

**Univerzita Palackého v Olomouci**

**Přírodovědecká fakulta**

**Katedra geoinformatiky**

**MONITOROVÁNÍ VYBRANÝCH PŮDNÍCH  
VLASTNOSTÍ BEZKONTAKTNÍMI METODAMI**

**Magisterská práce**

**Bc. Ladislav ROZKOŠNÝ**

**Vedoucí práce: doc. RNDr. Vilém Pechanec, Ph.D.**

**Olomouc 2017**

**Geoinformatika**

## **ANOTACE**

Diplomová práce s názvem Monitorování vybraných půdních vlastností bezkontaktními metodami vznikla na Katedře geoinformatiky Univerzity Palackého v Olomouci. V práci je kladen velký důraz na teoretickou část, neboť byla stěžejní pro další zpracování.

Cílem práce bylo vybrat dostupné algoritmy a metody pro stanovení půdních vlastností bezkontaktními metodami. Následně bylo zapotřebí tyto metody aplikovat na zájmovém území k němuž byly dostupné hodnoty půdních vlastností, multispektrální a hyperspektrální data. Na závěr bylo cílem posoudit kvalitu a použitelnost stanovených algoritmů a metod.

Rešeršní část ukázala, že nejpoužívanější metodou s nejlepšími výsledky je statistická predikce pomocí metody PLSR. K tomuto modelování byl zajištěn hyperspektrální snímek zájmového území, na kterém predikce proběhla. V této práci bylo zjištěno, že se jedná o vhodnou metodu i pro naše zájmová data a zájmové území i přes horší výsledky samotné predikce. Horší predikční schopnost nebyla dosažena z důvodu špatné aplikace metody nebo její nevhodnosti, ale z důvodu horšího charakteru některých vstupních datových souborů.

Multispektrální snímky vykazovaly menší použitelnost než snímky hyperspektrální. V práci bylo zjištěno, že použitelnost těchto dat je v aplikaci spektrálních indexů, které popisují komplexní charakteristiku půdy, nikoliv však izolovaných vlastností.

Výstupem práce je přehled dostupných studií s touto tematikou, samotný snímek s predikovanými hodnoty PLSR metodou a ucelený postup pro případnou další aplikaci tohoto modelování. Během práce vznikly také dva manuály pro základní zpracování dat dálkového průzkumu země v softwarech ENVI a SNAP.

## **KLÍČOVÁ SLOVA**

půdní vlastnosti; hyperspektrální data; multispektrální data; PLSR; spektrální indexy;

Počet stran práce: 75

Počet příloh: 4 (z toho 2 vázané a 1 volná a 1 elektronická)

## **ANOTATION**

The master thesis titled Monitoring of selected soil properties contactless method was created by the Department of Geoinformatics of Palacky University in Olomouc. The work is emphasized on theoretical part because this part was crucial for next analysis.

The main goal of the paper was the selection of available algorithms and methods for estimation of soil properties using contactless methods. Afterwards, it was needed to apply these approaches on the area of interest to which values of soil properties, multispectral and hyperspectral data was available. In conclusion, the last goal was the assessment of precision and usability of selected methods.

Research part showed statistical prediction through the PLSR method as the most used and as the method with the best results. The hyperspectral image of the area of interest was ensured for this predictive modelling thereon. In this paper, the mentioned method was assessed as suitable for our datasets and the area of interest despite worse results of prediction. The worse ability of prediction wasn't achieved because of poor application of the method or impropriety but because of the worse character of some input data sets.

Multispectral images showed smaller usability than hyperspectral images. In this paper, the usability of these images was found out in spectral indices application, which describes a comprehensive characterization of the soil, but not isolated properties.

The output of this work is the review of available studies on the similar topic, the image of predicted values by PLSR method and complete procedure for next application of this approach. During the work, two manuals were created for basic processing of remote sensing data in the software SNAP and the software ENVI.

## **KEYWORDS**

soil properties; hyperspectral data; multispectral data; PLSR; spectral indices;

Number of pages: 75

Number of appendixes: 4 (2 bound, 1 unbound and 1 electronic)

## **PROHLAŠUJI, ŽE**

- diplomovou práci včetně příloh, jsem vypracoval samostatně a uvedl jsem všechny použité podklady a literaturu.

- jsem si vědom, že na moji diplomovou práci se plně vztahuje zákon č.121/2000 Sb. - autorský zákon, zejména § 35 – využití díla v rámci občanských a náboženských obřadů, v rámci školních představení a využití díla školního a § 60 – školní dílo,

- beru na vědomí, že Univerzita Palackého v Olomouci (dále UP Olomouc) má právo nevýdělečně, ke své vnitřní potřebě, diplomovou práci užívat (§ 35 odst. 3),

- souhlasím, aby jeden výtisk diplomové práce byl uložen v Knihovně UP k prezenčnímu nahlédnutí,

- souhlasím, že údaje o mé diplomové práci budou zveřejněny ve Studijním informačním systému UP,

- v případě zájmu UP Olomouc uzavřu licenční smlouvu s oprávněním užití výsledky a výstupy mé diplomové práce v rozsahu § 12 odst. 4 autorského zákona,

- použít výsledky a výstupy mé diplomové práce nebo poskytnout licenci k jejímu využití mohu jen se souhlasem UP Olomouc, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly UP Olomouc na vytvoření díla vynaloženy (až do jejich skutečné výše).

V Olomouci dne

Ladislav Rozkošný

Děkuji vedoucímu práce doc. RNDr. Vilému Pechanci, Ph.D. za cenné podněty a připomínky při tvorbě práce, za veškeré studijní materiály, které mi byly vedoucím práce poskytnuty a také za ochotu a vstřícnost, které se mi dostávalo za celou dobu naší spolupráce. Dále bych chtěl poděkovat i Ing. Heleně Kiliánové, Ph.D. a RNDr. Janě Svobodové, Ph.D. za pomoc při vypracovávání rešerše. Rád bych poděkoval také Ing. Alexandru Mrázovi, Ph.D. za zajištění některých datových sad, konzultace během PLSR modelování a také přínos při tvorbě rešeršní části.

V neposlední řadě děkuji své rodině a kamarádům, kteří mě podporovali jak při vypracovávání tohoto textu, tak i během celého studia. Na závěr bych rád poděkoval celé katedře Geoinformatiky na Univerzitě Palackého v Olomouci, jež dopomohla ke vzniku této práce.

Vevázaný originál **zadání** bakalářské/magisterské práce (s podpisem vedoucího katedry a razítkem katedry).

# OBSAH

<b>SEZNAM POUŽITÝCH ZKRATEK .....</b>	<b>8</b>
<b>ÚVOD.....</b>	<b>10</b>
<b>1 CÍLE PRÁCE.....</b>	<b>11</b>
<b>2 METODY A POSTUPY ZPRACOVÁNÍ.....</b>	<b>12</b>
2.1 Použitá data.....	12
2.2 Použité metody.....	16
2.3 Použité programy.....	19
2.4 Postup zpracování.....	21
<b>3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY.....</b>	<b>24</b>
3.1 Půdní dusík (N).....	24
3.2 Organický půdní uhlík (Cox).....	27
3.3 Aktivní půdní reakce (pH).....	32
3.4 Půdní vlhkost.....	37
<b>4 VLASTNÍ ŘEŠENÍ.....</b>	<b>45</b>
4.1 Použití multispektrálních dat.....	45
4.2 Použití hyperspektrálních dat.....	47
<b>5 VÝSLEDKY.....</b>	<b>64</b>
5.1 Výsledky analýz s multispektrálními snímky.....	64
5.2 Výsledky analýz pomocí PLSR metody.....	65
<b>6 DISKUZE.....</b>	<b>71</b>
<b>7 ZÁVĚR.....</b>	<b>74</b>
<b>POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE</b>	
<b>PŘÍLOHY</b>	

# SEZNAM POUŽITÝCH ZKRATEK

<b>Zkratka</b>	<b>Význam</b>
ANN	Artificial Neural Network
BT	Radiační Teplota
CAI	Cellulose Absorption Index
CARS	Competitive Adaptive Reweighted Sampling
CART	Classification and Regression Tree
CEC	Cation Exchange Capacity
COI	Texture and Color Index
Cox	Organický půdní uhlík
CV	Cross Validation
DPZ	Dálkový průzkum země
EM algoritmus	Expectation-Maximization algorithm
ESA	European Space Agency
FLAASH	Fast Line-of-sight Atmospheric Analysis of Hypercubes
FLIS	Flying Laboratory of Imaging Spectroscopy
FWHM	Full Width at Half Maximum
GIS	Geographic Information System
GNSS	Global Navigation Satellite System
ICT	Information and Communication Technology
IEM	Integral Equation Model
LOO	Leave One Out Cross Validation
LRM	Logistický Regresní Model
LST	Povrchová Teplota
LV	Latent Variables
LWIR	Longwave Infrared
LWR	Locally Weighted Regression
MARS	Multivariate Adaptive Regression Splines
MIR	Mid-Infrared
MKK	Objemová půdní vlhkost
N	Dusík
NBI	Normalized Brightness Index
NBMI	Normalized Backscatter Moisture Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
NIR	Near-Infrared
NLV	Number of Latent Variables
NMDI	Normalized Multiband Drought Index
OC	Organic Carbon
OLI	Operational Land Imager
OMI	Organic Matter Content Index
P	Fosfor
PCR	Principal Component Regression
pH	Aktivní půdní reakce
PLS	Partial Least Squares



PLSR	Partial Least Squares Regression
QUAC	Quick Atmospheric Correction
R <sup>2</sup>	Koeficient determinance
RMSE	Root Mean Square Error
RMSEP	Root Mean Square Error of Prediction
RPD	Ratio of Predictive Deviation
RPIQ	Ratio of Interquartile Distance
SAR	Synthetic Aperture Radar
SFI	Soil Fertility Index
SIC	Satellite Image Corporation
SMLR	Stepwise Multiple Linear Regression
SNV	Standart Normal Variate
SOC	Soil Organic Carbon
SVG	Scalable Vector Graphic
SVMDA	Support Vector Machine Discriminant Analogy
SVMR	Support Vector Machine Regression
SWIR	Shortwave Infrared
ŠLP Křtiny	Školní lesní podnik Křtiny
TCI	Temperature Condition Index
TEB	Total Exchange Bases
TIRS	Thermal Infrared Sensor
USGS	United States Geological Survey
VCI	Vegetation Condition Index
VIS	Visible Spectrum
VNIR	Visible and Near-Infrared
WSVI	Water Supplying Vegetation Index

# ÚVOD

Od doby, kdy se lidstvo natolik vyvinulo, aby bylo schopno obdělávat první půdu, se zemědělství stalo základním zdrojem obživy pro lidstvo. S tím jak rostla populace, rostla i potřeba zemědělské půdy. Naše planeta se v určitém bodě dostává do situace, kdy začíná být vhodné půdy pro zemědělství pro veškerou populaci na naší planetě nedostatek. Vědci z celého světa se snaží najít odpověď na otázku, jakým způsobem zemědělství zefektivnit. Prvním krokem revoluce v zemědělství bylo používání hnojiv, což ovšem přerostlo do takové míry, kdy je velká část půdy znehodnocena nesprávným hnojením.

Jedním ze způsobů jak zachovat kvalitu půdy a zároveň používat hnojiva pro větší výnosnost je nalézt řešení na zvýšení efektivity využívání hnojiv. Touto tematikou se zabývá precizní zemědělství, neboli centrálně plánované zemědělství. Jedná se o mezinárodní název označující zemědělství, které využívá nové technologie vyvinuté v 80. a 90. letech 20. století (Lukas et al., 2004). Cílem je snaha efektivně využívat hnojiva a jiné produkční vstupy přesně tam a v takové míře v jaké jsou potřeba pro velký výnos, ale zároveň se zachováním limitní hodnoty pro trvale udržitelný rozvoj bez poškozování půdy. Postupy tohoto nového směru zemědělství byly známy již před staletími, kdy se naši předkové snažili využívat menších výměr pozemků pro eliminaci lokálních rozdílů (Lukas et al., 2004). Díky centrálně plánovanému zemědělství v moderním pojetí jsme v dnešní době schopni určit přesné hodnoty jednotlivých půdních vlastností a na jejich základě precizně rozplánovat hnojení dokonce v rámci jedné zemědělské parcely. Pro zjištění hodnot půdních vlastností a následného plánování hnojení jsou využívány metody geografických informačních systémů (GIS), informačních a komunikačních technologií (ICT), globálních navigačních družicových systémů (GNSS) a zvláště pak metody dálkového průzkumu Země (DPZ).

V České republice je v současné době obhospodařovááno zemědělskými podniky okolo 4 300 ha zemědělské půdy, což tvoří přibližně polovinu rozlohy celé země. Většinu tvoří orná půda, na které jsou pěstovány zemědělské plodiny. Na základě statistických údajů z Registru půdy (LPIS) vyplývá, že v České republice existuje přes 40 % orné půdy o výměře větší než 20 ha (Lukas et al., 2004). V takto velkých plochách lze předpokládat prostorovou variabilitu pozemku, a tudíž je vhodné právě zde aplikovat moderní postupy precizního zemědělství pro zvýšení výnosů.

Tato práce se zabývá stanovením několika půdních vlastností na základě reflektance extrahované z hyperspektrálních snímků a referenčních půdních měření.

Magisterská práce byla řešena v rámci projektu číslo: TA04020888 s názvem „Bezkontaktní modelování a časoprostorové modelování variability vybraných diferenčních vlastností kvality půdy“, který je řešen pod Technologickou agenturou České republiky za účasti Univerzity Palackého v Olomouci, Mendelovy Univerzity v Brně a společnosti SATURN Holešov spol. s r. o.

# 1 CÍLE PRÁCE

Cílem magisterské práce bylo na základě rešerše vybrat dostupné algoritmy pro stanovení (kvalitativní a následně kvantitativní) vybrané půdní vlastnosti, prakticky je otestovat v několika opakováních a vyhodnotit nejvhodnější metodu pro monitoring dané vlastnosti v závislosti na podmínkách ČR a dostupných datových sad. Vybranými půdními vlastnostmi bylo zastoupení Cox, N a P v půdě; pH půdy a dostupnost vody. Testovanými datovými sady byla aktuální data z Landsat7/8, SPOT6, Sentinel2, Pleiady a WorldView2. Zjištěné výsledky jsou konfrontovány s literárními poznatky a s výsledky souběžně probíhajících kontaktních rozborů. Oblastí výzkumu byl ŠLP Křtiny.

Na základě provedené rešerše se část dílčích cílů pozměnila. V části zkoumaných půdních vlastností byl vypuštěn P a v části testovacích snímků byla zahrnuta hyperspektrální data, na která byl na základě rešerše kladen mnohem větší důraz.

Hlavní cíl práce byl rozdělen do několika dílčích cílů:

- a) Rešerše dostupné metodiky pro stanovení jednotlivých půdních vlastností bezkontaktními metodami.
- b) Posouzení vhodnosti jednotlivých metod na základě dostupných datových sad a charakteru území.
- c) Aplikace nepoužívanějších metod, postupů a algoritmů na vybrané území na základě rešeršní části.
- d) Posouzení přesnosti a použitelnosti metody na zájmovém území s konkrétní datovou sadou.

## 2 METODY A POSTUPY ZPRACOVÁNÍ

### 2.1 Použitá data

V této práci bylo využíváno několik skupin dat. Ta je možné rozdělit na bezkontaktní data, které zastupovali satelitní multispektrální snímky a letecké hyperspektrální; půdní vzorky z laboratorních nebo terénních šetření kontaktními metodami a nakonec bezkontaktní terénní data, která byla měřena ručním spektrometrem. Jednotlivé kategorie a konkrétní data jsou popsány v následujících kapitolách.

#### 2.1.1 Letecká a satelitní data

##### Hyperspektrální letecká

Během tohoto průzkumu bylo zjištěno, že je zapotřebí pro přesnější analýzu a stanovení hodnot půdních vlastností využít hyperspektrální snímky. Hyperspektrální dálkový průzkum Země se rovněž nazývá Obrazová spektrometrie (Ustin et al, 2004). Tato velmi dynamicky se rozvíjející oblast dálkového průzkumu Země využívá velké množství úzkých a vzájemně těsně sousedících spektrálních pásem. V porovnání s klasickými multispektrálními daty jsou zde pásma tvořena v kanálech širokých 1 až 10 nm. Díky tomuto faktu dostáváme víceméně spojitou spektrální informaci o studovaném území. Celý koncept hyperspektrálních dat je často znázorňován na hyperspektrální kostce, která je tvořena nad sebou ležícími vrstvami, z nichž každá obsahuje spektrální informaci o sledovaném povrchu v určitém intervalu vlnových délek (Homolová, 2014).

Z důvodu horší dostupnosti satelitních snímků bylo využito dat, která byly za účelem této práce nasnímány leteckými senzory od společnosti CzechGlobe – Ústav výzkumu globální změny AV ČR, v. v. i. a zpracována v jejich laboratoři FLIS (Flying laboratory of imaging spectroscopy). Laboratoř využívá fotogrammetrické letadlo Cessna 2008B Grand Caravan, na kterém má sadu tří senzorů s názvy CASI-1500, SASI-600 a TASI-600 od společnosti ITRES, Ltd. (Hanuš et al., 2014). V tabulce (Tab. 1) je možné nahlédnout na parametry jednotlivých senzorů.

Tab. 1 Parametry hyperspektrálních senzorů využívaných společností Czech Globe. (Zdroj: CzechGlobe – Ústav výzkumu globální změny AV ČR, v. v. i.)

<b>Senzor</b>	CASI-1500	SASI-600	TASI-600
<b>Spektrální oblast</b>	VNIR	SWIR	LWIR
<b>Spektrální rozsah [nm]</b>	380-1 050	950-2 450	8 000-11 500
<b>Počet prostorových pixelů</b>	1500	600	600
<b>Max. Spektrální rozlišení [nm]</b>	3.2	15	110
<b>Zorný úhel [°]</b>	40	40	40

Pořízení zájmových snímků proběhlo 8. 11. 2016. Cílem bylo získat data, která budou vyhovovat kombinaci agrotechnických termínů a stanoveným atmosferickým podmínkám. Vývoj počasí umožnil snímkování až na začátku listopadu a to mezi 9. a 10. hodinou ranní, díky čemuž se na malých neosluněných částech zájmové lokality vyskytovala námraza, která měla také vliv na výslednou kvalitu dat. Autor dat sám uvádí ve své zprávě, že tento den přecházela přes lokalitu vysoká oblačnost a z důvodu pořízení dat v pozdním termínu se v datech může vyskytovat zvýšená míra šumu (Hanus et al., 2016). Během snímkování se teplota na základě informací z nedaleké meteorologické stanice Vranov (InMeteo, s.r.o., 2017) pohybovala v rozmezí 2°-3°C. Během předchozích pěti dní se vyskytovaly přízemní mrazíky a teplota vystoupala maximálně k 10°C. Srážkové poměry byly pět předchozích dní až na výjimky stále do 1 mm.

