FLIS) at CzechGlobe. *14<sup>th</sup> International Multidisciplinary scientific conference SGEM 2014 on Informatics, Geoinformatics and Remote Sensing*, vol. III, 177–182, 17–26, June 2014, Bulgaria.
- Hedley, J.D., Harborne, A.R. & Mumby, P.J. 2005. Simple and robust removal of sun glint for mapping shallow-water benthos. *International Journal of Remote Sensing* 26: 2107–2112.
- Heege, H.J., Reusch, S. & Thiessen, E. 2008. Prospects and results for optical systems for site-specific on-the-go control of nitrogen-top-dressing in germany. *Precision Agriculture* 9: 115–131.
- Heinzel, J. & Koch, B. 2011. Exploring full-waveform LiDAR parameters for tree species classification. *International Journal of Applied Earth Observation and Geoinformation* 13: 152–160.
- Hesslerová, P. & Pokorný, J. 2010a. Forest clearing, water loss, and land surface rating as development costs. *International Journal of Water* 5: 401 – 418.
- Hesslerová, P. & Pokorný, J. 2010b. The synergy of solar radiation, plant biomass, and humidity as an indicator of ecological functions of the landscape: A case study from central europe. *Integrated Environmental Assessment and Management* 6: 249 – 259.
- Hesslerová, P., Pokorný, J., Brom, J. & Rejšková Procházková, A. 2013. Daily dynamics of radiation surface temperature of different land cover types in a temperate cultural landscape: Consequences for the local climate. *Ecological Engineering* 145 – 154.
- Heurich, M., Schneider, T. & Kennel, E. 2003. Laser scanning for identification of forest structures in the bavarian forest national park. *Proceedings of the ScandLaser scientific workshop on airborne laser scanning of forests.*, 98–107, Swedish University of Agricultural Sciences, Umea, Sweden.
- Hirschmugl, M., Ofner, M., Raggam, J. & Schardt, M. 2007. Single tree detection in very high resolution remote sensing data. *Remote Sensing of Environment* 110: 533–544.
- Hilker, T., Coops, N.C., Wulder, M.A., Black, T.A. & Guy, R.D. 2008. The use of remote sensing in li-

- ght use efficiency based models of gross primary production: A review of current status and future requirements. *Science of the Total Environment* 404: 411–423.
- Holopainen, M. & Hyppä, J. 2003. Possibilities with laser scanning in practical forestry. *Proceedings of the ScandLaser scientific workshop on airborne laser scanning of forests*, 265–274, Swedish University of Agricultural Sciences, Umeå, Sweden.
- Holopainen, M., Mäkinen, A., Rasinmäki, J., Hyppä, J., Hyppä, H., Kaartinen, H., Viitala, R., Vastaranta, M. & Kangas, A. 2010. Effect of tree-level airborne laser-scanning measurement accuracy on the timing and expected value of harvest decisions. *European Journal of Forest Research* 129: 899–907.
- Holopainen, M., Vastaranta, M. & Hyppä, J. 2014. Outlook for the next generation's precision forestry in finland. *Forests* 5: 1682–1694.
- Homolová, L., Malenovský, Z., Clevers, J., García-Santos, G. & Schaepman, M. 2013. Review of optical-based remote sensing for plant trait mapping. *Ecological Complexity* 15: 1–16.
- Houborg, R., Anderson, M. & Daughtry, C. 2009. Utility of an image-based canopy reflectance modeling tool for remote estimation of LAI and leaf chlorophyll content at the field scale. *Remote Sensing of Environment* 113: 259–274.
- Hyppä, H. & Hyppä, J. 1999. Comparing the accuracy of laser scanner with other optical remote sensing data sources for stand attribute retrieval. *The Photogrammetric Journal of Finland* 16: 5–15.
- Hyppä, J. & Inkinen, M. 1999. Detecting and estimating attributes for single trees using laser scanner. *The Photogrammetric Journal of Finland* 16: 27–42.
- IPCC, 2007. Climate change: the physical science basis. *Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change* 996–996.
- Izydorczyk, K., Tarczynska, M., Jurczak, T., Mrowczynski, J. & Zalewski, M. 2005. Measurement of phycocyanin fluorescence as an online early warning system for cyanobacteria in reservoir intake water. *Environmental Toxicology* 20: 425–430.
- Jacquemoud, S. & Baret, F. 1990. PROSPECT: A model of leaf optical properties spectra. *Remote Sensing of Environment* 34: 75–91.
- Jacquemoud, S., Verhoef, W., Baret, F., Bacour, C., Zarco-Tejada, P.J., Asner, G.P., Francois, C. & Ustin, S.L. 2009. PROSPECT + SAIL models: A review of use for vegetation characterization. *Remote Sensing of Environment* 113: S56–S66.