Zájmové území bylo nasnímáno z výšky 2060 m senzory CASI a SASI a při předzpracování pořizovatele došlo ke spojení dat z obou senzorů do jednoho snímku. Výsledný počet pásem byl 148 (48 – CASI, 100 – SASI) se spektrálním rozlišením 14,2 nm (CASI) a 15 nm (SASI) a prostorovým rozlišením 1 m (CASI) a 2,5 m (SASI).

Na obdržených hyperspektrálních datech byly již provedeny radiometrické a atmosférické korekce, odstraněny absorpční pásy vody (1332-1452 nm a 1797-1977 nm) obsahující pouze šum a výsledné hodnoty pixelů je vyjádřením reflektance. Snímky již byly také georeferencované, a tudíž připraveny pro přímé zpracování.

### **Multispektrální satelitní data**

V této práci bylo využito také klasických multispektrálních satelitních senzorů. Část dat byla z komerční produkce a část byla dostupná zdarma. Konkrétně bylo tedy využito snímků ze systémů *Pleiades-1A*, *SPOT-6*, *WorldView-2*, *Sentinel 2* a *Landsat-8*. Pod textem je k dispozici přehled použitých dat a jejich základní charakteristika (Tab. 2).

Snímky ze systému *Pleiades-1A* jsou v současné době poskytovány společností *Satellite Imaging Corporation (SIC)*, ačkoliv správa spadá do gesce společnosti *AIRBUS Defence & Space*. Systém poskytuje data panchromatické o rozlišení 50 cm a multispektrální v pásmech Blue, Green, Red a Near Infrared o rozlišení 2 m (*Satellite Image Corporation, 2017a*).

*SPOT-6* je stejně jako v předchozím případě vytvořen firmou *AIRBUS Defence & Space* a poskytován společností *Satellite Image Corporation (SIC)*. Tento senzor je z použitých komerčních satelitních senzorů nejnovější, neboť jeho provoz započal 9. září 2012. Jedná se o šestý senzor z řady *SPOT*. Senzor snímá povrch ve čtyřech multispektrálních pásmech (Blue, Green, Red a Near Infrared) s rozlišením 6 m (*Satellite Image Corporation, 2017b*).

Systém *WorldView-2* spadá pod stejnou organizaci jako data *Pleiades-2* nebo *SPOT-6*, a tudíž je charakter správy podobný. Velkou výhodou tohoto senzoru oproti předchozím je až osm multispektrálních pásem (Blue, Green, Red, Near Infrared, Red Edge, Coastal, Yellow a Near Infrared 2) o ještě větším prostorovém rozlišení, které je u multispektrálních snímků 1,84 m (*Satellite Image Corporation, 2017c*).

Zástupcem otevřené nekomerční scény pod evropskou správou je systém *Sentinel-2*. Satelit řady *Sentinel* je součástí projektu *Copernicus* pod společnou správou Evropské kosmické agentury (ESA) a Evropské komise. Data ze satelitů *Sentinel* jsou poskytována

zdarma na *Scientific Data Hub* (<http://scihub.copernicus.eu>). Ke konci roku 2016 byly na oběžné dráze satelity řady 1, které sbírají radarová data a první družice z řady 2 a 3. Do roku 2006 by měly být vypuštěny všechny plánované družice z programu Copernicus. Naše data byla pořízena satelitem Sentinel-2, který svým senzorem snímá zemský povrch v 13 pásmech (Coastal Aerosol, Blue, Green, Red, Vegetation Red Edge, Vegetation Red Edge 2, Near Infrared, Vegetation Red Edge 3, Water Vapour, SWIR – Cirrus, SWIR, SWIR 2) o rozlišení 10 m, 20 m nebo 60 m (ESA, 2017a).

Druhým zástupcem otevřené nekomerční scény je systém Landsat-8. Jedná se již o osmý systém z programu Landsat probíhající od roku 1972. Provozovatelem a správcem je americká vládní agentura United States Geological Survey (USGS). Landsat-8 je v provozu od roku 2013 a poskytuje panchromatická data s prostorovým rozlišením 15 m a multispektrální data ze dvou senzorů. První senzor OLI (Operational Land Imager) snímá zemský povrch v sedmi pásmech (Coastal, Blue, Green, Red, Near Infrared, SWIR, SWIR2 a SWIR3) s rozlišením 30 m. Druhý senzor TIRS (Thermal Infrared Sensor) poskytuje data ve dvou termálních pásmech (TIR1, TIR2) s prostorovým rozlišením 100 m (Gisat s.r.o., 2017).

Tab. 2 Přehled použitých multispektrální satelitních snímků

<b>Systém</b>	<b>Datum</b>	<b>Lokalita</b>	<b>Multispektrální Pásma</b>	<b>Rozlišení</b>
Pleiades-1A	7. 2. 2015	Křtiny	B, G, R, NIR	2 m
SPOT-6	31. 10. 2015	Křtiny	B, G, R, NIR	6 m
WorldView-2	30. 10. 2014	Vysoké Pole	B, G, R, NIR, NIR2, VRE <sup>1</sup> , CA <sup>2</sup> , Y <sup>3</sup>	1,84 m
Landsat-8	30. 9. 2016	Křtiny	CA <sup>2</sup> , B, G, R, NIR, SWIR, SWIR2, SWIR3, TIR1, TIR2	30 m, 100 m
Sentinel-2	30. 9. 2016	Křtiny	B, G, R, NIR, VRE, VRE2, VRE3, CA <sup>2</sup> , WV <sup>4</sup> , Cirrus, SWIR, SWIR2	10 m, 20 m, 60 m


Pozn.: <sup>1</sup> Vegetation Red Edge, <sup>2</sup> Coastal Aerosol, <sup>3</sup> Yellow, <sup>4</sup> Water vapour

## 2.1.2 Data měřená kontaktními metodami

Měření půdních vlastností kontaktními metodami probíhalo v lokalitě Školní lesní podnik (ŠLP) Masarykův les Křtiny. Lokalita se nachází nedaleko Brna směrem na severovýchod. Důvodem volby této zájmové oblasti bylo, že se jedná o výzkumnou lokalitu Mendelovy university v Brně, konkrétně Lesnické a dřevařské fakulty, která je jedním ze spoluřešitelů projektu.

Během řešení práce došlo ke spolupráci s Ústavem geologie a pedologie, který prováděl sběr dat na dané lokalitě. Data byla měřena každý měsíc od března do listopadu v letech 2015 a 2016. Pro naše účely byla snaha využít taková data, jejichž sběr proběhl přibližně ve stejném období v jakém byly pořízeny letecké nebo satelitní snímky z důvodu použití výstupů jako referenčních hodnot.

Celkově bylo sbíráno 11 vzorků půdy na pěti transektech, což dává celkem 55 vzorků. Na některých lokalitách byla síť půdních odběrných míst ještě zhuštěna. V této práci bylo využíváno 22 naměřených hodnot z lokality (transektu) Rudice (Obr. 1). Po zahuštění zde sice docházelo k měření 64 míst, ovšem ke zbylým nebyla dostupná data se spektrální informací.



Obr. 1 Vybraná odběrná místa v lokalitě Rudice (zdroj: autor, WMS Ortofoto ČÚZK)

### 2.1.3 Bezkontaktní data z terénního průzkumu

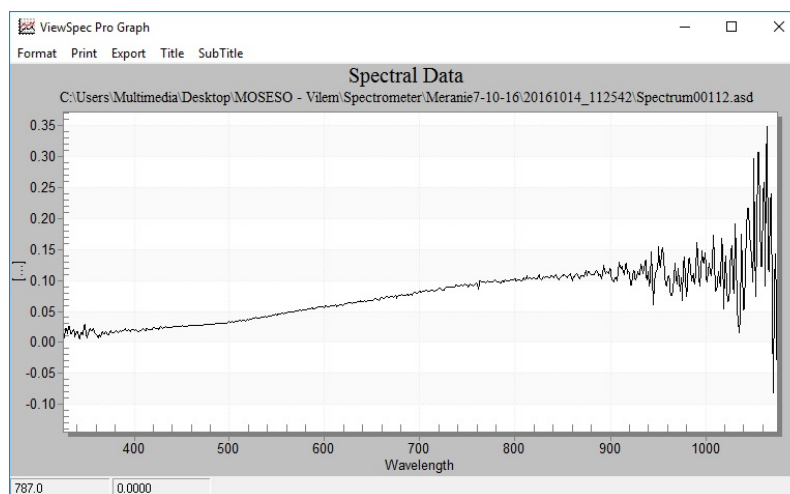
Během rešeršní části bylo zjištěno, že nejlepší výsledky pro stanovení hodnot půdních vlastností z dálkového průzkumu Země vychází při použití statistických predikčních modelů. K těmto modelům je zapotřebí využít tři sady dat. První datovou sadu, na které se provádí vlastní predikční modelování tvoří datové sady z leteckých nebo satelitních senzorů, které byly popsány dříve. Další referenční datovou sadu tvoří data měřená kontaktními metodami, která byla také popsána v předchozí kapitole. Poslední klíčovou datovou sadu tvoří právě data, jež jsou měřená ručním spektrometrem v laboratoři nebo v terénu. Tato datová sada by měla poskytovat čistou spektrální informaci o sledovaném území bez vnějších vlivů, které se mohou objevit na datech z dálkového průzkumu Země. Pomocí dat spektrální odrazivosti a referenčních dat se vytvoří statistický model pro další predikci.

Pro sběr výše popsaných dat byl využit přístroj FieldSpec HandHeld2 Spectroradiometer, který je k dispozici na Katedře geoinformatiky Univerzity Palackého v Olomouci. Přístroj měří v rozmezí 325 – 1075 nm s intervalem vzorkování 1.5 nm (ASD Inc., 2017). Během měření tímto přístrojem je zapotřebí využít bílý referenční

panel (Spectralon), který má přesně stanovenou odrazivost, a tudíž umožňuje určit iradiaci pro následné atmosférické korekce naměřených dat.

Jednotlivá odběrná místa (Obr. 1) v zájmové lokalitě ŠLP Masarykův les Křtiny byla naměřena 7. října 2016 mezi 12. a 15. hodinou. V tomto období se teplota na nedaleké meteorologické stanici Vranová pohybovala mezi 6°-8°C, přičemž došlo na začátku října k velkému teplotnímu poklesu. V tomto období se ještě nevyskytovaly ranní přízemní mrazíky a půda tedy nemohla být promrzlá. Srážkové úhrny za pět posledních dní před byly průměrně 3,5 mm, což značí, že půda byla poměrně vlhká (InMeteo, s.r.o., 2017).

Výstupem z tohoto přístroje byla surová reflektance jednotlivých odběrných míst ve formátu \*.ASD (Obr. 2), kterou je možné dále zpracovávat v interním softwaru *ViewSpecPro*. Z důvodu přechodu vysoké oblačnosti a rozdílných podmínek během měření byla reflektance půdních vzorků měřena celkem třikrát, přičemž byly vybrány ty hodnoty, u kterých byly dle terénních zápisků nejstálější podmínky.



Obr. 2 Zobrazení spektrálních dat v softwaru ViewSpecPro

## 2.2 Použité metody

### 2.2.1 PLSR

Metoda PLSR (Partial Least Squares Regression) je klíčovou metodou pro tento výzkum. Na základě rešeršní části vyšla jako nejlepší a v dnešní době je nejvíce používanou regresní metodou pro vytvoření modelu a následnou predikci hodnot půdních vlastností. Jedná se o metodu, která není ovšem používána jen v pedologii nebo dalších nejrůznějších oblastech přírodních věd, ale také i v ekonomii a marketingu. Hlavním důvodem, proč byla metoda vytvořena, je posuzování velkého množství možných korelací a predikujících proměnných. Metoda původně vznikla pro chemické účely. Velké množství vícenásobných regresních metod využívaných v chemii využívá principy právě metody PLSR (Melvik a Wahrens, 2016). Metoda stojí na algoritmu PLS (Partial Least Squares) a je také nazývána *PLS regression*, v čemž je možné vidět snahu o zachování původního názvu. PLS byla poprvé popsána švédským statistikem Hermannem Worldem (1966). Ovšem původ novodobého velkého rozmachu algoritmu PLS a celé metody PLSR se datuje k roku 2001, kdy na práci Harmanna



Worlda navázal jeho syn Svante World a popsal podrobně využití a způsob modelování tímto algoritmem (World et al., 2001).

PLSR je metoda, která často zpracovává data, mezi kterými existuje velmi silná korelace mezi predikovanými spektrálními pásmy. Tímto metoda snižuje dimenzionalitu popisovaných proměnných projektováním do nového počtu ortogonálních *latentních proměnných* (LVs - *Latent Variables*) (World et al. 2001). Metoda způsobí přenesení klíčového informačního obsahu prediktorů do několika nekorelujících uměle vytvořených proměnných s názvem LVs. Tyto proměnné nejsou vytvořeny pouze se zachováním maximálního informačního obsahu na základě spektrální informace, ale jsou také následně optimalizovány pro vypovídající hodnoty, jež lze použít při vícenásobné lineární regresi. Metoda se snaží pomocí LVs v multidimenzionálním prostoru matice  $X$  popsat multidimenzionální směr rozptylu v prostoru matice  $Y$  (Feilhauer et al., 2010). Základním modelem (1) algoritmu PLS je (Lindgren et al. 1993):

$$\begin{aligned} X &= TP^T + E \\ Y &= UQ^T + F \end{aligned} \quad (1),$$

kde  $X$  tvoří matici  $n \times m$  prediktorů a  $Y$  je matice  $n \times p$  tvořící matici odpovědí.  $T$  a  $U$  jsou matice  $n \times l$ , které tvoří projekci matice  $X$ , resp. matice  $Y$ .  $P$  ( $m \times l$ ) a  $Q$  ( $p \times l$ ) jsou ortogonální matice nakládací matice. Nakonec matice  $E$  a  $F$  jsou chybové základy, do kterých se ukládá šum a irelevantní informace, přičemž se předpokládá že vzorek je nezávislý a vykazuje distribuované náhodné proměnné. Rozklady matic  $X$  a  $Y$  jsou vytvořeny tak, aby maximalizovaly kovarianci mezi maticemi  $T$  a  $U$  (World et al., 2001). Tímto rozkladem získáváme vlastní nástroj pro odhad (výpočet)  $Y$  z  $X$  (2), ale zároveň také  $X$  z  $Y$ , protože model PLSR je symetrický a stačí pouze zaměnit formálně datové sady (TriloByte statistical software, s.r.o., 2017).

$$\hat{Y} = TBQ^T \quad (2).$$

Matice  $T$  se vypočítá z nových dat  $X$  pomocí  $T = XP^-$ . Zde  $P^-$  značí zobecněnou pseudoinverzi obdélníkové matice  $P$ . Matice se dá také spočítat z nových specifikací nebo nových parametrů. Označíme-li  $W = BQ^T$ , můžeme přepsat původní vztahy do tvaru (3)

$$\begin{aligned} X &= TP^T + E \\ Y &= TW + F \end{aligned} \quad (3),$$

kde vidíme, že data  $X$  a  $Y$  jsou k sobě spjata maticí hodnot  $T$ , která je vlastně ortogonalizovaná původní matice  $X$  s menším počtem dimenzí se zachováním maximálního množství informačního obsahu z původní matice  $X$ , odstraněným šumem a současně maximální kovariancí s daty v matici  $Y$  (TriloByte statistical software, s.r.o., 2017).

Počet latentních proměnných (NLV – Number of Latent Variables) existuje proto, aby se určil faktor pro nakládací matice  $T$ ,  $U$ ,  $P$  a  $Q$ . Většina z těchto matic konstruuje odhady lineární regrese mezi  $X$  a  $Y$  (Lindgren et al., 1993).

Modely jsou vytvářeny tak, že před analýzou je část dat algoritmu skryta. PLSR model je kalibrován fitováním modelu na zkoumaná data a validován za pomoci skryté části dat. Validace probíhá tak, že je zjišťováno, s jakou přesností je vytvořený model schopen predikovat zbytek dat se známými hodnotami. Ve většině případů se používá validace s názvem *LOO* (Leave One Out). Přesnost modelu je dána koeficientem determinace ( $R^2$ ) a střední kvadratickou chybou (RMSE) během částí kalibrace i validace. Optimální počet latentních proměnných (NLV) je zvolen experimentálně a minimalizuje koeficient determinace během kalibrace ( $R^2_{cal}$ ), aby se zabránilo přefitování modelu (může dojít k přítomnosti velkého šumu) a maximalizuje koeficient determinace během validace ( $R^2_{val}$ ) pro dosažení generického modelu (Roelofsen et al., 2015).

Metoda je v této práci využívána pro stanovení všech půdních vlastností z hyperspektrálních snímků. V principu se využívá dvou datových sad - referenční data měřená pedologickými metodami a k nim příslušné informace o spektrálním chování, které společně vytvoří prediktivní model, na jehož základě je možné z našich hyperspektrálních dat predikovat sledované hodnoty.

## 2.2.2 Vegetační a jiné indexy

Dílčím cílem bylo také otestování použitelnosti multispektrálních dat, která jsou pro běžné uživatele a experty v oboru precizní zemědělství snáze dostupnější než data hyperspektrální. To nejen z důvodu toho, že existuje velké množství satelitních senzorů s rozdílnými parametry a uživatel si tak může vybrat přesně dle jeho požadavků, ale také, protože existují i taková multispektrální data, která jsou poskytována zdarma. Přehled multispektrálních dat použitých v práci byl blíže popsán v kapitole 2.1.1. Spektrální indexy se při zkoumání půdních vlastností používají především pro odhad vlhkosti nebo komplexnějších půdních charakteristik. Hodnota ostatních půdních vlastností je silně ovlivňována právě vlhkostí. V půdě bez vegetačního pokryvu se stále vyskytuje nějaká zbytková vegetace, která obsahuje vodu. S tímto předpokladem, ale také s faktem přítomnosti vody samotné v půdě byly aplikovány některé vegetační indexy, jejichž použitelnost byla zjištěna na základě studie odborných periodik. V tabulce (Tab. 3) je možné vidět seznam spektrálních indexů, jejichž použitelnost na zájmových datech byla zkoumána v této práci. Podrobnější popis jednotlivých indexů je k dispozici v rešeršní Kapitole 3.

Tab. 3 Přehled zájmových vegetačních indexů

Index	Název indexu	Vzorec
NDVI	Normalized Difference Vegetation Index	$NDVI = \frac{NIR - RED}{NIR + RED}$
COI	Texture and Color Index	$COI = \frac{TM7_{dry}^2}{TM2_{dry}}$
OMI	Organic Matter Content Index	$OMI = \frac{1}{TM7_{dry}^2}$

<b>Index</b>	<b>Název indexu</b>	<b>Vzorec</b>
NBI	Normalized Brightness Index	$NBI = \log \left( \frac{TM7_{dry} TM2_{dry}^{-1}}{TM7_{wet}} \right)$

Pozn.: Zdroj a popis indexů zmíněn v Kapitole 3

## 2.3 Použité programy

### SNAP – Sentinel Application Platform

Jedním ze stěžejních softwarů využitých při práci s daty dálkového průzkumu Země byl software SNAP – Sentinel Application Platform. Jedná se o produkt vytvořený pod projektem COPERNICUS a je převážně určen pro zpracování dat ze senzorů řady Sentinel. Nejedná se ovšem o produkt jen s tímto účel, ale můžeme říci, že se jedná o plnohodnotný software určený pro práci s daty DPZ. Byl vytvořen společností Brockmann Consult, Array System Computing and C-S. Od svého počátku produkt prodělal množství změn, stejně jako i několik změn názvu. Ke konci roku 2016 je k dispozici nejnovější verze 4.0 (ESA, 2017b). Velkou výhodou tohoto produktu je fakt, že je distribuován pod licencí GPU General Public Licence, což znamená, že je poskytován zdarma.

System se skládá z pěti nástrojových balíčků Sentinel-1, Sentinel-2, Sentinel-3, SMOS a PROBA-V. Jednotlivé balíčky lze stáhnout zdarma z webových stránek společnosti ESA nebo i všechny dohromady jako součást jednoho softwaru. Jejich verze se liší s verzí programu SNAP, protože jsou vyvíjeny samostatně. Balíčky i celý software je k dispozici jak pro platformy Windows (64-bit, 32-bit), tak i pro platformy Mac OS X nebo UNIX (64-bit) (ESA, 2017b).

Problémem tohoto produktu je fakt, že je stále v intenzivním vývoji a v množství procesů nefunguje tak, jako by se od tohoto produktu očekávalo. Další problém představuje využití objektově orientovaného jazyku JAVA pro tvorbu softwaru, který je v dnešní době jinými jazyky překonáván, jelikož se vyskytují problémy s kompatibilitou aplikací v různých prostředích. Během práce vznikl také pro potřeby projektu manuál pro práci s tímto softwarem. Manuál je k nahlédnutí v příloze (Příloha 1).

### ENVI

Druhým zástupcem softwaru pro zpracování dat z dálkového průzkumu Země je program ENVI. Produkt americké společnosti Exelis Visual Information Solution (Exelis VIS), která koupila společnost Harris, jež stojí za tvorbou. V současné době dceřiná společnost Harris poskytuje rozsáhlou dokumentaci pro práci s tímto softwarem, ale i informace pro vývojáře a další specialisty z oboru. Software je dnes velmi silným nástrojem pro předzpracování, zobrazování, analýzu a sdílení dat z oblasti DPZ (ARCDATA PRAHA, s.ro., 2017).

Výhodou programu je, že obsahuje a podporuje práci s většinou současných družicových systémů, ale je schopen pracovat s vektorovými daty nebo i databází. V dnešní době je tento komerční produkt šířen pod správou společnosti ESRI, která je odpovědná za známější produkt ArcGIS.

V této práci byl software ENVI ve verzi 4.7 využit jen velmi okrajově a to převážně v situacích, kdy předchozí software SNAP byl nedostatečný, kdy analýzy nepracovaly dle

předpokladů nebo ve chvíli, kdy funkcionalita SNAPu byla nedostatečná pro zájmové analýzy. Stejně jako u předchozího programu na zpracování dat dálkového průzkumu Země vznikl i zde manuál, který je k dispozici v příloze (Příloha 2).

## **RStudio**

Software RStudio je jedním z klíčových produktů pro tuto práci a to zvláště při zpracování dat z ručního spektrometru a obecně při tvorbě predikčního modelu metodou PLSR. Jedná se o jedno z mnoha dostupných GUI (Graphical User Interface) pro práci s programovacím jazykem R. Výhodou práce v GUI není pouze lepší uživatelská přívětivost, ale také možnosti grafického zobrazení výsledných grafů a map.

RStudio je možné používat jako desktopovou aplikaci, ale také jako serverovou aplikaci. Z hlediska licence a distribuce softwaru je k dispozici placená i zdarma verze. Placená verze má výhodu uživatelské podpory. Verze šířená zdarma je šířena stejně jako v případě SNAP pod licencí GPL General Public Licence. Zdrojový kód celého GUI je volně k dispozici na portálu GitHub.com. Pro uživatele je k dispozici ke konci roku 2016 verze pro platformu Windows, Mac OS X (64-bit) a dvě verze pro Linuxové platformy Ubuntu/Debian (32-bit, 64-bit) a Fedora/RedHat/openSUSE (32-bit, 64-bit) (RStudio, 2017).

Nejen práce v softwaru RStudio, ale i obecně v programovacím jazyce R je velmi silná, protože již existuje velké množství uživatelsky vytvořených doplňujících balíčků pro konkrétní aplikace. V neposlední řadě je pro práci v R k dispozici rozsáhlá uživatelská základna, kde se dají diskutovat konkrétní problémové situace, které často vznikají například skutečností, že potřebné uživatelské balíčky byly napsány pro starší verzi jazyka R.

V této studii byla využita verze 1.0.136 (nejnovější ke konci roku 2016), která požaduje verzi programovacího jazyka R 2.11.1 nebo vyšší. Použitá verze jazyka byla 3.3.2. V práci bylo využito množství několik balíčků (pls, prospectr, raster, readxl) rozšiřujících funkcionalitu. Využití těchto balíčků je blíže přiblíženo v kapitole 4.2.

## **QGIS**

Jediný zástupce Geografických Informačních Systémů (GIS) byl v naší práci software QGIS. Jedná se o velmi silný program, který patří mezi nejvýznamnější na poli Open Source v oblasti GIS. Software je vyvíjen od roku 2002 skupinou dobrovolníků. Od roku 2008 je produkt zařazen mezi projekty Open Source Geospatial Foundation, nevládní neziskové organizace, která je inspirována v mnoha ohledech nadací Apache Foundation, zaštiťující například velmi známý projekt The Apache HTTP Server Project. V dnešní době se software používá jako plnohodnotný ekvivalent ke komerčním robustním desktop systémům jako například ArcGIS od firmy ESRI. Díky této organizaci je produkt šířen pod licencí Creative Commons (CC BY-SA) (Open Source Geospatial Consortium, 2017).

Velkou výhodou produktu je možnost implementování nebo vytváření vlastních balíčků v programovacích jazycích C++ nebo Python. QGIS poskytuje veškeré nejenom základní nástroje pro práci s vektorovými a rastrovými daty, zpracování GNSS dat, tvorbu mapových výstupů nebo například připojení databáze. Do QGIS je možné zpřístupnit funkce dalšího open source produktu GRASS GIS, čímž získáváme ještě větší funkcionalitu a QGIS tedy může sloužit i jako nadstavba tohoto softwaru. Program

je dostupný pro platformu Windows (32-bit, 64-bit), Mac OS X, velké množství distribucí Linuxu, BSD nebo i Android (Open Source Geospatial Consortium, 2017).

Ke konci roku 2016 byly k dispozici zatím poslední verze 2.18 s názvem Las Palmas, která také byla využita pro naši práci. V tomto výzkumu byl software použit pro zpracování vektorových dat z terénních bodových měření, částečné zpracování i rastrových snímků a tvorbu mapových výstupů.

### **Inkscape**

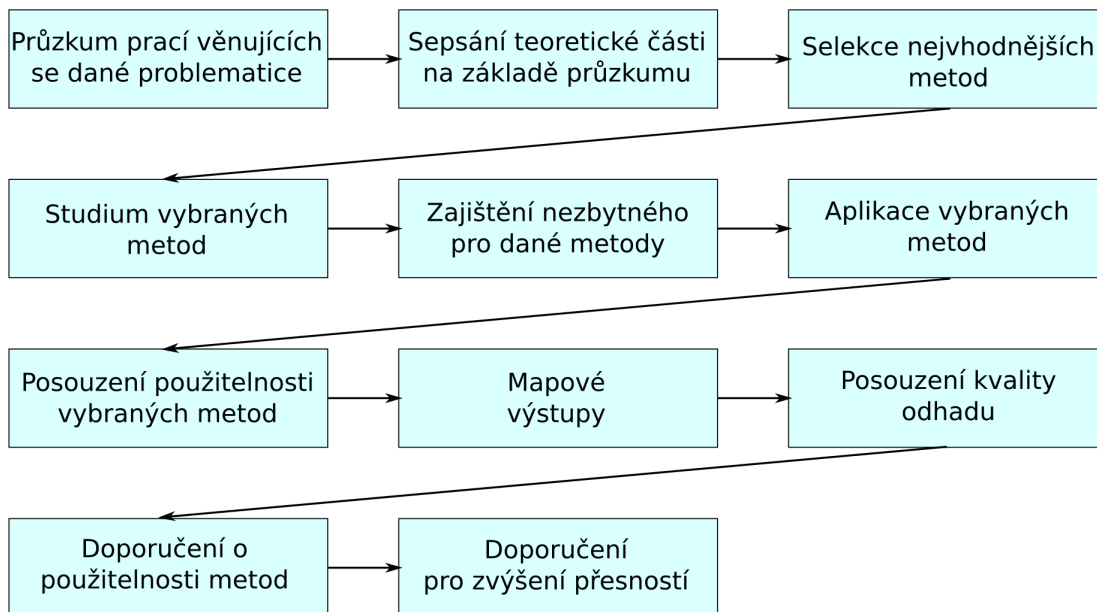
Poslední ze skupiny významných softwarů v této práci je program Inkscape. Tento software patří do rodiny grafických open source programů, u kterého by se dalo říct, že v určitých ohledech patří mezi plnohodnotné ekvivalenty k známějším Adobe Illustrator (Adobe) nebo CorelDRAW (Corel Corporation). Na základě tohoto výčtu je patrné, že se jedná o software pracující s vektorovou grafikou.

Vývoj Inkspace započal v roce 2003 a jeho intenzivní rozvoj stále probíhá. Program podporuje platformy Windows, Mac OS X a GNU/Linux. Jeho nativním formátem je otevřený standard SVG (Scalable Vector Graphics) definován konsorciem W3C. Inkscape je členem americké neziskové organizace Software Freedom Conservacy a distribuován pod licenci GPL General Public Licence. Okolo softwaru existuje rozsáhlá komunita tvořící silnou podporu pro uživatele. Ke 4. lednu 2017 byla vydána prozatím nejnovější stabilní verze s označení 0.92, která začala podporovat také SVG2 a CSS3 (Inkscape.org, 2017).

V práci byl tento produkt využíván spíše okrajově a to převážně pro finální prezentaci grafických výstupů jako jsou grafy, diagramy a mapy.

## **2.4 Postup zpracování**

Na obrázku (Obr. 3) je možné vidět rozplánovaný postup zpracování. Jednotlivé kroky zde jsou rozepsány odděleně, ačkoliv se v praxi stávalo, že se kroky prolínaly. Níže jsou jednotlivé kroky stručně popsány. Podrobnější popis je předmětem celé práce.



### **I. Průzkum prací věnujících se dané problematice**

Část průzkumu byla jedna z těch náročnějších a nejrozsáhlejších částí, jelikož na začátku samotné práce bylo potřeba prostudovat studie, které se věnují dané problematice. Tato část znamenala studium velkého množství zahraničních publikací a článků, což dokládá i velké množství citací v kapitole Použitá literatura a informační zdroje.

### **II. Sepsání teoretické části na základě průzkumu**

Po rozsáhlém průzkumu bylo zapotřebí veškeré informace sepsat do přehledného textu s rozdělením na jednotlivé kapitoly dle zkoumaných půdních vlastností za účelem tvorby této práce.

### **III. Selekcce nejvhodnějších metod**

Část selekce probíhala víceméně zároveň s předchozí sekcí, neboť už během samotného psaní přehledu o nejdůležitějším z dostupných zdrojů vycházely na povrch nejpoužívanější metody a také jejich přesnosti v porovnání s jinými. Z této části vyšel jednoduchý přehled používaných a důležitých metod, které jsou zmíněny v kapitole Současný stav dané problematiky.

### **IV. Studium vybraných metod**

Po selekci metod bylo zjištěno, že některé metody nejsou všeobecně známé, a tudíž nejsou ani předmětem studia geoinformatiky na Katedře geoinformatiky Univerzity Palackého v Olomouci. Tyto méně známé metody bylo potřeba důkladně prostudovat a hlavně zjistit, co je zapotřebí zajistit (data, informace, software) pro aplikaci těchto metod.

## **V. Zajištění nezbytného pro dané metody**

Poté, co došlo k určení klíčových metod a jejich důslednému prostudování, bylo zjištěno jaká nová data jsou zapotřebí. Kromě klasických multispektrálních snímků pro aplikaci indexů bylo zapotřebí zajistit také hyperspektrální snímky a spektrální chování odběrných míst zjištěné pomocí ručního spektrometru přímo v terénu.

## **VI. Aplikace vybraných metod**

Následně práce došla do fáze, kdy zájmové metody byly nastudovány, byly zajištěny potřebné datové sady a další informace. Zde nastal proces samotné aplikace vybraných metod. Došlo k aplikaci indexů na multispektrálních datech při zkoumání půdních vlastností a také aplikace statistické metody PLSR (Partial Least Square Regression) na hyperspektrální datovou sadu.

## **VII. Posouzení použitelnosti**

Použitelnost jednotlivých indexů byla zkoumána při aplikaci na našich zájmových snímcích. Predikční model byl zkoumán z hlediska náročnosti aplikace a celého postupu budování modelu.

## **VIII. Mapové výstupy**

Po predikci půdních vlastností statistickými metodami z hyperspektrálních snímků byly také vytvořeny mapové výstupy pro rozložení sledovaných půdních vlastností.

## **IX. Posouzení kvality predikce**

Tímto krokem započala závěrečná fáze výzkumu. V části posouzení kvality predikce došlo k určení s jakou přesností došlo ke stanovení hodnot půdních vlastností pomocí zvolených bezkontaktních metod. Ke stanovení kvality došlo pomocí několika statistických metod, které byly používány ve studovaných pracích z prvního klíčového bodu našeho výzkumu. Posouzení kvality predikce bylo také provedeno vizuálně pomocí mapových výstupů.

## **X. Doporučení o použitelnosti**

Na závěr byla podána některá doporučení o vhodnosti zvolených metod pro agronomické analýzy v podobných podmínkách. Byly také popsány důvody jednotlivých nastavení v konkrétním případě a zvolené metody.

## **XI. Doporučení pro zvýšení přesnosti**

Poslední část výzkumu byla řešena víceméně souběžně s předchozí částí. Společně tady s doporučením o použitelnosti bylo zapotřebí objektivně ohodnotit naše výstupy a zvážit možnosti zvýšení přesnosti predikce.

## **3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY**

V této práci jsou zkoumány čtyři půdní vlastnosti: půdní dusík, organický půdní uhlík, aktivní půdní reakce a půdní vlhkost. Tyto charakteristiky a jejich kvantitativní hodnocení byly zkoumány izolovaně, ačkoliv se navzájem více či méně ovlivňují. V rešeršní části textu níže jsou tedy tyto půdní vlastnosti rozděleny do jednotlivých kapitol.

### **3.1 Půdní dusík (N)**

#### **3.1.1 Význam v půdě**

Dusík je jedním ze základních minerálů, které potřebují rostliny pro svou existenci. Veškeré minerály mohou být rozděleny na makroelementy (N, K, Ca, Mg, P, S), které jsou nezbytné pro život rostlin a mikroelementy (Cl, B, Fe, Mn, Zn, Cu, Mo), kterých mají rostliny stopové množství, ale jsou pro ně také více či méně důležité. Každá rostlina má specifické potřeby na formu a poměr jednotlivých minerálů. Tyto látky jsou tedy přijímány selektivně rostlinnými buňkami ve formě iontů rozpuštěných ve vodě. V případě dusíku je to nejčastěji ve formě  $\text{NO}_3^-$  a  $\text{NH}_4^+$  (Šarapatka a kol., 2010).

Dusík zaujímá čtvrté místo v důležitosti prvků u rostlin hned po uhlíku, kyslíku a vodíku. Tento prvek je nejdůležitější pro stavbu a tvorbu protoplazmy, enzymů a různých heterocyklických sloučenin. Významnou roli hraje také při tvorbě biomasy. Při jeho nedostatku může docházet k omezení růstu, žloutnutí až usychání listů a obecně předčasnému stárnutí rostlin.

Důležitou roli v půdě hraje jeho spojení s fosforem (P). Tyto dva prvky se vzájemně ovlivňují a u velkého množství rostlin se uvádí poměr koncentrace N:P. Na přítomnost těchto dvou prvků reagují téměř všechny rostliny. Znalost poměru a vazby mezi těmito prvky je velmi důležitá, protože například zvýšení koncentrace jednoho prvku může mít za následek vzrůst dostupnosti prvku druhého.

Průměrná hodnota výskytu dusíku v půdě je 2 g/kg sušiny. Problémem je, že většina dusíku v půdě je stále v organické půdě, kterou rostliny přijímat nemohou. Tento dusík musí projít mineralizací, následně nitrifikací, kdy nakonec dojde ke vzniku nitrátů, které už rostliny mohou zpracovat. Velké množství dusíku se do půdy dostává také atmosférickými srážkami (Šarapatka a kol., 2010 a Šarapatka, 2014). Popsat celý dusíkatý cyklus v půdě je velmi složitá záležitost. Existuje množství modelů, které se pokouší o kombinaci s atmosférickými daty, výsledky však nejsou nikdy stoprocentní (Wang et al., 2010).

Stanovení dusíku v půdě je taktéž komplikované a zahrnuje množství procesů. Ideálně je potřeba zahrnout veškerý dusíkatý cyklus, který napoví vývoj dusíku. Ovšem tyto modely budou vždy zatíženy určitou chybou. Pedologové se zabývají stanovením dusíku především z důvodu lepšího hospodaření s dusíkatými hnojivy. V obecném zájmu je zajistit vysoké výnosy s minimální degradací půdy (Li et al., 2015).

#### **3.1.2 Stanovení půdního dusíku bezkontaktními metodami**

K stanovování půdních vlastností nejčastěji dochází v laboratoři. Klasické laboratorní metody jsou bohužel často časově náročné, drahé a destruktivní. Prosto se stále hledají nové metody, které by tyto negativní vlastnosti eliminovaly (Chang et al.,



2001). Mezi takové nové metody patří laboratorní spektroskopie. Nejpoužívanější přístroje pro měření spektra odrazivosti jednotlivých objektů jsou ASD FieldSpec 3, Perstom NIR System 6500 a FOSS XSD Rapid Content Analyzer spectrometer (Shi et al., 2013; Chang et al., 2016; Li et al., 2015 a Vagen et al., 2006). Tyto přístroje měří většinou s rozlišením 1 – 2 nm ve vlnových délkách od 300 do 2500 nm. Pro měření ve střední infračervené části spektra (MIR) je využíván například přístroj Bruker-TENSOR 27 Fourier transform infrared spectrometer (Vohland et al., 2014).