- Janik, L.J., Skjemstad, J.O., Shepherd, K.D. & Spounger, L.R. 2007. The prediction of soil carbon fractions using mid-infrared-partial least square analysis. *Australian Journal of Soil Research* 45: 73–73.
- Jirka, V., Pokorný, J., Kobrzek, F., Mareček, P., Zicha, J. & Bíla, J., 2011, Soustava prostředků pro zjišťování energetických toků v přízemní vrstvě atmosféry. Česká republika. Užitný vzor, 22671 u1. 2011-09-12. (the system for detecting energy flows in the ground layer of the atmosphere. the czech republic. utility model, 22671 u1. 2011-09-12.).
- Jupp, D., Kirk, J. & Harris, G. 1994. Detection, identification and mapping of cyanobacteria — using remote sensing to measure the optical quality of turbid inland waters. *Marine and Freshwater Research* 45: 801–828.
- Jutzi, B. & Gross, H. 2007. Normalization of lidar intensity data based on range and surface incidence angle. ETH, Zürich, Switzerland, July 9–12, 2007.
- Kahru, M., Savchuk, O. & Elmgren, R. 2007. Satellite measurements of cyanobacterial bloom frequency in the baltic sea: interannual and spatial variability. *Marine Ecology Progress Series* 343: 15–23.
- Karu, H., Szava-Kovats, R., Pensa, M. & Kull, O. 2009. Carbon sequestration in a chronosequence of scots pine stands in a reclaimed opencast oil shale mine. *Canadian Journal of Forest Research-Revue Canadienne De Recherche Forestière* 39: 1507–1517.
- Katsiabani, K., Adaktilou, N. & Cartalis, C. 2009. A generalised methodology for estimating land surface temperature for non-urban areas of Greece through the combined use of NOAA-AVHRR data and ancillary information. 43, 930–940. *Advances in Space Research* 930 – 940.
- Kříbek, B., Strnad, M., Boháček, Z., Sýkorová, I., Čejka, J. & Sobalík, Z. 1998. Geochemistry of miocene lacustrine sediments from the Sokolov coal basin (Czech Republic). *International Journal of Coal Geology* 37: 207–233.
- Kedziora, A. 2010. Landscape management practices for maintenance and enhancement of ecosystem services in countryside. *Ecohydrology & Hydrobiology* 10: 133 – 152.
- Křen, J., Klem, K., Svobodová, I., Miša, P. & Neudert, L. 2014. Yield and grain quality of spring barley as affected by biomass formation at early growth stages. *Plant Soil and Environment* 60: 221–227.
- Křen, J., Lukas, V., Svobodová, I., Dryšlová, T., Miša, P. & Neudert, L. 2009. Possibilities of cereal canopy assessment by using the NDVI. In *Proceedings of Precision Agriculture '09*, E.J. van Henten, D. Goense & C. Lokhorst (Eds.), 151–158, Wageningen Academic Publishers.
- Kimes, D., Gastellu-Etchegorry, J. & Esteve, P. 2002. Recovery of forest canopy characteristics through inversion of a complex 3d model. *Remote Sensing of Environment* 79: 320–328.
- Kirilen, A., Achmetov, R., Stratilatov, N., Baklanov, A., Fedorov, V. & Novikov, M. 2010. Spacecraft resurs-p. *Geomatics by Sovzond* 4: 23–25 (in Russian).
- Koch, B., Heyder, U. & Weinacker, H. 2006. Detection of individual tree crowns in airborne lidar data. *Photogrammetric Engineering & Remote Sensing* 72: 357–363.
- Kokaly, R.F., Asner, G.P., Ollinger, S.V., Martin, M.E. & Wessman, C.A. 2009. Characterizing canopy biochemistry from imaging spectroscopy and its application to ecosystem studies. *Remote Sensing of Environment* 113: S78–S91.
- Kokaly, R.F. & Clark, R.N. 1999. Spectroscopic determination of leaf biochemistry using band-depth analysis of absorption features and stepwise multiple linear regression. *Remote Sensing of Environment* 67: 267–287.
- Korpela, I., Ørka, H.O., Maltamo, M., Tokola, T. & Hyppä, J. 2010. Tree species classification using airborne LiDAR—effects of stand and tree parameters, downsizing of training set, intensity normalization, and sensor type. *Silva Fennica* 44: 319–339.
- Kotchenova, S.Y., Vermote, E.F., Matarrese, R. & Klemm Jr, F.J. 2006. Validation of a vector version of the 6s radiative transfer code for atmospheric correction of satellite data. part i: Path radiance. *Applied Optics* 45: 6762–6774.
- Kruse, F., Lefkoff, A., Boardman, J., Heidebrecht,

- K., Shapiro, A., Barloon, P. & Goetz, A. 1993. The spectral image processing system (SIPS)—interactive visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment* 44: 145–163.
- Kruse, F.A. 2004. Comparison of ATREM, ACORN, and FLAASH atmospheric corrections using low-altitude AVIRIS data of boulder, CO. *13th JPL Airborne Geoscience Workshop*.
- Kunkel, B., Blechinger, F., Viehmann, D., Van Der Piepen, H. & Doerffer, R. 1991. ROSIS imaging spectrometer and its potential for ocean parameter measurements (airborne and space-borne). *International Journal of Remote Sensing* 12: 753–761.
- Kwak, D.A., Lee, W.K., Lee, J.H., Biging, G.S. & Gong, P. 2007. Detection of individual trees and estimation of tree height using LiDAR data. *Journal of Forest Research* 12: 425–434.
- Laurent, V.C.E., Verhoef, W., Clevers, J.G.P.W. & Schaepman, M.E. 2011. Estimating forest variables from top-of-atmosphere radiance satellite measurements using coupled radiative transfer models. *Remote Sensing of Environment* 115: 1043–1052.
- Laurent, V.C.E., Verhoef, W., Damm, A., Schaepman, M.E. & Clevers, J.G.P.W. 2013. A bayesian object-based approach for estimating vegetation biophysical and biochemical variables from APEX at-sensor radiance data. *Remote Sensing of Environment* 139: 6–17.
- Le, C., Li, Y., Zha, Y., Sun, D., Huang, C. & Lu, H. 2009. A four-band semi-analytical model for estimating chlorophyll a in highly turbid lakes: The case of Taihu lake, China. *Remote Sensing of Environment* 113: 1175–1182.
- le Maire, G., François, C. & Dufrêne, E. 2004. Towards universal broad leaf chlorophyll indices using PROSPECT simulated database and hyperspectral reflectance measurements. *Remote Sensing of Environment* 89: 1–28.
- le Maire, G., François, C., Soudani, K., Berveiller, D., Pontailler, J.Y., Bréda, N., Genet, H., Davi, H. & Dufrêne, E. 2008. Calibration and validation of hyperspectral indices for the estimation of broadleaved forest leaf chlorophyll content, leaf mass per area, leaf area index and leaf canopy biomass. *Remote Sensing of Environment* 112: 3846–3864.
- Leckie, D., Gougeon, F., Hill, D., Quinn, R., Armstrong, L. & Shreenan, R. 2003. Combined high-density lidar and multispectral imagery for individual tree crown analysis. *Canadian Journal of Remote Sensing* 29: 633–649.
- Leonenko, G., Los, S.O. & North, P.R.J. 2013. Statistical distances and their applications to biophysical parameter estimation: Information measures, m-estimates, and minimum contrast methods. *Remote Sensing* 5: 1355–1388.
- Lhotáková, Z., Albrechtová, J., Malenovský, Z., Rock, B.N., Polák, T. & Cudlín, P. 2007. Does the azimuth orientation of norway spruce (*Picea abies*/L./Karst.) branches within sunlit crown part influence the heterogeneity of biochemical, structural and spectral characteristics of needles? *Environmental and Experimental Botany* 59: 283–292.
- Li, F., Mistele, B., Hu, Y., Chen, X. & Schmidhalter, U. 2014. Reflectance estimation of canopy nitrogen content in winter wheat using optimised hyperspectral spectral indices and partial least squares regression. *European Journal of Agronomy* 52: 198–209.
- Li, Z.L., Tang, B.H., Wu, H., Ren, H., Yan, G., Wan, Z., Trigo, I.F. & Sobrino, J.A. 2013. Satellite-derived land surface temperature: Current status and perspectives. *Remote Sensing of Environment* 131: 14–37.
- Liang, S. 2004. *Quantitative remote sensing of land surfaces*. John Wiley & Sons, Inc., Hoboken, New Jersey.
- Lilienthal, H. 2003. *Entwicklung eines bodengestützten Fernerkundungssystems für die Landwirtschaft, Landbauforschung Völkenrode*, vol. Sonderheft 254. Bundesforschungsanst. für Landwirtschaft (FAL), Braunschweig.
- Lillesand, T.M. & Kiefer, R.W. 2000. *Remote Sensing and Image Interpretation (4th edition)*. John Wiley & Sons, Inc., New York.
- Lillesand, T.M., Kiefer, R.W. & Chipman, J.W. 2008. *Remote sensing and image interpretation*. John Wiley & Sons, Hoboken, NJ.
- Loague, K. & Green, R.E. 1991. Statistical and graphical methods for evaluating solute transport models: Overview and application. *Journal of Contaminant Hydrology* 7: 51–73.