Další možností je využití dálkového průzkumu Země. Tato cesta je asi nejméně nákladná a nejšetnější k půdě. Letecké a satelitní multispektrální a hyperspektrální snímky jsou schopny zmapovat relativně velkou plochu za krátký časový úsek. Při stanovování půdních vlastností tímto způsobem je ale potřeba eliminovat vliv atmosféry, aby bylo dosaženo čisté reflektance (Gomez et al., 2008). Pro zjišťování dusíku touto cestou bylo v minulosti například využito leteckého snímkování hyperspektrální kamerou (Hively et al., 2011). Ze satelitních systémů je velmi používaný hyperspektrální systém Hyperion (Lu et al., 2013; Baojuan, 2008) nebo multispektrální systémy Landsat 5 a 7 (Wang et al., 2010; Vagen et al., 2006; Rivero et al., 2009).

## **Metody**

Použití spektroskopie v pedologii je zkoumáno již od 80. let minulého století, kdy Dalal a Henry (1986) poprvé použili metodu SMLR (Stepwise multiple linear regression). V dalších letech byly postupně testovány a porovnávány další metody jako PCR (Principal component regression) (Chang et al., 2001) nebo například ANN (Artificial neural network) (Zheng et al., 2008). V současné době je ale za nepoužívanější a většinou nejlepší metodu považována PLSR (Partial least squares regression) (Shi et al., 2013; Li et al., 2015; Viscarra Rossel et al., 2016; Vohland et al., 2016).

Shi et al. (2013) ve své práci porovnávali metody SMLR (Stepwise multiple linear regression), SVMR (Support vector machine regression) a PLSR (Partial Least squares regression). I v této práci vyšly nejlépe výsledky korelace stanovených hodnot s kontaktním měřením pomocí metody PLSR. Na druhou stranu například Li et al. (2015) porovnávali metody LWR (Locally weighted regression), PLSR a SVMDA (Support vector machine discriminant analogy) přičemž nejlepší výsledky vykazovala metoda LWR. Vohland et al. (2014) metodu PLSR ještě zpřesňovali pomocí strategie CARS (Competitive adaptive reweighted sampling). Při kombinaci těchto metod byly excelentní výsledky pro OC (organický uhlík), N (dusík) a pH. Pomocí metody CARS byly na základně využití regresních křivek určeny nejvýznamnější vlnové délky.

## **Předzpracování**

Velká většina autorů na svá data změřená pomocí laboratorní spektroskopie aplikovala Savitzky-Golay smoothing. Díky této metodě byl odstraněn z dat náhodný šum (Stevens et al., 2010; Shi et al., 2013; Li et al., 2015; Viscarra Rossel et al., 2016). Dalším krokem bylo převedení dat na SNV (Standard normal variate) a odstranění outlierů. Nakonec v rámci přezpracování dat je využívána 1. derivace. Někteří autoři zkoušeli aplikovat na data i 2. derivaci. Z důvodu velkého šumu je však 1. derivace považována za vhodnější (Vagen et al., 2006; Shi et al., 2013; Li et al., 2015; Chang et al., 2016).

Při měření pomocí dálkového průzkumu země je nejdůležitější provést radiometrické a atmosférické korekce. V případě družicových systémů jsou na velké většině snímků radiometrické korekce již provedeny (Baojuan, 2008). Atmosférické korekce jsou velmi důležité pro veškeré environmentální aplikace. Záření dopadající na senzor je radiance se všemi atmosférickými vlivy a pro přesné stanovení hodnot, které vyzařují objekty na zemském povrchu je potřeba tuto radianci převést na reflektanci (Musilová, 2008). K tomuto převodu je k dispozici velké množství modelů. Například v softwaru ENVI pro zpracování DPZ dat jsou dostupné modely FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes) a QUAC (QUick Atmospheric Correction). Některé snímky je možné získat už s provedenými atmosférickými korekcemi. Skutečnost, že byly atmosférické korekce již provedeny, by měla být zaznamenána v metadatech.

## **Závěry a hodnocení**

Vlnové délky vhodné pro zkoumání půdního dusíku se mezi jednotlivými pracemi poměrně liší. Dalal a Henry (1986) jako vhodné vlnové délky určili rozsah 1100 až 2500 nm (konkrétněji 1702, 1870 a 2052 nm). Sterberg et al. (2010) naproti tomu jako vhodné vlnové délky považovali 1100, 1600, 1700, 1800, 2000 a 2200 nm. Shi et al. (2013) své výsledky porovnávali s předchozími výstupy, které do své práce zakomponovali a výstupem byla série pásem 1450, 1850, 2250, 2330 a 2400 nm. V této práci je poukazováno na to, že určení vhodných vlnových délek závisí především na celkovém zpracování a použité metodě. Poslední uvedená pásma jsou brána jako vhodná především pro N (ovšem dají se použít i pro jiné půdní vlastnosti) a pro nepoužívanější metodu PLSR. Obecně lze říci, že nepoužívanější a nejvhodnější jsou pásy vodní absorpce od 1300 do 3000 nm (Shi et al., 2013; Vohland et al., 2014). Oblast je spojována s vodním obsahem, který mění celkový obsah C v půdě (Rossel, 2010). Tato skutečnost naznačuje, že obsah N v půdě se může nepřímo vztahovat prostřednictvím vlnových délek k C (Morra, 1991). Chang et al. (2016) ve své práci také poukazuje na vysokou korelaci mezi množstvím těchto prvků v půdě.

Několik studií se dále zabývalo porovnáváním VIS-NIR a MIR části spektra. Ve většině těchto studií vyšlo lépe MIR (Reeves III et al., 2006; Bellon-Maurel et al., 2011; Vohland et al., 2014). Pro práci v MIR byla většinou také využívána metoda PLSR nebo nějaká její variace (např. CARS-PLSR). Vlnové délky vhodné pro měření N v MIR byly stanoveny okolo 1676 až 1672, 1260 a 1036  $\text{cm}^{-1}$ . Tyto vlnové délky jsou spojovány s pásmy zvýrazňující látky, které obsahují skupiny C-O v různých vazbách (Vohland et al., 2014).

Podle Wang et al. (2010) patří mezi základní faktory ovlivňující dusík v půdě organický uhlík,  $\text{NH}_4^+$ ,  $\text{NO}_2^-$ ,  $\text{NO}_3^-$ , teplota půdy, vlhkost a pH. Tyto faktory se nepřímo objevují i v některých dalších pracích. Například Shi et al. (2013) uvádí, že stanovování dusíku je vhodné u vysušených vzorků. Wang et al. (2010) ve své práci dále vytvořili pro hodnocení půdního dusíku model, do kterého vstupovala data Landsat 5 (vypočítali NDVI, LAI, čistou reflektanci a zbytkovou radianci), meteorologická data (teplota, vlhkost, rychlost větru atd.), data z modelu SWAT (zkoumá jednotlivé dusíkaté procesy jako nitrifikaci a volatilizaci) a nakonec data ze samostatného modelu zkoumající denitrifikaci. Na základě tohoto modelu bylo zjištěno, že asi nejcitlivější faktor pro ztrátu půdního dusíku je obsah půdní vody. Analýza citlivosti ukázala, že při změně obsahu půdní vody o 20 % dojde ke 100% změně výsledků.

Bylo vyzkoumáno, že hodnota půdní vlastnosti je lineární funkce její reflektance (Chang et al., 2016). Konkrétně u dusíku vyšlo, že čím vyšší reflektance, tím nižší koncentrace N v půdě. Tato skutečnost byla podpořena spektrální knihovnou CSSL (Chinese soil spectral library) (Li et al., 2015).

Zajímavou práci představili Vagen et al. (2006), kteří se pokusili vytvořit Soil Fertility Index (SFI). Stanovení celkové kvality půdy je komplikovaná záležitost a autoři se přou o tom, které faktory by měly do hodnocení kvality půdy vstupovat. Mezi základní faktory, na kterých se téměř všichni shodují, patří textura, vodní kapacita, pH, N, P, K, C apod. Stanovení půdních vlastností proběhlo na základě ruční spektrofotometrie. Při tvorbě SFI bylo u každé půdní vlastnosti určováno, zda je dobrá, průměrná nebo nevyhovující na základně EM (expectation-maximization) algoritmu. Pro následnou identifikaci vlnových délek, které stanovují půdní kvalitu, byly použity rozhodovací stromy (CART). Na jednotlivé vzorky byl následně aplikován proporcional-odds model (logistický regresní model = LRM), který pak vstupoval do výpočtu. Nakonec byl vytvořen matematický vztah (4), do kterého vstupovala pravděpodobnost  $P(Y_i=1)$ , že půdní vzorek  $i$  bude stanoven jako dobrý,  $\alpha$  je *intercept*,  $\beta_i$  je vlnová délka určená na základě regresních koeficientů a  $X_{ik}$  jsou log-odds poměry.

$$SFI = \ln\left(\frac{P(Y_i=1)}{1-P(Y_i=1)}\right) = \alpha + \sum_{k=1}^K \beta_k X_{ik} \quad (4).$$

Model byl testován na datech z Landsat 7 a poskytl velmi dobré výsledky pro pH, organický uhlík a N. Jako významná pásma z Landsatu 7 byla určena band 1 (450-520 nm), band 5 (1550-1750 nm) a band 7 (2090-2350 nm).

Pro posuzování přesnosti jsou modelovaná data konfrontována s kontaktním měřením. Ze statistických veličin se pro chybovost nejčastěji používá Koeficient determinace ( $R^2$ ) a RMSE (Vagen et al., 2006; Wang et al., 2010; Shi et al., 2013; Chang et al., 2016). Hojně využívané je také RPD (ratio of predictive deviation) – podíl predikční odchylky, jehož hodnoty jsou ve většině případů posuzovány na základě doporučení Saeys et al. (2005).

## 3.2 Organický půdní uhlík (Cox)

### 3.2.1 Význam organického půdního uhlíku v půdě

Půda se skládá z organické a anorganické složky. Organickou složku lze dle Šarapatky (2014) dále dělit na:

- a) živé organismy (půdní edafon),
- b) primární organickou složku,
- c) meziprodukty humifikačních procesů,
- d) humus.

Jednotlivé složky se mohou ještě podrobněji dělit do dalších složek. Sledovaný organický uhlík je obsažen víceméně ve všech složkách půdy. Při stanovování množství organického uhlíku v půdě vlastně zjišťujeme množství spalitelné organické hmoty.

To se zjišťuje buď *spalováním za sucha*, nebo *spalováním za mokra*. Obě tyto metody jsou založeny na principu oxidace uhlíku půdních látek. Množství čistého uhlíku se z tohoto určuje pomocí nepřímých metod, užívajících se k výpočtu množství humusu (Šarapatka, 2014).

Z pohledu uhlíku jako prvku je nutné poznamenat, že se jedná o základní stavební kámen všech organických látek a je tak nejvýznamnějším biogenním prvkem. Obrovské množství tohoto uhlíku je obsaženo právě v půdě, kde se vyskytuje v organické formě a je často nazýván jako organická hmota. Samotná organická hmota tvoří jen malý podíl půdy (asi 5 %), ale na druhou stranu velmi významně ovlivňuje množství fyzikálních a chemických pochodů v půdě. Množství organické půdní hmoty závisí na vstupu organických látek a produktů dekompozice. Tyto vstupy jsou převážně ovlivněny klimatickými podmínkami a vegetací. Příkladem těchto vstupů mohou být zbytky rostlin, kořeny, spady a splachy různých živin a také vlastní půdní organismy (Urbánková, 2015).

Z předchozího odstavce vyplývá, že vstupy a výstupy organických látek v půdě jsou převážně díky sezonním vlivům velmi obtížně kvantifikovatelné. Ovšem veškeré tyto procesy mají obrovský význam pro řadu dalších půdních vlastností. Mezi nejovlivnitelnější můžeme řadit půdní vlhkost, provzdušnění, teplotu, celkový fyzikální a chemický režim, vodní režim a obecně její úrodnost (Dvořáková 2015), což je hlavní důvod proč je tato půdní charakteristika sledována i v naší práci. Zajímavým faktem je, že například půdy s vysokým obsahem organické hmoty mají vyšší retenční schopnost, což může být v sušších oblastech velmi důležité pro vegetaci (Šimek, 2003).

Velkým problémem pro organickou hmotu je samotné obhospodařování půdy. Při této činnosti dochází k velkým ztrátám organické hmoty, což je v pedologii nazýváno jako *dehumifikace*. Obhospodařováním jsou myšleny technické činnosti jako orba nebo procesy spojené se zintenzivněním zemědělské produkce jako je například využití chemických hnojiv. Dehumifikaci ale způsobují i některé přírodní pochody, například vodní a větrná eroze (Urbánková, 2015).

### **3.2.2 Stanovení organického půdního uhlíku bezkontaktními metodami**

Bezkontaktními metodami je myšleno v obecném měřítku využití reflektance půdy, tedy její odrazivosti v určité oblasti elektromagnetického spektra. Nemusí se ovšem jednat o jednoduchou záležitost, protože celková radiace dopadající na půdu je ve většině případů deformována na základě složek v půdě obsažených. Může dojít k vibracím jednotlivých molekul a v důsledku toho k ohýbání nebo roztahování a tím tedy i procesům jako absorpce, lom a pohlcování dopadající energie. Na základě znalostí základní fyziky víme, že energie je přímo úměrná frekvenci a nepřímo úměrná vlnové délce. To pro nás znamená, že jsme schopni určit charakteristické spektrální chování (v tomto případě půdy), které jsme po numerickém vyjádření schopni použít pro analytické účely. Nejedná se ovšem jen o záležitost organického půdního uhlíku, ale veškeré existující látky v závislosti na zkoumaném měřítku (Blum, 2006). Frekvence, které jsou odraženy od zkoumané látky, nazýváme *reflektancí (R)*, která je ve velké většině případů transformována na *absorbanci (A)*. Absorbanci vypočítáme dle příslušného vzorce (5).

$$A = \log(1/R) \quad (5).$$

Absorbance se využívá ve většině statistických regresních metod, které se využívají i například pro stanovení půdního organického uhlíku. Problémem je, že stanovení reflektance izolované půdní vlastnosti je zatíženo chybou, protože chod energie je ovlivněn i jinými látkami, teplotou, vlhkostí apod. (Stenberg et al., 2010).

Častým problémem při identifikování určité vlastnosti jsou absorpční pásy. V našem případě však mohou být tyto oblasti užitečné, neboť obsahují důležité informace o obsahu organických i anorganických látek, které tuto absorpci mohou způsobovat. Například ve VIS (400-780 nm) jsou absorpce spojeny s výskytem minerálů, obsahujících například železo (Mortimore et al., 2004). Organická půdní hmota má také některé absorpční pásy ve VIS, ale mnohem významnější je pro ni pásmo NIR (780-2500 nm). Absorpční pásy zde jsou spojeny a identifikují převážně hodnoty skupin OH, SO<sub>4</sub>, H<sub>2</sub>O, CO<sub>3</sub> a CO<sub>2</sub> (Clark, 1999). Na základě obsahu těchto skupin v jednotlivých půdních typech jsme schopni určit například množství humusu v půdě (Viscarra Rossel, et al., 2006). Někteří autoři uvádějí, že nejdominantnější absorpční pásy pro zkoumání půdy mohou být nalezeny ve vlnových délkách 1400-1900 nm (Liu et al., 2002). Pro náš konkrétní případ při studiu SOC (soil organic carbon) a celkový N vyšly jako klíčové pásy okolo vlnových délek 1100, 1600, 1700 až 1800, 2000 a 2200 až 2400 nm (Ben-Dor a Banin, 1995; Dalal a Henry, 1986; Henderson et al., 1992; Krishnan et al., 1980; Malley et al., 2000; Martin et al., 2002; Morra et al. 1991; Stenberg, 2010). Na druhou stranu v některých pracích se výsledky poměrně lišily. Některé z nich byly potvrzeny, některým autorům zase vyšly výrazně odlišné hodnoty (Clark, 1999; Goddu a Delker, 1960; Xing et al., 2005; Kang a Xing, 2005; Clark et al., 1990). Viscarra Rossel a Behrens (2010) představili ve své práci přehled (Tab. 4) klíčových absorpčních vlnových délek pro zkoumání půdních vlastností a převážně půdního uhlíku na základě jejich interakce s jednotlivými molekulami vyskytující se v půdě.

Tab. 4 Přehled absorpčních vlnových délek při studiu půdního uhlíku C

<b>Organická látka</b>	<b>Základ [cm<sup>-1</sup>]</b>	<b>Vlnové délky (VIS-NIR [nm])</b>	<b>VIS-NIR mód</b>
Aromáty	$\nu_1$ C–H 3030	1650 1100 825	2 $\nu_1$ 3 $\nu_1$ 4 $\nu_1$
Aminy	$\delta$ N–H 1610 $\nu_1$ N–H 3330	2060 1500 1000 751	$\nu_1\delta$ 2 $\nu_1$ 3 $\nu_1$ 4 $\nu_1$
Alkyly s asymetrickými a symetrickými doublety	$\nu_3$ C–H 2930 $\nu_1$ C–H 2850	1706 1754 1138 1170 853 877	2 $\nu_3$ 2 $\nu_1$ 3 $\nu_3$ 3 $\nu_1$ 4 $\nu_3$ 4 $\nu_1$

Organická látka	Základ [cm <sup>-1</sup> ]	Vlnové délky (VIS-NIR [nm])	VIS-NIR mód
Karboxylové kyseliny	$\nu_1$ C=O 1725	1930 1449	3 $\nu_1$ 4 $\nu_1$
Amidy	$\nu_1$ C=O 1640	2033 1524	3 $\nu_1$ 4 $\nu_1$
Alifatické látky	$\nu_1$ C-H 1465	2275 1706	3 $\nu_1$ 4 $\nu_1$
Methyl	$\nu_1$ C-H 1445–1350	2307–2469 1730–1852	3 $\nu_1$ 4 $\nu_1$
Fenoly	$\nu_1$ C-OH 1275	1961	4 $\nu_1$
Polysacharidy	$\nu_1$ C-O 1170	2137	4 $\nu_1$
Sacharidy	$\nu_1$ C-O 1050	2381	4 $\nu_1$

Zdroj: Viscarra Rossel a Baherns (2010)

## Data

Spektroskopie umožňuje určování obsahu organického uhlíku v laboratoři (Reeves et al., 1999, Chang a Laird, 2002) nebo přímo v terénu v případě využití ručního spektrometru (Barnes et al., 2003). Toto jsme ovšem schopni určit i ze snímků DPZ. Velkým problémem však zde je, že signál který není změřen těsně nad připraveným půdním vzorkem je zatíženo chybou. Tuto chybu způsobují atmosférické podmínky, ale i samotné charakteristiky půdy jako například půdní vlhkost a drsnost půdy nebo případná přítomnost vegetace (Ben-Dor et al., 2002; Cécillon et al., 2009, Stevens et al., 2010, Stevens et al., 2008). Změna reflektance půdy vlivem těchto podmínek velmi často přesahuje samotnou reflektanci organické hmoty (Barnes et al., 2003). Z důvodu velkého vlivu se například jen minimálně využívá satelitních hyperspektrálních snímků a ve většině případů autoři využili letecké hyperspektrální snímky (Ben-Dor et al., 2002; Stevens et al., 2010; Selige et al., 2006). Potenciálem satelitních hyperspektrálních snímků a důležitými kroky při zpracování snímků pro půdní průzkumy se věnoval například Gomez et al. (2008). Jedním z klíčových faktorů při použití letecké nebo satelitní spektroskopie při zkoumání organického půdního uhlíku je prostorové rozlišení snímků. Pro využití výsledků šetření například v precizním zemědělství je zapotřebí velmi vysokého rozlišení (Chang et al., 2001; Kerry et al., 2010; Stevens et al., 2006).