- Lukas, V., Neudert, L. & Křen, J. 2011a. *Mapevání variabilitu půdy a porostů v precizním zemědělství*. Metodika pro praxi. Mendel University, Brno, Czech Republic.
- Lukas, V., Ryant, P., Neudert, L., Dryšlová, T., Gnip, P. & Smutný, V. 2011b. *Tvorba aplikačních map pro základní hnojení plodin v precizním zemědělství*. Metodika pro praxi. Mendel University, Brno, Czech Republic.
- Ma, S., Tao, Z., Yang, X., Yu, Y., Zhou, X. & Li, Z. 2014. Bathymetry retrieval from hyperspectral remote sensing data in optical-shallow water. *IEEE Transactions on Geoscience and Remote Sensing* 52: 1205–1212.
- Machala, M. & Zejdová, L. 2014. Forest mapping through object-based image analysis of multispectral and LiDAR aerial data. *European Journal of Remote Sensing* 47: 117–131.
- Maier, S.W., Ludeker, W. & Gunther, K.P. 1999. SLOP: A revised version of the stochastic model for leaf optical properties. *Remote Sensing of Environment* 68: 273–280.
- Main, R., Cho, M.A., Mathieu, R., O'Kennedy, M.M., Ramoelo, A. & Koch, S. 2011. An investigation into robust spectral indices for leaf chlorophyll estimation. *ISPRS Journal of Photogrammetry and Remote Sensing* 66: 751–761.
- Makarieva, A., Gorshkov, V. & Li, B.L. 2006. Conservation of water cycle on land via restoration of natural closed-canopy forests: implications for regional landscape planning. *Ecological Research* 21: 897 – 906.
- Malenovský, Z., Albrechtová, J., Lhotáková, Z., Zurita-Milla, R., Clevers, J., Schaepman, M.E. & Cudlín, P. 2006. Applicability of the PROSPECT model for Norway spruce needles. *International Journal of Remote Sensing* 27: 5315–5340.
- Malenovský, Z., Homolová, L., Zurita-Milla, R., Lukeš, P., Kaplan, V., Hanuš, J., Gastellu-Etchegorry, J.P. & Schaepman, M.E. 2013. Retrieval of spruce leaf chlorophyll content from airborne image data using continuum removal and radiative transfer. *Remote Sensing of Environment* 131: 85–102.
- Malenovský, Z., Martin, E., Homolová, L., Gastellu-Etchegorry, J.P., Zurita-Milla, R., Schaepman, M.E., Pokorný, R., Clevers, J.G.P.W. & Cudlín, P. 2008. Influence of woody elements of a norway spruce canopy on nadir reflectance simulated by

- the DART model at very high spatial resolution. *Remote Sensing of Environment* 112: 1–18.
- Mallet, C. & Bretar, F. 2009. Full-waveform topographic lidar: State-of-the-art. *ISPRS Journal of Photogrammetry and Remote Sensing* 64: 1–16.
- Maltamo, M. 2004. Estimation of timber volume and stem density based on scanning laser altimetry and expected tree size distribution functions. *Remote Sensing of Environment* 90: 319–330.
- Maltamo, M., Packalén, P., Suvanto, A., Korhonen, K.T., Mehtätalo, L. & Hyvönen, P. 2009. Combining ALS and NFI training data for forest management planning: a case study in Kuortane, western Finland. *European Journal of Forest Research* 128: 305–317.
- Maltese, A., Bates, P., Capodici, F., Cannarozzo, M., Ciraolo, G. & La Loggia, G. 2013. Critical analysis of thermal inertia approaches for surface soil water content retrieval. *Hydrological Sciences Journal* 58: 1144–1161.
- Mandlburger, G., Pfennigbauer, M., Steinbacher, F. & Pfeifer, N. 2011. Airborne hydrographic LiDAR mapping—potential of a new technique for capturing shallow water bodies. *MODSIM2011, 19th International Congress on Modelling and Simulation, Modelling and Simulation Society of Australia and New Zealand*, 2416–2422.
- Mariotti, I., Thenkabail, P.S., Huete, A., Sloanecker, E.T. & Platonov, A. 2013. Hyperspectral versus multispectral crop-productivity modeling and type discrimination for the HypsIRI mission. *Remote Sensing of Environment* 139: 291–305.
- Mas, J. & Flores, J. 2008. The application of artificial neural networks to the analysis of remotely sensed data. *International Journal of Remote Sensing* 29: 617–663.
- McCoy, R.M. 2004. *Field Methods in Remote Sensing*. 1 edition ed., The Guilford Press, New York.
- Michajlov, I. 1943. Zahlenmäßiges verfahren für die ausführung der Bestandeshöhenkurven. *Forstwissenschaftliches Centralblatt* 6: 273–279.
- Michel, K., Terhoeven-Urselmans, T., Nitschke, R., Steffan, P. & Ludwig, B. 2009. Use of near- and mid-infrared spectroscopy to distinguish carbon and nitrogen originating from char and forest-floor material in soils. *Journal Of Plant Nutrition And Soil Science* 172: 63–70.
- Mikita, T., Cibulka, M. & Janata, P. 2013a. Hodnocení přesnosti digitálních modelů reliéfu 4. a 5. generace v lesních porostech. *Geodetický a kartografický obzor* 59: 76–85.
- Mikita, T., Klimánek, M. & Cibulka, M. 2013b. Evaluation of airborne laser scanning data for tree parameters and terrain modelling in forest environment. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis* 61: 1339–1347.
- Miller, J., Hare, E. & Wu, J. 1990. Quantitative characterization of the vegetation red edge reflectance 1. an inverted-gaussian reflectance model. *International Journal of Remote Sensing* 11: 1755–1773.
- Milton, E.J., Schaepman, M.E., Anderson, K., Kneubühler, M. & Fox, N. 2009. Progress in field spectroscopy. *Remote Sensing of Environment* 113: S92–S109.
- Ministry of Agriculture. 2010. *Angricuture status report 2009 (Zpráva o stavu zemědělství ČR za rok 2009)*. Ministry of Agriculture, Prague, Czech Republic.
- Mishra, S., Mishra, D.R. & Schluchter, W.M. 2009. A novel algorithm for predicting phycocyanin concentrations in cyanobacteria: A proximal hyperspectral remote sensing approach. *Remote Sensing* 1: 758–775.
- Montreuil, A.L., Levoy, F., Bretel, P. & Anthony, E.J. 2014. Morphological diversity and complex sediment recirculation on the ebb delta of a macrotidal inlet (Normandy, France): A multiple LiDAR dataset approach. *Geomorphology* 219: 114–125.
- Mulder, V.L., de Bruin, S., Schaeppman, M.E. & Mayr, T.R. 2011. The use of remote sensing in soil and terrain mapping — a review. *Geoderma* 162: 1–19.
- Mutanga, O. & Skidmore, A.K. 2007. Red edge shift and biochemical content in grass canopies. *ISPRS Journal of Photogrammetry and Remote Sensing* 62: 34–42.
- Norman, J.M. & Becker, F. 1995. Terminology in thermal infrared remote sensing of natural surfaces. *Agricultural and Forest Meteorology* 77: 153 – 166.
- North, P.R.J. 1996. Three-dimensional forest light interaction model using a monte carlo method. *IEEE Transactions on Geoscience and Remote Sensing* 34: 946–956.
- Novotný, J. 2014. Tree crown delineation using region growing and active contour: Approach introduction. *Mendel 2014: 20th International Conference on Soft Computing*, vol. 20, Brno University of Technology, Brno.
- Næsset, E. 2004. Accuracy of forest inventory using airborne laser scanning: Evaluating the first nordic full-scale operational project. *Scandinavian Journal of Forest Research* 19: 554–557.
- Šourková, M., Frouz, J. & Šantrůčková, H. 2005. Accumulation of carbon, nitrogen and phosphorus during soil formation on alder spoil heaps after brown-coal mining, near Sokolov (Czech Republic). *Geoderma* 124: 203–214.
- Pael, H.W. & Paul, V.J. 2012. Climate change: Links to global expansion of harmful cyanobacteria. *Water Research* 46: 1349–1363.
- Pal Arya, S. 2001. *Introduction to Micrometeorology..* No. 79 in International Geophysics Series, Academic Press, San Diego.
- Pearlman, J., Barry, P., Segal, C., Shepanski, J., Beiso, D. & Carman, S. 2003. Hyperion, a space-based imaging spectrometer. *IEEE Transactions on Geoscience and Remote Sensing* 41: 1160–1173.
- Penuelas, J., Filella, I., Biel, C., Serrano, L. & Save, R. 1993. The reflectance at the 950–970 nm region as an indicator of plant water status. *International Journal of Remote Sensing* 14: 1887–1905.
- Penuelas, J., Gamon, J., Fredeen, A., Merino, J. & Field, C. 1994. Reflectance indices associated with physiological changes in nitrogen- and water-limited sunflower leaves. *Remote Sensing of Environment* 48: 135–146, cited By (since 1996)336.
- Petráš, R. & Pajtik, J. 1991. Sústava československých objemových tabuľiek drevín. *Lesnický časopis* 37: 49–56.
- Petrie, G. 2011. Airborne topographic laser scanners. *GEO Informatics* 14: 34–44.