Mezi nejpoužívanější ruční spektrometry pro naše účely můžeme řadit stejně jako v předchozí kapitole například FieldSpec 3 (Vandour et al., 2016) nebo AgriSpec spectrometer (Gomez et al., 2008). Z pohledu letecké či satelitní spektrometrie autoři využívali systém Hyperion (Gomez et al., 2008, Roelofsen et al., 2015, Tadele et al., 2013) a senzor AISA-Eage (Vadour et al., 2016) nebo HyMap (Hbirkou et al., 2012).

## Metody

Jak už bylo dříve naznačeno, jednotlivé půdní vlastnosti a jejich odrazivé charakteristiky se překrývají a vzájemně ovlivňují, tudíž není možné hodnotu dané vlastnosti určit přímo ze spektrálních charakteristik zájmové oblasti. Je zapotřebí matematicky extrahovat vhodná spektra. Toto je možné provést několika (převážně

regresními) metodami. Tyto metody potřebují referenční spektra a k nim příslušné hodnoty půdní vlastnosti změřené standardní cestou, pomocí nichž vytvoří model, který je poté naplněn daty pro zájmové území (Martens a Naes, 1989). Pro stanovení obsahu organického půdního uhlíku bývají nejčastěji používány metody SMLR (Stepwise Multiple Linear Regression) (Ben-Dor a Banin, 1995), PCR a PLSR (Viscarra Rossel a Lark, 2009). V některých pracích se také objevilo využití metody umělých neuronových sítí (ANN) (Daniel et al., 2003; Fidencio et al., 2002) nebo MARS (Multivariate Adaptive Regression Splines) (Shepherd a Walsh, 2002). Poměrně častým způsobem odhadování bylo využití metody PLSR v kombinaci s ANN nebo jinými metodami. Obecně se ale autoři shodují, že nejlepší výsledky podává model vytvořený v základu metodou PLSR (Viscarra Rossel, 2007; Viscarra Rossel a Lark, 2009; Mouazen et al., 2010; Viscarra Rossel a Bahrens, 2010).

Zajímavou studii s velkým potenciálem představili Sylvain et al. (2012). V této práci se pokusili vytvořit nové indexy pro zkoumání půdních vlastností z multispektrálního systému Landsat-7. Veškeré jejich práce a analýzy byly postavené na již zmiňovaném faktu, že reflektance koreluje negativně s vlhkostí, organickými látky, barvou půdy a texturou. Jejich cílem bylo vytvořit nové spektrální indexy pro hodnocení organické půdní hmoty (jež je tvořena převážně uhlíkem), textury a barvy a také pro hodnocení půdní vlhkosti. Na základě zjištění vztahu mezi reflektancí a hodnotou půdní vlastností měřenou v laboratoři byly určeny následující indexy (6, 7, 8):

$$COI = \frac{TM7_{dry}^2}{TM2_{dry}} \quad (6)$$

$$OMI = \frac{1}{TM7_{dry}^2} \quad (7)$$

$$NBI = \log\left(\frac{TM7_{dry} TM2_{dry}^{-1}}{TM7_{wet}}\right) \quad (8)$$

COI (Texture and Color Index) je index značící fyzikální vlastnosti půdy jako texturu a zabarvení, OMI (Organic Matter Content Index) byl vyvinut pro stanovení množství organické půdní hmoty a NBI (Normalized Brightness Index) určuje míru vlhkosti půdy. V indexech jsou uvedeny hodnoty TM, značící číslo spektrálního pásu u Landsat-7 a dále u NBI se pracuje s dvěma snímky – pořízen v suchém období (dry) a pořízen ve vlhkém období (wet). Celá práce sice představuje velký potenciál nových indexů, na druhou stranu ovšem nenabízí popis interpretace výsledných hodnot.

### **Předzpracování**

Základním krokem je opět stejně jako u zkoumání předchozích vlastností provedení radiometrických a atmosférických korekcí. Z radiometrických korekcí se především jedná o redukci šumu nebo pásem s výraznou absorbcí, která nám dává nulové hodnoty o území. Toto se provádí pouze odstraněním příslušných pásem z příslušných dat. Dle Roelofsen et al. (2015) jsou pásy s největší atmosférickou absorpcí v oblasti 1347-1434 nm a 1804-1957 nm. Tadele et al. (2013) ve své práci určil oblasti pod 380 nm a nad 2450 nm jako šum a tedy vhodné pro odstranění pro další analýzy. Z pohledu

atmosférických korekcí je potřeba odstranit iradianci a celkový vliv atmosféry. Pro tyto korekce je možné využít velké množství modelů a softwarů. Vědci, kteří zkoumali organický půdní uhlík, využívali především model ATREM (Atmospheric Removal Program) (Gao a Goetz, 1990; Roelfsen et al., 2015; Tadele et al., 2013), model ATCOR4 (Hbirkou et al., 2012) nebo empirické odstranění vlivu atmosféry na data na základě naměřených spekter v terénu v programu ENVI 5.1 Classic (Vandour et al., 2016).

Předzpracování naměřených spekter znamenalo v téměř všech pracech odstranění šumu, převedení reflektance na absorbanci nebo vyhlazení spekter pomocí Savitzky-Golay transformace (Gomez et al., 2008; Vandour et al., 2016; Hbirkou et al., 2012). Některé práce se také zmiňují o převzorkování naměřených spekter ručním spektrometrem na spektra, která odpovídají příslušnému satelitnímu senzoru (Gomez et al., 2008). Nejpoužívanějším softwarem pro zpracování snímků DPZ a případné použití některých spektrálních indexů pro identifikaci a následné odstranění vegetace byl program ENVI (v několika verzích) (Vandour et al., 2016; Hbirkou et al., 2012). Dalším velmi významným softwarem tentokrát už pro samotnou tvorbu modelu a určení hodnot příslušné půdní vlastnosti bylo RStudio (Vandour et al., 2016).

## **Výsledky a hodnocení**

Obecné výsledky jako určení klíčových pásem nebo stanovení nejvhodnější metody byly už zmíněny v předchozím textu. Zde je ovšem důležité zdůraznit, že jednotlivé výsledky a přesnosti byly rozdílné. Toto je připisováno především citlivosti modelu na počet vstupních půdních vzorků nebo použití rozličných hyperspektrálních snímků. Například Hbirkou et al. (2012) ve své studii odhadoval půdní organický uhlík s vysokou přesností za pomoci senzoru HyMap, zatímco Gomes et al. (2008) měl s použitím snímků ze systému Hyperion nízkou přesnost. Kvalita je samozřejmě také ovlivněna i předzpracováním snímků. Rozdílné modely na korekce mohou dát různé výsledky nebo například odstranění šumu a nevhodných vlnových délek může být i přes určitá doporučení poměrně subjektivní záležitostí.

Jak již bylo předesláno, výsledné klíčové vlnové délky pro stanovení půdního organického uhlíku se liší. Henderson et al. (1992) zohledňuje celý rozsah 405-1055 nm. Podle dalších autorů jsou nejvýznamnější vlnové délky 1065-1165 nm v NIR a 1955-2495 nm v SWIR. Bellon-Maurel et al. (2010) jako klíčový určili rozsah 1650-2500 nm.

Přesnost modelů a výsledků se hodnotí podobně jako v předchozím případě statistickými veličinami jako je RMSE (Root Mean Square Error), RMSEP (Root Mean Square Error of Prediction),  $R^2$  (Coefficient of Determination), RPD (Residual Prediction Deviation) a RPIQ (Ratio of Interquartile Distance) (Vandour et al., 2016) .

## **3.3 Aktivní půdní reakce (pH)**

### **3.3.1 Význam aktivní půdní reakce**

Aktivní půdní reakce, která se také označuje jako kyselost půdy, je základní chemickou vlastností půdy. Její hodnota ovlivňuje velké množství půdotvorných procesů, ovlivňuje růst vegetace, určitým způsobem přeměňuje také organickou hmotu a ovlivňuje další půdní vlastnosti. Z obecného hlediska významně ovlivňuje příjem živin



a tím i celkovou úrodnost půdy (CENIA, 2013). Příjmem rostlin se myslí zejména dostupnost živin. S jinou hodnotou půdní reakce jsou k dispozici jiné prvky (Hrudová, 2011). Výskyt aktivní půdní reakce je spojován s volně se vyskytujícími ionty vodíku, příp. hliníku nebo železa (CENIA, 2013).

V praxi můžeme nalézt označením pH, které značí aktivní půdní reakci. Tato veličina nabývá hodnot od 0 do 14. Půdy s hodnotou pH do 6,5 jsou označovány jako kyselé, s hodnou pH 6,6-7,2 neutrální a půdy s vyšší hodnotou jako alkalické (zásadité). Čím více vodíkových iontů se v půdě vyskytuje tím má půda nižší pH a je kyselejší. Z hlediska zemědělství je pro důležitost pozorování a stanovování hodnoty pH dána faktem, že kyselé půdy jsou méně úrodné a také méně osídleny půdními organismy i rostlinami. Kyselost půdy je dána také jejím původem a matečnou horninou. Například na vápenci se vyvíjí půdy zásadité a na žule naopak kyselé. Ideální hodnota pH pro zemědělskou produkci byla stanovena mezi hodnotami 4 a 8,5 (CENIA, 2013). Jak již bylo naznačeno, dle naměřené hodnoty pH jsme schopni určit, jaké živiny jsou v půdě dostupné, a tudíž jsme schopni určit pro jaký druh plodin je daná půda vhodná. Neutrální až alkalické půdy jsou nejdostupnější živinami N, P, K, Ca, Mg a Mo. Na kyselých půdách jsou nejdostupnější Fe, Mn, B, Cu, Zn a Al. Na základě znalosti i dostupnosti konkrétních prvků můžeme zvolit jiný postup nebo přidávat potřebná hnojiva (Hrudová, 2011). Půdní reakci lze rozdělit na tři druhy: *půdní aktivní reakce* (pH/H<sub>2</sub>O), *půdní reakce potenciální výměnná* (pH/KCl) a *půdní reakce potenciální hydrolytická* (Ha; nmol H<sup>+</sup>/100 g půdy) (Zajoncová a Vinter, 2013). V našem výzkumu se dále budeme zabývat aktivní půdní reakcí, která bude pro naše účely označována pouze pH.

Velkým probléme současnosti je, že velké množství půd je okyselováno lidskou činností. Například jevem známým jako kyselé deště jsou zvyšovány emise SO<sub>2</sub> a NO<sub>x</sub> (CENIA, 2013). Ovšem nejenom tyto globální problémy hrají roli při okyselování půdy. Je potřeba zmínit, že půda je okyselována také při intenzivní biologické činnosti v půdě, při odstranění alkalických látek z půdy, při procesech nitrifikace, při hnojení fyziologicky kyselými hnojivy atd. Naopak zásaditost je dána například vysokým obsahem uhličitanu vápenatého, další biologickou činností v půdě, hnojením fyziologicky zásaditými hnojivy a vápnění půdy (Hrudová, 2011).

### **3.3.2 Stanovení aktivní půdní reakce bezkontaktními metodami**

V případových studiích se přístupy poměrně různí, neboť se předpokládá, že pH nemá přímou spektrální odezvu. Stenberg (2010) také ve své práci nepředpokládá přímou spektrální odezvu, ale přišel s myšlenkou, že hodnota pH by šla s největší pravděpodobností předpovědět přes kovariance s pufrací kapacitou organické hmoty, jílu, minerálů nebo mikrobiálních procesů, které jsou řízené stejnými vlastnostmi půdy. Ve své práci také uvádí domněnku, že jiní autoři ve svých pracích, kde se využívalo reflektance v NIR, došli k uspokojivým výsledkům právě proto, že existovala významná kovariance s dalšími vlastnostmi, které měly přímou spektrální odezvu jako například uhlík nebo dusík. Dle několika prací (Islam et al., 2003; Pirie et al., 2005) bylo zjištěno, že korelační spektra jsou velmi podobná s obsahem jílu a kationtovou výměnnou kapacitou (CEC – cationt exchange capacity). Na druhou stranu například Chang et al. (2001) nenašli žádnou přímou podobnost mezi měřeným parametrem a dalšími

parametry půdy. Ačkoliv množství prací našlo přímý vztah s odrazivostí v NIR, Li et al. (2015), Marín-González et al. (2013) a Tekin et al. (2013) ve svých výzkumech poukazují na to, že důvodem je pouze přímé ovlivnění hodnoty pH půdní organickou hmotou, dusíkem a jilem. Z jejich výsledků vyplývá, že přesnost výpočetních modelů pro stanovení pH je nejnižší v porovnání s jinými veličinami.

V jednotlivých výzkumech se autoři také zabývali komplexnějšími procesy v půdě a jejich možným přímým vztahem k hodnotě pH. Mezi tyto procesy patří převážně nitrifikace, což je proces významně ovlivňovaný právě hodnotou pH. Proces celkové výměnné báze (TEB – total exchange bases) byl sledován také závislý na pH, neboť s alkalitou klesá příjem kationtů (Piekarczyk, 2011). Dále byla také sledována významná korelace půdní elektrické konduktivity a mírou absorpce vodíku (SAR – sodium absorption rate) se spektrální odrazivostí ze snímků ze systému Landsat ETM+ (Fernandez-Buces et al., 2006). Frouz et al. (2011, 2005) ve svých pracích dokonce uvádí že konduktivita a pH jsou dva hlavní faktory zodpovědné za toxicitu půdních substrátů.

Téměř všechny práce, které se zabývaly stanovením půdního pH, se současně věnují i dalším půdním veličinám. Například W. Ji et al. (2016) stanovoval zároveň organický uhlík a celkový dusík. Brodský (2011) stanovuje při budování české spektrální knihovny půd také půdní organický uhlík, potenciální výměnnou půdní reakci, obsah uhličitánů, texturu, dostupný fosfor (P), draslík (K), vápník (Ca) a hořčík (Mg). Lu et al. (2013) kromě pH zkoumá také organický půdní uhlík a celkový fosfor. Jednotlivé výzkumy stanovovaly různé veličiny společně s pH dle jejich vlastního zájmu, ale dá se vysledovat určitá skupina vlastností, která má největší zastoupení. Mezi tyto vlastnosti patří půdní organický uhlík, celkový fosfor, celkový dusík, vápník, hořčík, železo a jiné kovy, elektrická konduktivita nebo například kationtová výměnná kapacita.

## **Metody**

Metod pro stanování pH existuje celá řada. Mezi nejpoužívanější patří *klasická metoda laboratorní*. Aktivní půdní reakce se dle této metody měří pH-metrem ve vodném výluhu (pH/H<sub>2</sub>O) s přesným stanovením množství vody a časových prodlevách. Ve studiích týkajících se půdy je hodnota pH stanovována z přirozeně vyschlého vzorku půdy a následně rozmíchaného v suspenzi v různých poměrech (Brodský, 2011; Schirrmann et al., 2011; W. Ji et al., 2016).

Další skupinu metod bychom mohli nazvat *spektroskopické laboratorní metody*. Jsou to takové metody, které využívají při měření půdních vlastností v laboratoři nebo v terénu ruční spektrometry. Pro měření pH se používají víceméně stejné spektrometry jako v předchozích kapitolách. Mezi nejpoužívanější tedy patří ASD FieldSpec Pro spectrometer 3/5 (W. Ji et al., 2016; Roelofsen, 2015; Brodský, 2011; Vagen et al., 2006), Field Scout TDR-300 (W. Ji et al., 2016), Airborne Prism Experiment APEX (Roelofsen, 2015), Perkin-Elmer Lambda 950 spectrophotometer (Lu et al., 2013), Fourier transformed NIR spectrometer (Dong et al, 2011) nebo například FOSS XDS Rapid Content Analyzer spectrometer cally (Vohland et al., 2014).

Na základě měření spektrometrem a metody CARS-PLSR byly extrahovány klíčové vlnové délky pro měření aktivní půdní reakce (Tab. 5).

Tab. 5 Klíčové vlnové délky při stanovení pH metodou CARS-PLSR

Oblast vlnových délek	Klíčové vlnové délky
VIS (450-780 nm)	-
NIR (780-2550 nm)	1915-1920, 2110, 2120, 2450-2455, 2465
MIR (3800-1500 cm <sup>-1</sup> )	2484, 2472-2468

Zdroj: Vohland et al., 2014

Z hlediska konkrétních metod, které popíší variabilitu pH v půdě patří mezi nejpoužívanější metody PCR (Principal Component Regression) a PLSR (Partial Least Square Regression), což dokládá i tabulka pod textem přejatá od Viscarra Rossel et al. (2006), která uvádí přehled významných prací, použitých metod a hodnocení (Tab. 6).

Tab. 6 Přehled prací a výsledků zabývajících se stanovením pH spektroskopickými metody

Půdní reakce	Oblast vlnových délek	Rozsah vlnových délek [nm]	Metoda	n <sup>kalibrace</sup> / n <sup>validace</sup>	RMSE	R <sup>2</sup>	Zdroj
pH	MIR	2500-20000	PLSR	-	-	0,72	Janik et al. (1998)
pH	NIR	1100-2300	PLSR (8)	183 x-val	-	0,74	Daniel et al. (2003)
pH	NIR	1100-2300	PLSR (11)	120/59	-	0,73	Janik and Skjemstad (1995)
pH	VIS-NIR	350-2500	MARS	505/253	0,43	0,70	Reeves and McCarty (2001)
pH <sub>Ca</sub>	MIR	2500-25000	PLSR	183	-	0,67	Reeves et al. (1999)
pH <sub>Ca</sub>	VIS-NIR	400-2498	PCR (13)	30/119	0,56	0,56	Shepherd and Wals (2002)
pH <sub>w</sub>	MIR	2500-25000	PLSR	183	-	0,56	Janik et al. (1998)
pH <sub>w</sub>	NIR	700-2500	PCR	121/40	-	0,70	Islam et al. (2003)
pH <sub>w</sub>	VIS-NIR	400-2400	SMLR (959, 1212)	15/10	-	0,54	Shibusawa et al. (2001)
pH <sub>w</sub>	VIS-NIR	400-2489	PCR (13)	30/119	0,55	0,57	Chang et al. (2001)
pH <sub>w</sub>	UV-VIS-NIR	250-2500	PCR	121/40	-	0,71	Islam et al. (2003)

Zdroj: Viscarra Rossel et al., 2006

Stenberg et al. (2010) ve své práci uvádí, že nejlepší kalibrační metody jsou takové, které jsou založeny na lineární regresi, převážně tedy SMLR (Stepwise Multiple Regression). Tuto metodu také používali Ben-Dor et al. (1995) a Dalal a Henry (1986). Metoda SMLR byla později nahrazována metodami PCR (Chang et al., 2001; Piekarczyk, 2011) a PLSR (Vohland et al., 2014; Tekin et al., 2013; Kuang et al., 2015; Chang et al., 2001, Roelofsen, 2015), neboť vykazovaly lepší výsledky v predikčních modelech. Výjimku tvořila práce Kunag et al. (2015), který se pokoušel vytvořit model pomocí ANN nebo práce Vohland et al. (2014), který pro zpřesnění metody PLSR použil navíc ještě CARS.