- Pierce, F.J. & Nowak, P. 1999. Aspects of precision agriculture. *Advances in Agronomy* 67: 1–85.
- Pitkänen, J. 2001. Individual tree detection in digital aerial images by combining locally adaptive binarization and local maxima methods. *Canadian Journal of forest research* 31: 832–844.
- Planck, M. 1900. Zur theorie des gesetzes der energieverteilung im normalspektrum. verhandlungen

- der deutschen physikalischen gesellschaft 2: 237.
- ter Haar, D.* 1967. *On the Theory of the Energy Distribution Law of the Normal Spectrum. The Old Quantum Theory*, Pergamon Press, p. 82, LCNN 66029628.
- Pokorný, J., Brom, J., Čermák, J., Hesslerová, P., Huryna, H., Nadezhina, N. & Rejšková, A. 2010. How water and vegetation control solar energy fluxes and landscape heat. *International Journal of Water* 5: 311 – 336.
- Pouliot, D.A., King, D.J. & Pitt, D.G. 2005. Development and evaluation of an automated tree delineation algorithm for monitoring regenerating coniferous forests. *Canadian Journal of Forest Research* 35: 2332–2345.
- Qu, Z., Kindel, B. & Goetz, A.F.H. 2003. The high accuracy atmospheric correction for hyperspectral data (HATCH) model. *IEEE Transactions on Geoscience and Remote Sensing* 41: 1223–1231.
- Quattrochi, D.A. & Luval, J.C. 2004. *Thermal Remote Sensing in Land Surface Processing*. CRC Press.
- Randolph, K., Wilson, J., Tedesco, L., Li, L., Pascual, D.L. & Soyeux, E. 2008. Hyperspectral remote sensing of cyanobacteria in turbid productive water using optically active pigments, chlorophyll a and phycocyanin. *Remote Sensing of Environment* 112: 4009–4019.
- Rao, P.V.L., Gupta, N., Bhaskar, A.S.B. & Jayaraj, R. 2002. Toxins and bioactive compounds from cyanobacteria and their implications on human health. *Journal of environmental biology / Academy of Environmental Biology, India* 23: 215–224.
- Richter, R. 2012. Atmospheric / topographic correction for airborne imagery (ATCOR-4 user guide, version 6.2 BETA). Tech. rep., DLR - German Aerospace Center, Wessling (Germany).
- Richter, R. & Schläpfer, D. 2002. Geo-atmospheric processing of airborne imaging spectrometry data. Part 2: Atmospheric/topographic correction. *International Journal of Remote Sensing* 23: 2631–2649.
- Rippl, W. 1995. Management of water cycle and energy flow for ecosystem control: the energy-transport-reaction (ETR) model. *Ecological Modelling* 78: 61 – 76.
- Rivera, J.P., Verrelst, J., Leonenko, G. & Moreno, J. 2013. Multiple cost functions and regularization options for improved retrieval of leaf chlorophyll content and LAI through inversion of the PROSAIL model. *Remote Sensing* 5: 3280–3304.
- Rodríguez-Moreno, F., Lukas, V., Neudert, L. & Dryšlová, T. 2014. Spatial interpretation of plant parameters in winter wheat. *Precision Agriculture* 15: 447–465.
- Rouse, J.W., Haas, R.H., Schell, J.A. & Deering, D.W. 1974. Monitoring vegetation systems in the great plains with ERTS. *3rd ERTS-1 Symposium*, editors S. Fraden, E. Marcanti & M. Becker, 309–317, NASA SP-351, Washington D.C. USA.
- Sampson, P.H., Zarco-Tejada, P.J., Mohammed, G.H., Miller, J.R. & Noland, T.L. 2003. Hyperspectral remote sensing of forest condition: Estimating chlorophyll content in tolerant hardwoods. *Forest Science* 49: 381–391.
- Savitzky, A. & Golay, M.J.E. 1964. Smoothing and differentiation of data by simplified least squares procedures. *Analytical Chemistry* 36: 1627–1639.
- Schaepman, M. 2009. Imaging spectrometers. *The SAGE Handbook of Remote Sensing*, editors T.A. Warner, M. Duane Nellis & G.M. Foody, 166–178, SAGE, London (UK).
- Schaepman, M.E., Ustin, S.L., Plaza, A.J., Painter, T.H., Verrelst, J. & Liang, S. 2009. Earth system science related imaging spectroscopy - an assessment. *Remote Sensing of Environment* 113: S123–S137.
- Schaepman-Strub, G., Schaepman, M.E., Painter, T.H., Dangel, S. & Martonchik, J.V. 2006. Reflectance quantities in optical remote sensing-definitions and case studies. *Remote Sensing of Environment* 103: 27–42.