Někteří autoři se ve svých pracích zabývali také využitím technologií, která je možno využít v pohybu – například připevnění senzoru na traktor. Tekin et al. (2013) a Kuang et al. (2015) využili AgroSpec mobile VIS-NIR spectrometer, který umí kopírovat pohyb stroje, na který je připevňován. Dále například Wang et al. (2015) využil FT-NIR spectrometer Precision fertilizer, který byl pomocí tyče připevňován na traktor pro sbírání informací v reálném čase.

### **Předzpracování**

Ve většině případů byla surová data naměřená spektrometrem převedena na absorbanci (viz kapitola 3.2.2). Dalším častým krokem byla normalizace dat. Chang (2001) dále aplikoval na vypočtenou absorbanci také první derivaci. Velmi častým krokem předzpracování dat bylo také vyhlazení Savitzky-Golay metodou (Tekin et al., 2013; Kuang et al., 2015, Wang et al., 2015; W. Ji et al., 2016). Téměř ve všech případech došlo o ořezání spekter a převzorkování.

Nejpoužívanějším softwarem pro předzpracování dat z dálkového průzkumu země byl program ENVI (Hiveli, 2011; Vagen et al., 2005). Pro předzpracování dat z ručního spektrometru nebo i samotnou tvorbu predikčního modelu byly využívány stejně jako v předchozích případech matematicko-statistické platformy jako Matlab, R, SAS nebo Unscrambler.

### **Data**

Z hlediska obecných podmínek a doby měření se autoři víceméně nezmiňují o ničem významném. Výjimkou jsou studie Roelofsena (2015) a Lu et al. (2013), kteří využívali stejnou datovou sadu z terénního šetření, bylo zmiňováno, že vzorky byly sbírány v době extrémního sucha, což jim dalo pravý spektrální obraz půdy. V těchto pracích je uvedeno, že sucho může být pro analýzy tohoto druhu velmi výhodné.

Letecká nebo satelitní data pro porovnání s měřením ručním spektrometrem byly využívány jak hyperspektrální, tak multispektrální. Hyperspektrální data byla využita ze satelitního senzoru Hyperion (Lu et al., 2013) nebo například z leteckého senzoru HyperspecTIR. Mutlispektrální data byla použita z běžných satelitních senzorů jako ASTER (Piekarczyk et al., 2011), SPOT-5 (Wang et al., 2010), Landsat-5 (TM) (Wang et al., 2010).

## Výsledky a hodnocení

Jak již bylo nastíněno v předchozích kapitolách, stanovení půdního pH není tak jednoduchá záležitost jako u ostatních půdních vlastností, které jsou předmětem zájmu této práce. Samotné pH nemá výrazné spektrální chování a je vždy doprovázeno spektrálním chováním jiných veličin. Díky tomuto faktu u většiny prací vyšla pouze mírná přesnost u modelů sledující pH, na základě hodnocení pomocí RPD a  $R^2$  (Lu et al., 2013). Naopak Hively et al. (2011) tvrdí, že modely jako PLSR jsou výborné pro posuzování nejenom pH, ale i dalších prvků. López-Granados et al. (2005) ve své práci představil modely s nejvyšším  $R^2$  právě pro stanovení pH společně s organickou půdní hmotou a texturou. Chang (2001) konstatuje, že modely pro výpočet pH z pásma NIR jsou obecně stanovovány s nižší přesností. Jejich  $R^2$  se pohybuje v rozmezí 0,5-0,8. Výjimku tvořila práce Wang et al. (2015), kterému vyšla přesnost modelů  $R^2$  v rozmezí 0,85-0,92. Tato skutečnost byla ovšem způsobena faktem, že se jednalo o modely popisující společně organickou hmotu, která je půdní reakcí přímo ovlivňována. Navzdory nižší přesnosti modelů pro určení pH, Tekin et al. (2013) uzavírá tuto problematiku s tvrzením, že výsledná kvalita je stále dostatečná pro účely zemědělského vápnění při využití technologie precizního zemědělství.

Obecně se metody a přesnosti modelů pro hodnocení aktivní půdní reakce hodnotí pomocí stejných statistických parametrů jako v jiných kapitolách. Mezi nejvýznamnější patří  $R^2$  (Coefficient of Determination), RMSE (Root Mean Square Error), RPD (Residual Prediction Deviation) a RPIQ (Ratio of Interquartile Distance) (W. Ji et al., 2016, Piekarczyk, 2011; Dong et al. 2011).

## 3.4 Půdní vlhkost

### 3.4.1 Význam půdní vlhkosti

Definice půdní vlhkosti je poměrně složitá a liší se v jednotlivých vědních oborech. V pedologii vyjadřujeme vlhkost půdy jako souhrn velkého množství charakteristik (polní vodní kapacita, bod snížení dostupnosti vody, bod vadnutí atd.). Definice půdní vlhkosti je velmi úzce spjata s metodou měření. Všechny metody jsou ale zatíženy chybou a proto jsou výsledky mezi sebou těžko srovnatelné (Honsová, 2008). Obecně ale můžeme říct, že půdní vlhkost představuje vodu drženou v prostoru mezi půdními částicemi. Dělí se na dvě základní skupiny: povrchovou půdní vlhkost, která leží ve svrchní části půdy (asi do 10 cm) a půdní vlhkost v kořenové zóně. Druhá ze jmenovaných je dostupná právě pro rostliny a je důležitá pro zemědělství. Z hlediska pedologie se jedná o půdní vlhkost do dvou metrů (Gaja, 2013).

Obecně půdní vlhkost nepředstavuje nijak významnou složku hydrologického cyklu, ale z hlediska biologických, biochemických a pedologických procesů hraje velmi významnou roli. Klíčovou úlohu představuje půdní vlhkost při výměně vody a energie skrze evaporaci a rostlinou transpiraci, což znamená, že patří mezi základní proměnné při tvorbě počasí (Li a Islam, 1999). Z hlediska zemědělství je důležitá pro výživu rostlin a celkové plánování závlahy (Gaja, 2013). Vlhkost půdy ovšem není ovlivněna pouze srážkami, velkou roli zde hraje také množství organické hmoty v půdě, na kterou se voda váže a také způsob obdělávání a jiné antropogenní pochody (Diviš, 2010).

Velký problém představuje sucho. Jedná se o přírodní hazard, který je způsobený nedostatkem dešťových srážek vůči normálnímu dlouhodobému průměru (Wilhite

a Buchanan-Smith, 2005). Sucho způsobuje obrovské ekonomické a zemědělské škody. Sucho je možné rozdělit na meteorologické, zemědělské, hydrologické a socioekonomické. Z důvodu charakteru práce nás zajímá převážně sucho zemědělské, které je definováno jako nedostatek vody v půdě pro podporu růstu zemědělských plodin (Gaja, 2013).

Jedním z nejjednodušších způsobů stanovení půdní vlhkosti v terénu je určení pocitem při stisku v dlani. Zde určujeme pět kategorií: vyprahlá → suchá → vlahá → vlhká → mokrá (Diviš, 2010).

### **3.4.2 Stanovení půdní vlhkosti bezkontaktními metodami**

Půdní vlhkost je velmi důležitá pro celý dálkový průzkum země, neboť vlhkost, čili množství vody, formuje spektrální charakteristiky téměř všech objektů (Dobrovolný, 1998; Ben-Dor, 2002; Lilienthal, 2003; Halounová a Pavelka, 2005; Ben-Dor et al., 2009; Dewitte et al., 2012; Gaja, 2013).

Formování spektrálních charakteristik půdní vlhkosti je vhodné popsat pro každou zájmovou část elektromagnetického spektra zvlášť:

#### **Viditelná, blízká infračervená a střední infračervená část spektra**

V této části platí základní pravidlo, že narůstající obsah půdní vlhkosti snižuje odrazivost objektu v absorpčních pásech vody. Ty se nachází ve vlnových délkách 1400 nm, 1900 nm a 2700 nm. Absorpční pás je obecně dle VÚGTK (2016) „Rozsah vlnových délek elektromagnetického záření, které je zcela nebo silně pohlcováno atmosférou“. Ovšem v ostatních pásech vodní vlhkost také formuje odrazivost a to převážně díky vnitřním odrazům v molekulách vody, která pokrývá půdní částice, ale už ne tak výrazně. Pokud chceme zobecnit závěry, můžeme říci, že čím více vlhkosti půda obsahuje, tím více se jeví půda na snímcích tmavší, tzn. méně odrazivá. Na druhou stranu ale musíme zmínit, že voda není jediný faktor, který odrazivost ovlivňuje. Mezi další patří třeba textura, úhel dopadu, obsah organických látek, pokryv vegetace apod.

Mezi obsahem půdní vlhkosti a texturou půdy je možné také vysledovat korelaci. Písečné půdy mají vyšší odrazivost než například jílovité. Důvod je zřejmý. Hrubá půda dobře odvádí vodu a tudíž je její půdní vlhkost nižší. Když přidáme předchozí zobecnění, dospějeme k závěru, že písečné půdy mají vyšší odrazivost díky malému množství vody. Nutné ale připomenout, že pokud posuzujeme půdu s naprostou nulovou vlhkostí, toto pravidlo platí naopak. Při nedostatku vody je záření odraženo mezi jednotlivými částicemi půdy uvnitř a je tedy velmi silně absorbováno. Toto je důvod, proč mohou mít vysušené hrubozrnné půdy nižší odrazivost než jemnozrnné.

Qiu (2006) uvádí, že informace o půdní vlhkosti můžeme získat pouze z několika vrchních milimetrů půdního profilu a tudíž metody založené pouze na spektrální odrazivosti nejsou dostatečné. Díky přímému vztahu mezi půdní vlhkostí a spektrálním projevem vegetace můžeme v těchto vlnových délkách vhodně využít spektrálních vegetačních indexů. Mezi nejpoužívanější vegetační indexy patří NDVI, VCI, TCI, WSVI, NDWI a NMDI (Huete et al., 1999; Honková, 2008; Gaja, 2013; Wang a Qu, 2007).

NDVI (*Normalized Difference Vegetation Index*) je určen především pro hodnocení stavu vegetace, ale nepřímo jej lze použít pro hodnocení vlhkosti, neboť zdravá vegetace indikuje vyšší půdní vlhkost a naopak. Index stojí na vlastnosti, že chlorofyl u zdravé

vegetace silně absorbuje elektromagnetické záření v RED pásmu (600 – 700 nm) a naopak v NIR pásmu (700 – 900 nm) je záření díky morfologické struktuře listů silně odraženo. Hodnota NDVI se pohybuje v rozmezí -1 a 1, přičemž zdravá vegetace nabývá vysokých kladných hodnot, kamenitá a holá půda hodnot kolem 0 a voda nebo sníh spíše záporných hodnot (Singh et al., 2003; Lillesand et al., 2004; Jain et al., 2009). Index spočítáme dle následujícího vzorce (9) (Tucker, 1979):

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (9).$$

VCI (*Vegetation Condition Index*) se využívá pro odstranění přírodních vlivů (klíma, půdní typ, topografie atd.) na hodnoty NDVI, protože více počítá s měřením NDVI v měnících se podmínkách například během několika let. Vzorec pro výpočet indexu je (10) (Kogan, 1995):

$$VCI_{yc} = 100 \frac{NDVI_{yc} - NDVI_{min_c}}{NDVI_{max_c} - NDVI_{min_c}} \quad (10),$$

kde  $NDVI_{min}$  a  $NDVI_{max}$  představují minimální a maximální hodnoty NDVI pro každý pixel v oblasti v kompozici  $c$  a v roce  $y$ . Výsledné hodnoty jsou v procentech, kdy vyšší hodnoty znamenají dobrý zdravotní stav vegetace a tudíž i dostatek vláhy (Unganai a Kogan, 1998; Domenikiotis et al., 2004).

*TCI (Index teplotního stavu)* využívá hodnot radiační teploty (BT) a na základě toho určuje zdravotní stav vegetace způsobený nadměrnou vlhkostí nebo dlouhodobým suchem. Kogan (1995) definoval vzorec (11) pro výpočet:

$$TCI_{yc} = 100 \frac{BT_{min_c} - BT_{yc}}{BT_{max_c} - BT_{min_c}} \quad (11),$$

kde BT značí dlouhodobé maximální nebo minimální teploty: Koeficienty mají stejný význam jako v případě indexu VCI. Nízká hodnota TCI ve výsledku znamená, že na vegetaci působí velmi vysoké teploty a tedy suché a nepříznivé podmínky (Kogan, 1995).

Další jmenované indexy není nutné blíže představovat, protože všechny stojí na stejném principu jako předchozí a tím je určitá korelace mezi zdravotním stavem vegetace (resp. množstvím vody v listech) a půdní vlhkostí. Žádný z těchto indexů nemá pro půdní vlhkost větší význam než popsané výše.

### **Termální infračervená část spektra**

Tato část spektra je využívána především pro detekci teploty (Schmugge et al., 2002). Při využití nejen tohoto pásma a znalostech o teplotě, ale i pásma viditelného, je možné určit i povrchovou teplotu. Díky procesu vypařování je vlhká půda obvykle chladnější. To znamená, že půda s nízkou odrazivostí a zároveň nízkou emisivitou bude

signalizovat větší přítomnost vody. V případě nízké odrazivosti, ale vysoké emisivity jsme schopni určit, že se pravděpodobně jedná o suchou půdu.

Informace u půdní vlhkosti jsou získávány především na základě radiační teploty ve vlnových délkách 3000-5000 nm a 8000-14000 nm (Qui, 2006; Mukund, 2008). Při aplikaci výpočetního modelu na určení půdní vlhkosti je nutné také zohlednit vlastní *emisivitu* objektu. Emisivita objektu je vlastně koeficient vyzařování, který nám říká, jak velkou schopnost vyzařovat má reálně těleso ve srovnání s absolutně černým tělesem (Gaja, 2013; Qui, 2006). Zkoumání povrchu v této části spektra je omezeno převážně atmosférickými podmínkami a přítomností vegetace (Mekonnen, 2009). Díky těmto faktorům je zapotřebí při předzpracování nejprve odstranit šum a stejně jako v předchozí oblasti elektromagnetického spektra je v této části možné sledovat půdní vlhkost jen ze svrchní části půdního profilu.

Pro stanovení obsahu vody v půdě z dat z termální části spektra se využívají dvě metody:

- 1) Metoda zdánlivé tepelné setrvačnosti (Apparent thermal inertia method – ATI) (Tramutoli et al., 2000; Claps a Laguardia, 2004).
- 2) Metoda využívající kombinace povrchové teploty a vegetačního indexu (Carlson et al., 1995; Gillies et al., 1997).

*Metoda zdánlivé tepelné setrvačnosti* je založena na principu tepelné setrvačnosti materiálu a značí odpor tělesa vůči změně teploty při změně teploty okolí. Materiál s nízkou setrvačností se rychleji zahřeje, ale také rychleji vychladne. Takovým materiálem je například suchá půda. Naopak například voda je materiál s vysokou setrvačností a tím vykazuje mnohem menší výkyvy teplot. To znamená, že půda s vyšším obsahem vody bude mít vyšší tepelnou setrvačnost, tzn. stálejší teplotu (Wang a Qu, 2009). Výpočet tepelné setrvačnosti je komplikovanější, neboť jsou zapotřebí i data z terénního šetření. Z tohoto důvodu se využívá výpočet *zdánlivé* tepelné setrvačnosti, kterou lze odvodit přímo z multispektrálních dat. Potřebujeme zjistit pouze *albedo* ( $\alpha$ ) a rozdíl mezi *maximální* a *minimální povrchovou teplotou během denního cyklu* ( $\Delta T$ ). Výslednou zdánlivou tepelnou (12) setrvačnost vložíme do vzorce pro výpočet obsahu půdní vlhkosti (13), přičemž hodnoty *a* a *b* jsou empiricky odvozené koeficienty (Tramutoli et al., 2000; Claps a Laguardia, 2004; Liang et al. 2012).

$$ATI = \frac{1 - \alpha}{\Delta T} \quad (12),$$

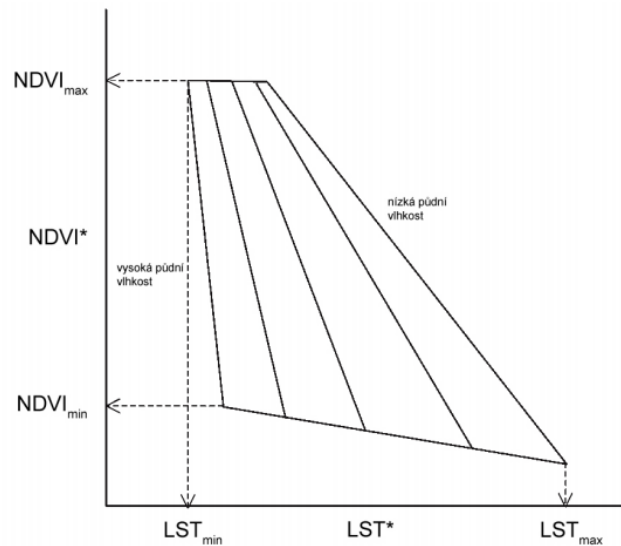
$$W = a \cdot ATI + b \quad (13).$$

Jedná se o velmi přesnou metodu s tím, že je nutné ji použít na oblast s žádnou nebo minimální vegetací (Wang a Qu, 2009).

*Metoda využívající kombinace povrchové teploty a vegetačního indexu* se nazývá někdy také *Trojúhelníková metoda*, protože využívá vztah mezi půdní vlhkostí, povrchovou teplotou (LST) a NDVI. Hodnoty povrchové teploty (LST) a NDVI jsou po odstranění extrémů, šumu, příměsí oblačnosti atd. vkládány do dvourozměrného grafu, kde vytváří trojúhelníkový graf (Obr. 3). Pravá strana tohoto grafu znázorňuje nejsušší pixely (tzv. warm edges – teplý okraj) a levá strana značí nejvlhčí pixely (tzv. cold edges – studený okraj). Další vlastností tohoto grafu je zúžení v horní části,



kteřé nám značí, že povrchová radiační teplota klesá s nárůstem NDVI. (Chauhan et al., 2003; Wang et al., 2007; Hossain a Easson, 2008; Wang a Qu, 2009).