- Schläpfer, D. & Richter, R. 2002. Geo-atmospheric processing of airborne imaging spectrometry data. Part 1: Parametric orthorectification. *International Journal of Remote Sensing* 23: 2609–2630.
- Schlörl, M. & Atzberger, C. 2006. Inversion of a forest reflectance model to estimate structural canopy variables from hyperspectral remote sensing data. *Remote Sensing of Environment* 100: 281–294.
- Schlörl, M., Atzberger, C., Hill, J., Buddenbaum, H., Werner, W. & Schüller, G. 2010. Retrieval of chlorophyll and nitrogen in Norway spruce (*Picea abies* L./Karst.) using imaging spectroscopy. *International Journal of Applied Earth Observation and Geoinformation* 12: 17–26.
- Schneider, E. & Sagan, D. 2005. *Into the Cool: Energy Flow, Thermodynamics, and Life*. The University of Chicago Press, Chicago, London.
- Schrödinger, E. 1944. *What is Life?* Cambridge University Press.
- Sims, D.A. & Gamon, J.A. 2002. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment* 81: 337–354.
- Sithole, G. & Vosselman, G. 2004. Experimental comparison of filter algorithms for bare-earth extraction from airborne laser scanning point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing* 59: 85–101.
- Srivastava, A., Singh, S., Ahn, C.Y., Oh, H.M. & Asthana, R.K. 2013. Monitoring approaches for a toxic cyanobacterial bloom. *Environmental Science & Technology* 47: 8999–9013.
- Stenberg, B., Rossel, R.A.V., Mouazen, A.M. & Wetterlid, J. 2010. Chapter five – visible and near infrared spectroscopy in soil science. *Advances in Agronomy* 107: 163–215.
- Stoney, W.E. 2005. A guide to the global explosion of land-imaging satellites. markets and opportunities. *Earth Imaging Source* 2: 10–14.
- Stuckens, J., Verstraeten, W., Delalieux, S., Swennen, R. & Coppin, P. 2009. A dorsiventral leaf radiative transfer model: Development, validation and improved model inversion techniques. *Remote Sensing of Environment* 113: 2560–2573.
- Thom, A.S. 1975. *Momentum, Mass and Heat Exchange of Plant Communities: Edited by J.L. Monteith*.
- Tonolli, S., Dalponte, M., Vescovo, L., Rodeghiero, M., Bruzzone, L. & Gianelle, D. 2011. Mapping and modeling forest tree volume using forest inventory and airborne laser scanning. *European Journal of Forest Research* 130: 569–577.
- Ustin, S.L., Gitelson, A.A., Jacquemoud, S., Schaepman, M., Asner, G.P., Gamon, J.A. & Zarco-Tejada, P. 2009. Retrieval of foliar information about plant pigment systems from high resolution spectroscopy. *Remote Sensing of Environment* 113: S67–S77.
- Ustin, S.L., Roberts, D.A., Gamon, J.A., Asner, G.P.

- & Green, R.O. 2004. Using imaging spectroscopy to study ecosystem processes and properties. *Biogeoscience* 54: 523–534.
- van der Meer, F. & de Jong, S.M. 2006. *Imaging spectrometry: Basic principles and prospective applications*, Kluwer Academic Publishers, Dordrecht, The Netherlands.
- van Leeuwen, M. & Nieuwenhuis, M. 2010. Retrieval of forest structural parameters using LiDAR remote sensing. *European Journal of Forest Research* 129: 749–770.
- Vane, G., Goetz, A.F. & Wellman, J.B. 1984. Airborne imaging spectrometer: A new tool for remote sensing. *IEEE Transactions on Geoscience and Remote Sensing* GE-22: 546–549.
- Vastaranta, M., Holopainen, M., Yu, X., Hyppä, J., Mäkinen, A., Rasimäki, J., Melkas, T., Kaartinen, H. & Hyppä, H. 2011. Effects of individual tree detection error sources on forest management planning calculations. *Remote Sensing* 3: 1614–1626.
- Vauhkonen, J., Tokola, T., Maltamo, M. & Packalén, P. 2010. Applied 3d texture features in ALS-based forest inventory. *European Journal of Forest Research* 129: 803–811.
- Verhoef, W. & Bach, H. 2007. Coupled soil-leaf-canopy and atmosphere radiative transfer modeling to simulate hyperspectral multi-angular surface reflectance and TOA radiance data. *Remote Sensing of Environment* 109: 166–182.
- Verrelst, J., Alonso, L., Camps-Valls, G., Delegido, J. & Moreno, 2012a. Retrieval of vegetation biophysical parameters using gaussian process techniques. *IEEE Transactions on Geoscience and Remote Sensing* 50: 1832–1843.