Obr. 3 Obecný trojúhelníkový graf vyjadřující vztah mezi vlhkostí, teplotou (LST) a NDVI. (zdroj: Gaja, 2013)

Hodnoty, které jsou vynášeny na obě osy, jsou standardizované hodnoty povrchové teploty a NDVI indexu dle příslušných vztahů (14, 15). Následně lze podle následující regresní rovnice (16) vyjádřit vztah mezi půdní vlhkostí, NDVI a povrchové teploty (Carlson et al., 1994):

$$LST^* = \frac{LST - LST_{min}}{LST_{max} - LST_{min}} \quad (14),$$

$$NDVI^* = \frac{NDVI - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \quad (15),$$

$$W = \sum_{i=0}^{i=n} \sum_{j=0}^{j=n} a_{ij} NDVI^{*i} LST^{*j} \quad (16).$$

Omezením této metody může být mírná subjektivnost při čtení trojúhelníkového grafu a také nutnost zastoupení plného rozsahu povrchové vlhkosti půdy a vegetačního krytu pixely. Tento graf byl také využit v mnoha studiích, kde byl kombinován i s pozemním měřením (Wang et al., 2007). Například Hossain a Easson (2008) pro tuto metodu použili data z MODIS společně s daty AMSR-E (data z mikrovlnné části spektra).

### Mikrovlnná část spektra

Právě tato část elektromagnetického spektra je nejvíce využívána pro detekci půdní vlhkosti (Schmugge et al., 2002). Zde se využívají aktivní senzory, což znamená, že není snímána odražená energie ze Slunce, ale přístroj sám vyzařuje energii a následně zaznamená odraz. Intenzita tohoto odraženého záření závisí především na drsnosti

povrchu a právě půdní vlhkosti (Anderson a Croft, 2009). Změna intenzity odraženého záření na základě půdní vlhkosti je způsobena *dielektrickou konstantou*. Dielektrická konstanta nám popisuje, jak se ustanovuje počet dipólů v látce vlivem elektrického pole. Ve zkratce nám to popisuje například, zda se daná látka stane vlivem tohoto pole vodičem. Vysoké hodnoty dielektrické konstanty zvětšují intenzitu zaznamenaného signálu. Dielektrická hodnota vody nabývá přibližně hodnoty 80, zatímco suchá půda 3 až 4 v závislosti na frekvenci. To pro nás znamená, že více vody půda obsahuje, tím vyšší bude dielektrická konstanta a tím vyšší bude intenzita zaznamenaného signálu (Schmugge a Jackson, 1993; Engman a Chauhan, 1995; Njoku a Entekhabi, 1996).

Pro zkoumání půdní vlhkosti v mikrovlnné části spektra, se používají především nízkofrekvenční pásma L (1,0-2,0 GHz) a C (4,0-8,0 GHz) (Lakhankar et al., 2009). Jednou z obrovských výhod dat pořízených v mikrovlnné části spektra je nezávislost na atmosférické podmínky a sluneční záření a také fakt, že jsme schopni získat informace o půdní vlhkosti až z hloubky 5 cm (Schmugge a Jackson, 1993). Omezením je opět drsnost půdy a přítomnost vegetace.

Metody snímání povrchu v mikrovlnné části spektra dělíme na *pasivní* a *aktivní*. Pasivní metody jsou takové, kdy senzor měří přirozenou dlouhovlnnou energii vyzářenou z objektů na zemském povrchu (radiální teplotu). Tyto metody ale nejsou nijak významné pro měření půdní vlhkosti (Gaja, 2013; Jackson et al., 1996; Macelloni et al., 2003). Aktivní metody využívají systém, který sám vyše krátký a intenzivní signál směrem k povrchu a poté je senzorem zaznamenána odražená část. Mezi nejpoužívanější takový systém patří systém SAR (radar se syntetickou aparaturou). Po odvození půdní vlhkosti je možné použít *teoretické*, *empirické* a *semiempirické* modely (Lakhankar et al., 2009; Wang a Qu, 2009). Teoretické modely předpovídají obecný trend koeficientu odrazivosti v reakci na změny v drsnosti a vodním obsahu. Tento koeficient je ale nutné predikovat na základě známé charakteristiky drsnosti povrchu, což ovšem může být významné omezení modelu, neboť parametrizace může být určena subjektivně (Gaja, 2013). Mezi nejznámější teoretický model patří IEM (Integral Equation Model) (Fung et al., 1992). Empirické modely stojí na získaných datech z experimentálního šetření. Tyto modely jsou ale z tohoto důvodu hůře aplikovatelné na různé datové sady. Příkladem takového modelu může být NBMI (Normalized Backscatter Moisture Index) (Shoshany et al., 2000). Semiempirické modely jsou kombinací obou předchozích druhů. Využívají tedy teoretických základů, ale i parametrů odvozených z experimentálních dat (Wang a Qu, 2009).

### **3.4.3 Data pro posuzování půdní vlhkosti**

Pro zjišťování půdní vlhkosti obecně existuje množství dat, přičemž velká část je dokonce dostupná i zdarma (Tab. 7). Problémem těchto dat je menší prostorové rozlišení, které by znamenalo jen velmi nízkou přesnost při použití na našem zájmovém území.

Tab. 7 Přehled datových zdrojů používaných pro odhad půdní vlhkosti

<b>Senzor (provozovatel)</b>	<b>Mise (délka provozu)</b>	<b>Prostorové rozlišení</b>	<b>Spektrální rozlišení</b>
<b>AMSR-2</b> Advanced Microwave Scanning Radiometer -2 (JAXA)	GCOM-W1 – Global Change Observation Mission-W1 (2012-2017) GCOM-W2 (2016-2021) GCOM-W3 (2020-2025)	5-50 km	MW (1-100 cm) 6,925 GHz, 7,3 GHz, 10,65 GHz, 18,7 GHz, 23,8 GHz, 36,5 GHz, 89,0 GHz
<b>ASCAT</b> Advanced Scatterometer (EUMETSAT, ESA)	Metop-A – Meteorological Operational Polar Satellite-A (2006-2018) Metop-B (2012-2017) Metop-C (2018-2021)	25-50 km	MW (1-100 cm) C-Band (5,256 GHz)
<b>AVHRR/3</b> Advanced Very High Resolution Radiometer/3 (NOAA)	NOAA-15 - National Oceanic and Atmospheric Administration - 15 (1998 - 2015) NOAA-16 - National Oceanic and Atmospheric Administration - 16 (2000 - 2014) NOAA-17 - National Oceanic and Atmospheric Administration - 17 (2002 - 2013) NOAA-18 - National Oceanic and Atmospheric Administration - 18 (2005 - 2016) Metop-A - Meteorological Operational Polar Satellite - A (2006 - 2018) NOAA-19 - National Oceanic and Atmospheric Administration - 19 (2009 - 2016) Metop-B - Meteorological Operational Polar Satellite - B (2012 - 2017) Metop-C - Meteorological Operational Polar Satellite - C (2018 - 2021)	1,1 km	VIS (0,58-0,68 $\mu\text{m}$ ) NIR (0,725-1,1 $\mu\text{m}$ ) SWIR (1,58-1,64 $\mu\text{m}$ ) MWIR (3,55-3,93 $\mu\text{m}$ ) TIR (10,3-11,3 $\mu\text{m}$ , 11,5-12,5 $\mu\text{m}$ )
<b>C-Band SAR</b> C-Band Synthetic Aperture	Sentinel-1 A (2014-2021) Sentinel-1 B (2015-2023)	9-50 m	MW (1-100 cm) C-Band (5,405

<b>Senzor (provozovatel)</b>	<b>Mise (délka provozu)</b>	<b>Prostorové rozlišení</b>	<b>Spektrální rozlišení</b>
Radar (ESA)	Sentinel-1 C (2019-2026)		GHz)
<b>ETM+</b> Enhanced Thematic Mapper Plus (USGS/NASA)	Landsat 7 - Landsat 7 (1999 - 2021)	15-60 m	VIS - TIR: 0,45 - 12,5 $\mu\text{m}$ (8 pásem) VIS (0,40 $\mu\text{m}$ - 0,75 $\mu\text{m}$ ) NIR (0,75 $\mu\text{m}$ - 1,3 $\mu\text{m}$ ) SWIR (1,3 $\mu\text{m}$ - 3,0 $\mu\text{m}$ ) TIR (6,0 $\mu\text{m}$ - 15,0 $\mu\text{m}$ )
<b>L-band Radiometr (SMAP)</b> L-band Radiometer (SMAP) (NASA)	SMAP - Soil Moisture Active Passive (2015 - 2018)	40 km	L-band (1,4 GHz)
<b>MIRAS (SMOS)</b> Microwave Imaging Radiometer using Aperture Synthesis (ESA)	SMOS – Soil Moisture and Ocean Salinity (Earth Explorer Opportunity Mission) (2009-2017)	33-50 km	MW (1-100 cm) L-Band (1,41 GHz)
<b>MODIS</b> MODerate-Resolution Imaging Spectroradiometer (NASA)	Terra - Terra (formerly EOS AM-1) (1999 - 2015) Aqua - Aqua (formerly EOS PM-1) (2002 - 2015)	250-1000 m	VIS - TIR: 0,4-14,4 $\mu\text{m}$ (36 pásem)
<b>PALSAR-2 (ALOS-2)</b> Phased Array type L-band Synthetic Aperture Radar-2 (JAXA)	ALOS-2 - Advanced Land Observing Satellite-2 (2014 - 2019)	1-10 m	MW (1-100 cm) L-Band (1,27 GHz)
<b>SAR (RADARSAT-2)</b> Synthetic Aperture Radar (CSA) C band (CSA)	RADARSAT-2 - RADARSAT-2 (2007 - 2015)	2,8-100 m	MW (1-100 cm) C-Band (5,405 GHz)
<b>SAR (RISAT)</b> Synthetic Aperature Radiometer (RISAT) (ISRO)	RISAT-1 – Radar Imaging Satellite (2012-2017) RISAT-1A – Radar Imaging Satellite (2019- 2023)	3-50 m	MW (1-100 cm) C-Band (5,35 GHz)
<b>TIRS</b> Thermal Infrared Sensor (USGS/NASA)	Landsat 8 - Landsat 8 (2013 - 2023)	100 m	TIR (6,0 $\mu\text{m}$ - 15,0 $\mu\text{m}$ )

Pozn.: Šedé jsou plánované nebo již schválené mise, Zdroj: Svobodová (2016).

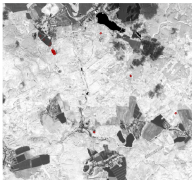
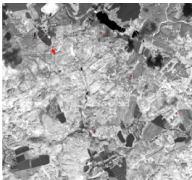
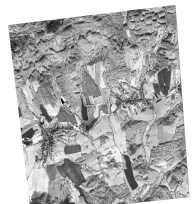
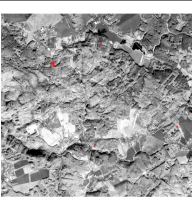
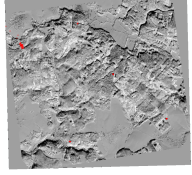
## 4 VLASTNÍ ŘEŠENÍ

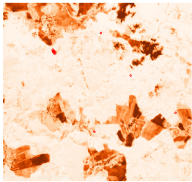
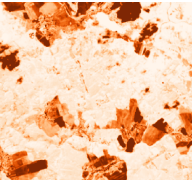
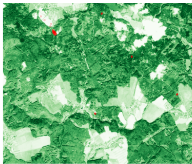
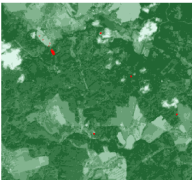
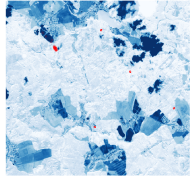
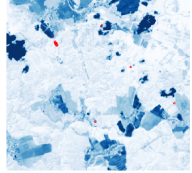
Výzkum použitelnosti zjištěných metod byl rozdělen do dvou částí. První část tvoří využití zájmových multispektrálních dat, na kterých byla posuzována vhodnost aplikace vybraných vegetačních indexů, které jsou na základě rešerše používány v pedologických analýzách pro odhad půdní vlhkosti a dalších charakteristik. Druhou významnější skupinu tvoří aplikace vybraných predikčních modelů na hyperspektrálních datech.

### 4.1 Použití multispektrálních dat

Seznam použitých indexů je k nahlédnutí již v kapitole 2.2.2. Tento seznam byl vytvořen na základě rešeršní části, která je popsána v kapitole 3. Výsledky a použitelnost jednotlivých indexů na zájmových datech je předložena tabulkou (Tab. 8) pod tímto textem.

Tab. 8 Použitelnost zájmových indexů na zájmových datech

Index	Senzor	Rozsah	Náhled	Korelační koeficient			
				$N_{tot}$	$C_{tot}$	pH/H <sub>2</sub> O	MKK
NDVI	Sentinel-2	0,853403 až -0,266833		0,37	0,35	0,07	0,18
	Landsat-8	0,547226 až -0,105358		0,54	0,33	0,15	0,21
	WorldView-2	0,995495 až -0,998919		NA	NA	NA	NA
	SPOT-6	0,55903 až -0,502674		NA	NA	NA	NA
	Pleiades-1A	0,498208 až -0,619238		NA	NA	NA	NA

Index	Senzor	Rozsah	Náhled	Korelační koeficient			
				N <sub>tot</sub>	C <sub>tot</sub>	pH/H <sub>2</sub> O	MKK
COI	Sentinel-2	61,23 až 4705		-0,35	-0,47	0,12	-0,11
	Landsat-8	4609,7 až 15322		-0,32	-0,32	0,03	-0,16
OMI	Sentinel-2	$3,55 \times 10^{-7}$ až $-2,77 \times 10^{-6}$		0,15	0,43	-0,21	0,15
	Landsat-8	$1 \times 10^{-8}$ až $2,26 \times 10^{-8}$		0,30	0,31	-0,02	0,14
NBI	Sentinel-2	-410 až -262		0,30	0,43	-0,10	0,16
	Landsat-8	-781,5 až -681,9		0,33	0,32	-0,01	0,16

Pozn.: NA – neznámé hodnoty z důvodu chybějících referenčních dat

Počítání NDVI se u systémů Sentinel-2 a Landsat-8 nesetkalo s většími problémy a je tedy možné je pro hodnocení půdy tímto indexem bez problému použít. U WorldView-2 se již vyskytly určité nejasnosti. Tento systém obsahuje dvě NIR pásma, přičemž Wolf (2010) uvádí, že pro výpočet NDVI je vhodné použít pásmo NIR2. Výsledky s tímto pásmem jsou uvedeny i v předchozí tabulce. Nicméně NDVI vypočítané tímto způsobem vykazovalo některé nesrovnalosti jako například, že holé orné půdy nabývaly záporných hodnot. Lépe už vycházely výsledky s pásmem NIR1. Snímek ze systému SPOT 6 obsahuje větší množství stínů v okolí lesních porostů, které způsobují záporné hodnoty. Poslední snímek pořízený systémem Pleiades-1A byl již po vizuální stránce při zobrazení v pravých barvách (RGB) velmi zvláštní. Po výpočtu NDVI na tomto snímku byly výsledné hodnoty i některých oblastí s vegetací záporné nebo blízké nule.

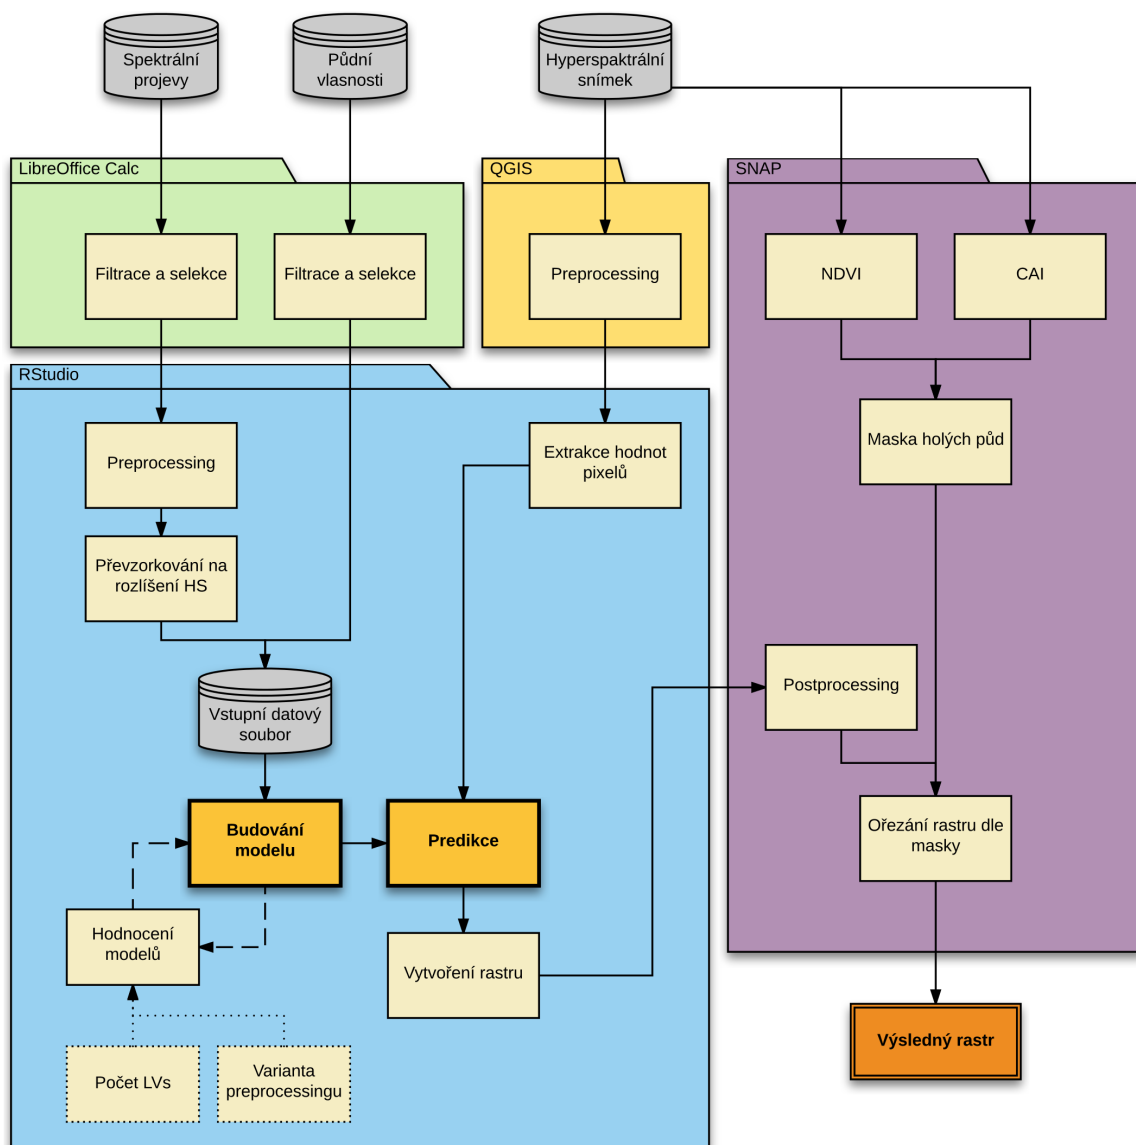
Další indexy byly počítány jen pro systémy Sentinel-2 a Landsat-8, protože ostatní zájmová data neobsahovala potřebná pásma. Výpočet musel být mírně poupraven, jelikož autoři těchto indexů měli k dispozici snímky z Landsat-7 pro suché a vlhké období. V této práci bylo nutné vybrat odpovídající pásma dle spektrálního rozsahu a nakonec využít pásma jen z jednoho snímku bez ohledu na vlhkostní poměry. Výsledné hodnoty těchto indexů jsou hůře interpretovatelné, protože jejich autoři ve své studii nepředstavili návod na jejich interpretaci. Lze tedy hodnotit pouze vizuální stránku, porovnání jednotlivých oblastí mezi sebou a případnou korelaci. Výsledky těchto indexů u Sentinelu-2 je zapotřebí brát s rezervou, neboť spektrální pásma u tohoto systému jsou mírně posunutá oproti systému Landsat.