- Verrelst, J., Muñoz, J., Alonso, L., Delegido, J., Rivera, J.P., Camps-Valls, G. & Moreno, J. 2012b. Machine learning regression algorithms for biophysical parameter retrieval: Opportunities for Sentinel-2 and -3. *Remote Sensing of Environment* 118: 127–139.
- Vinciková, H., Pechar, L. & Hanuš, J. 2013. *Měření a využití spektrální odrazivosti (reflektance) slunečního záření z hladiny povrchových vod*. Vindušková, O. & Frouz, J. 2013. Soil carbon accumulation after open-cast coal and oil shale mining in northern hemisphere: a quantitative review. *Environmental Earth Sciences* 69: 1685–1698.
- Vogelmann, J.E., Rock, B.N. & Moss, D.M. 1993. Red edge spectral measurements from sugar maple leaves. *International Journal of Remote Sensing* 14: 1563–1575.
- Vos, R.J., Hakvoort, J.H.M., Jordans, R.W.J. & Ibelings, B.W. 2003. Multiplatform optical monitoring of eutrophication in temporally and spatially variable lakes. *Science of The Total Environment* 312: 221–243.
- Vosselman, G. 2000. Slope based filtering of laser altimetry data. *International Archives of Photogrammetry and Remote Sensing* 33: 935–942.
- Wei, G., Shalei, S., Bo, Z., Shuo, S., Faquan, L. & Xu-ewu, C. 2012. Multi-wavelength canopy LiDAR for remote sensing of vegetation: Design and system performance. *ISPRS Journal of Photogrammetry and Remote Sensing* 69: 1–9.
- Weiss, M., Baret, F., Myneni, R.B., Pragnere, A. & Knyazikhin, Y. 2000. Investigation of a model inversion technique to estimate canopy biophysical variables from spectral and directional reflectance data. *Agronomie* 20: 3–22.
- Widlowski, J.L., Taberner, M., Pinty, B., Bruniquel-Pinel, V., Disney, M., Fernandes, R., Gastellu-Etchegorry, J.P., Gobron, N., Kuusk, A., Lavergne, T., Leblanc, S., Lewis, P.E., Martin, E., Molftus, M., North, P.R.J., Qin, W., Robustelli, M., Rochdi, N., Ruiloba, R., Soler, C., Thompson, R., Verhoef, W., Verstraete, M.M. & Xie, D. 2007. Third radiation transfer model intercomparison (RAMI) exercise: Documenting progress in canopy reflectance models. *Journal of Geophysical Research D: Atmospheres* 112.
- Wulder, M.A., White, J.C., Nelson, R.F., Næsset, E., Ørka, H.O., Coops, N.C., Hilker, T., Bater, C.W. & Gobakken, T. 2012. Lidar sampling for large-area forest characterization: A review. *Remote Sensing of Environment* 121: 196–209.
- Young, S.J., Johnson, B.R. & Hackwell, J.A. 2002. An in-scene method for atmospheric compensation of thermal hyperspectral data. *Journal of Geophysical Research: Atmospheres* 107: 4774.
- Yu, X., Hyppä, J., Holopainen, M. & Vastaranta, M. 2010. Comparison of area-based and individual tree-based methods for predicting plot-level forest attributes. *Remote Sensing* 2: 1481–1495.
- Yu, X., Litkey, P., Hyppä, J., Holopainen, M. & Vastaranta, M. 2014. Assessment of low density full-waveform airborne laser scanning for individual tree detection and tree species classification. *Forests* 5: 1011–1031.
- Zarco-Tejada, P.J., Miller, J.R., Harron, J., Hu, B., Noland, T.L., Goel, N., Mohammed, G.H. & Sampson, P. 2004. Needle chlorophyll content estimation through model inversion using hyperspectral data from boreal conifer forest canopies. *Remote Sensing of Environment* 89: 189–199.
- Zarco-Tejada, P.J., Miller, J.R., Noland, T.L., Mohammed, G.H. & Sampson, P.H. 2001. Scaling-up and model inversion methods with narrowband optical indices for chlorophyll content estimation in closed forest canopies with hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing* 39: 1491–1507.
- Zarco-Tejada, P.J., Pushnik, J.C., Dobrowski, S. & Ustin, S.L. 2003. Steady-state chlorophyll fluorescence detection from canopy derivative reflectance and double-peak red-edge effects. *Remote Sensing of Environment* 84: 283–294.
- Zhu, W., Tian, Y.Q., Yu, Q. & Becker, B.L. 2013. Using hyperion imagery to monitor the spatial and temporal distribution of colored dissolved organic matter in estuarine and coastal regions. *Remote Sensing of Environment* 134: 342–354.