Dále bylo zjišťováno, zda existují významnější korelace mezi hodnotami pixelů získaných aplikací spektrálních indexů a hodnotami půdních vlastností. Pro zajištění určité relevance byly korelace počítány pouze pro data ze systémů Landsat-8 a Sentinel-2, protože pro všechny půdní vlastnosti byla dostupná data pouze k říjnu 2016, k čemu měly nejbližší právě zmiňované snímky pořízené 30. 9. 2016. Pro tyto korelace mohl být datový soubor rozšířen, neboť bylo možné zahrnout i ty vzorky, u kterých nebyly k dispozici informace o spektrálním chování z ručního spektrometru. Výsledný datový soubor pro korelace měl tedy 45 vzorků. Z uvedených hodnot korelačního koeficientu vidíme, že v případě NDVI vykazují mírnou závislost hodnoty celkového dusíku s hodnotami získanými z Landsat-8. Korelace s ostatními půdními vlastnostmi nebo se systémem Sentinel-2 byly nízké. Index COI pro určení barvy a textury ukázal mírnou negativní korelaci mezi indexem vypočítaným ze systému Sentinel-2 a celkovým uhlíkem. U indexu COI vidíme, že až na aktivní půdní reakci dochází k negativním korelacím u všech půdních vlastností. Mírná pozitivní korelace (0,43) byla zjištěna také mezi indexem pro hodnocení organické půdní hmoty (OMI) vypočítaným na datech Sentinel-2 a obsahem celkového uhlíku. Index pro určení půdní vlhkosti (NBI) ukázal mírnou korelaci s hodnotami snímku Sentinel-2 a s naměřenými hodnotami celkového uhlíku. Ostatní hodnoty byly nízké nebo téměř nulové.

## **4.2 Použití hyperspektrálních dat**

Z rešeršní části vyplynulo, že metodou s nejlepšími predikčními schopnostmi pro spektroskopické analýzy půd je metoda PLSR (Partial Least Square Regression). Princip této metody je blíže popsán v kapitole 2.2.1.

Pro vybudování modelu bylo zapotřebí zajistit dvě různé datové sady. První, popisující hodnoty půdních vlastností a druhou, obsahující informace o spektrálním chování jednotlivých odběrných míst. Datové sady musely být předzpracovány pro přímou aplikaci. Po vybudování modelu na základě latentních proměnných došlo k predikci nových hodnot na hyperspektrálním snímku. Nový raster byl dále upraven pro názornější a logicky správnou vizualizaci. Na obrázku 4 je možné vidět schématický postup celého zpracování a predikce metodou PLSR. Jednotlivé kroky jsou dále rozepsány v následujícím textu.



Obr. 4 Schematické znázornění našeho postupu při predikci dat metodou PLSR

#### 4.2.1 Zpracování vstupních dat

Data obsahující informace o spektrálních projevech byla získána ve formě reflektance dle spektrálního rozsahu snímání použitého přístroje ve formátu \*.XLS. Každé místo (resp. půdní vzorek) bylo měřeno celkem třikrát. Na základě poznámek o přechodech vysoké oblačnosti během měření a grafické vizualizace spektrálních křivek bylo vybráno jediné měření pro další analýzy. Zapotřebí byla dále filtrace naměřených dat dle dostupnosti informací o jednotlivých půdních vlastnostech.

Druhá data byla získána také ve formátu \*.XLS a obsahovala informace o pedologickém šetření. Z této datové sady musely být pro nejlepší výsledky extrahovány pouze ty údaje, které jsou svým datem měření nejbližší k měření ručním spektrometrem. Byly vybrány tedy ta data, jež se vztahují k říjnu 2016. Další část filtrace proběhla za účelem zajištění konzistentnosti obou datových sad. Došlo ke smazání informací o odběrných místech, ke kterým nebyly dostupné spektrální informace.



Po tomto kroku byly určeny úplné informace o 22 odběrných místech. Výsledná datová sada byla tedy tvořena spektrálním chováním a hodnotami pH/H<sub>2</sub>O, C<sub>tot</sub>, N<sub>tot</sub> a objemovou půdní vlhkostí (MKK) (Tab. 9).

Tab. 9 Naměřené půdní vlastnosti u zájmových 22 vzorcích

	pH/H <sub>2</sub> O	C <sub>tot</sub> [%]	N <sub>tot</sub> [%]	MKK [%]
<b>Min</b>	4,750	0,160	0,1400	27,74
<b>1. kvartil</b>	5,133	1,421	0,1750	40,95
<b>Median</b>	5,350	1,683	0,1900	45,06
<b>Mean</b>	5,503	1,659	0,1889	43,50
<b>3. kvartil</b>	5,772	2,070	0,2000	47,30
<b>Max</b>	6,530	2,710	0,2450	50,72

Zdroj: UGP Mendelu Brno

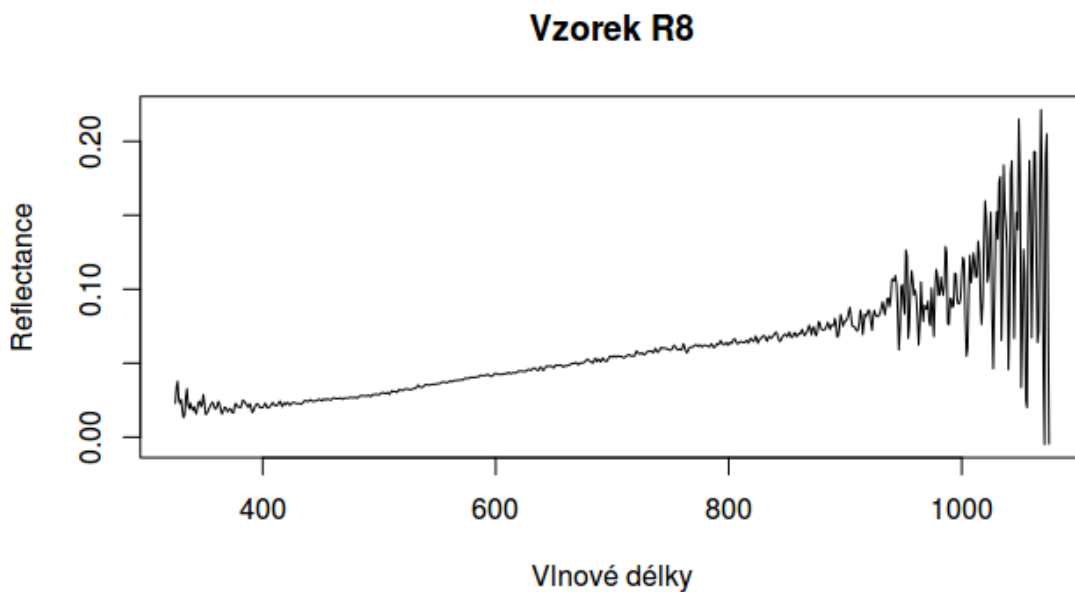
#### 4.2.2 Předzpracování spektrálních informací

Další klíčové fáze predikce probíhaly pomocí jazyka R v RStudios. Pro samotné načtení dat ve formátu \*.XLS bylo zapotřebí využít volně dostupného balíku *readxl*. Nové balíky se v jazyce R instalují a aktivují pomocí dvou jednoduchých příkazů (Kód 1).

```
install.packages("název balíku")
library(název balíku) (Kód 1).
```

Načtení proběhlo příkazem *read\_excel*, u kterého se volil parametr cesta k datům. V následující fázi je zapotřebí rozlišit dva souběžně jdoucí podobné kroky. Modely byly fitovány jak pro následnou predikci na konkrétním hyperspektrálním datasetu, tak pro případnou predikci na nových spektrálních datech, změřených stejným zařízením. Samotná predikce probíhala pouze na leteckých snímcích, ale pro testování použitelnosti a porovnání výsledků predikčních schopností obou variant došlo k budování modelu pro stejné zařízení.

V případě modelování pro spektrometr muselo dojít k odstranění dat vykazujících pouze šum. Tyto okrajové hodnoty spektrálního rozsahu se u jednotlivých přístrojů liší. V této práci byly hodnoty šumu stanoveny experimentálně na základě grafického znázornění naměřených spekter a rozhodnutí ještě podpořeno vědeckou prací Nawi et al. (2013), který odstraňoval u stejného přístroje hodnoty nižší než 600 nm a vyšší než 1000 nm nebo prací Lawrence (2015), který také odstraňoval hodnoty menší než 450 nm a větší než 950 nm. Na obrázku 5 je možné vidět naměřenou reflektanci na příkladu vzorku R08. I z tohoto grafu je patrné, že odrazivost do 400 nm a od 900 nm vykazuje šum. Hodnoty v těchto vlnových délkách byly tedy z importované datové sady odstraněny.



Obr. 5 Naměřená reflektance u vzorku R8

Pro námi využívanější modelování s hyperspektrálními daty bylo zapotřebí spektrálního převzorkování dle rozlišení hyperspektrálního snímku. Volně dostupný balík *prospectr* nabízí funkcí *resample2* převzorkování dle předem stanovených středů nových pásem a přesně stanovenou šířkou pásma (FWHM). Tyto informace byly extrahovány z hlavičky našich snímků a vloženy jako vektor do R. Příkladem aplikace funkce *resample2* je (Kód 2):

```
res ← resample2(samples[,10:760],as.numeric(colnames(samples[,
10:760])),b,fwhm) (Kód 2),
```

kde první parametr označuje zájmovou datovou sadu, druhý parametr původní středy pásem (v našem případě názvy sloupců v dataframe), třetí je vektor nových středů pásem a poslední značí šířku. Díky tomuto převzorkování, které bylo poměrně výrazné neboť šířka spektrálních pásem byla u části dat ze senzoru CASI okolo 14,2 nm a ze senzoru SASI 15 nm nebylo zapotřebí odstranění šumu ze spektrálních dat, protože takováto šíře pásem šum shladila.

### Varianty transformace naměřené reflektance

Po odstranění šumu nebo převzorkování bylo testováno několik variant transformace reflektance. Tyto varianty byly vybrány na základě rešeršní části a později byla zkoumána predikční schopnost u takto transformovaných hodnot. Během aplikace transformační metody byla zároveň data převedena na matici, kterou si žádá PLSR metoda jako vstup. Testované varianty transformace byly:

- 1) *Absorbance*, která vycházela ve studovaných pracích nejlépe.
- 2) *Savitzky-Golay smoothing*, což je metoda podléhající dalšímu nastavení jako velikost okna a řád polynomu.

- 3) *1. derivace*, která zvýrazní odchylky od trendu spektrální křivky.
- 4) *Standart normal variate*, které odstraní rozptyl a převede data na normální rozdělení.

Absorbance je ve své podstatě pouze logaritmus podílu reflektance. Což znamená, že pro tuto variantu nebylo v R zapotřebí použít speciální funkce a pro matici s názvem *res* byl použit jednoduchý příkaz (Kód 3):

```
res.abs<-I(as.matrix(log10(1/res)))
```

 (Kód 3).

Funkci pro Savitzky-Golay smoothing nabízí opět balík *prospectr*. Tato transformace byla použita jak samostatně, tak i společně s použitím první derivace nebo absorbance. Metoda je ve své podstatě upravenou metodou nejmenších čtverců. Do této metody vstupují dva parametry. Těmi je řád polynomu a velikost okna. Řád polynomu se používá pro aproximaci bodů, které spadají do velikosti zvoleného okna. Čím menší řád polynomu v porovnání s velikostí okna zvolíme, tím dojde k většímu vyhlazení dat (Savitzky a Golay, 1964). Na základně několika předchozích studií (Bogrekcí a Lee, 2005; Li et al., 2015) a charakteru našich dat byla pro naše účely zvolena varianta s velikostí okna 11 a 2. řádem polynomu. Ve funkci pro toto zpracování s názvem *savitzkyGolay* se nastavují čtyři parametry – datová sada, řád polynomu, velikost okna a případně derivace. Níže je k dispozici ukázka příkazu (Kód 4) pro variantu s 1. derivací.

```
res.sg.1d<-I(as.matrix(savitzkyGolay(res, p=2, w=11, m=1)))
```

 (Kód 4).

I pro poslední variantu transformace je v balíku *prospectr* jednoduchá funkce *standartNormalVariate*, do které vstupuje pouze jeden parametr a to datová sada.

Po modelování byla ovšem použita i samotná reflektance bez její úpravy. Celkem nám tedy do procesu budování modelů vstupovalo šest druhů spektrálních informací ke každému půdnímu vzorku.

### 4.2.3 Kalibrace a validace modelu

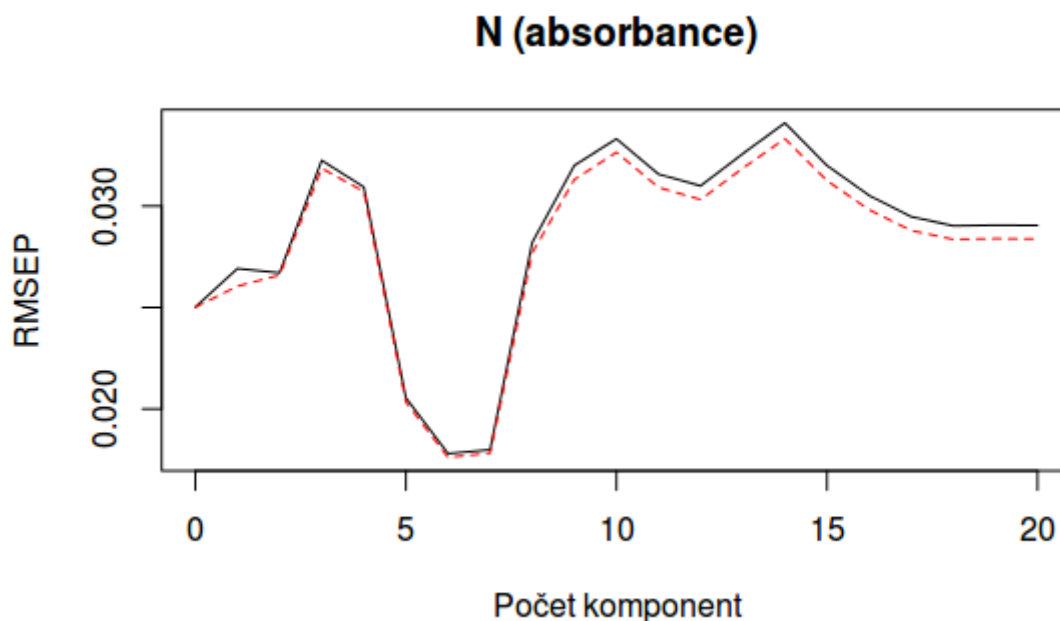
Nejklíčovější částí celého procesu bylo budování modelu. Tento celý proces probíhá iteračně. Dochází k fitování pomocí různého nastavení s různými parametry za účelem získání nejlepší predikční schopnosti daného modelu. Tato část procesu je velmi důležitá, neboť výsledné hodnoty jsou závislé na charakteru modelu. Přesnost predikce je závislá na kvalitě vstupních dat, kterou nelze často ovlivnit, a právě na kvalitě vybudovaného modelu. Variace pro budování modelu se v našem případě odvíjely od způsobu transformace spektrální informace a také od počtu latentních proměnných.

Po kalibraci se model dá validovat dvěma způsoby, které se ve většině případů používají souběžně. Prvním způsobem je křížová validace, kdy se ze vstupních dat vždy určitá část odstraní a testuje se, jak jsou zbylá data schopna tuto část predikovat. Druhou částí je validace pomocí testovacích dat. V praxi to funguje tak, že vstupní datový soubor je rozdělen na dvě datové sady – *trénovací* a *testovací*. Na trénovací datové sadě se model zkalibruje a provede se křížová validace, následně se vloží

testovací datová sada a zkoumá se s jakou přesností ji model popisuje. Doporučené rozdělení je na dvě a jednu třetinu.

V tomto výzkumu bylo zamýšleno využít výše uvedený standardní postup a na základě polohy odběrných míst bylo vybráno šest rovnoměrně rozložených vzorků, které budou tvořit testovací datovou sadu. 22 vzorků bylo tedy rozděleno na 16 (trénovací) a 6 (testovací). Bohužel při dalším postupu, jež je popsán níže, bylo zjištěno, že datová sada o 16 vzorcích je v našich podmínkách naprosto nedostatečná a nelze tak vytvořit žádný model vykazující alespoň minimální předpovědní schopnosti. Bylo zapotřebí použít pro budování modelu celou datovou sadu o 22 vzorcích, a tudíž byla pro validaci použita pouze metoda křížové validace.

Vzhledem k tomu, že vstupní datová sada není nikterak obsáhlá, bylo možné díky menší výpočetní náročnosti nevolit při budování modelu počet latentních proměnných. Dostupný algoritmus funkce *pls* z volně dostupného balíku *pls* je schopen vybudovat model s maximálním počtem latentních proměnných. Do predikce ovšem musí vstoupit už konkrétní hodnota. Volba počtu latentních proměnných je při použití metody PLSR velká otázka. Neexistuje žádný pevně stanovený postup pro toto určení, přičemž přidání/odebrání jen jedné latentní proměnné může mít za následek naprosto odlišné hodnoty predikce. Existují pouze určitá doporučení. Obecně přijímané doporučení je zobrazení grafu hodnot RMSEP (Root Mean Square Error of Prediction) pro všechny komponenty a následně vybrat počet s nejnižším RMSEP nebo s hodnotou, od které se RMSEP výrazně nesnižuje. Mevik a Wahrens (2016) toto doporučení ještě zpřesňují tvrzením, že je vhodnější vybrat ten počet komponent, které vykazují první lokální minimum RMSEP, nikoliv celkové minimum. V případě volby celkového minima dochází často k přefitování modelu. Pro zvolení příslušného počtu se využívá graf pro RMSEP (Obr. 6).



Obr. 6 Graf RMSEP nafitovaného modelu pro N a absorpenci

Na základě výše zobrazeného grafu můžeme vidět, že použití 6 komponent, při kterých dosáhneme nejnižší hodnoty RMSEP 0,0178, je pravděpodobně nejlepší volbou.

Použití nějaké varianty křížové validace není příkazem *pls* pro vybudování PLSR modelu vynuceno, ovšem bez této validace není možné zjistit hodnotu RMSEP, a tudíž určit nejlepší možný počet latentních proměnných. V tomto příkaze je navíc možné vybrat ze dvou variant křížové validace. První variantou je *CV (Cross Validation)*, kde je možné určit na jak velké segmenty chceme datový soubor pro validaci dělit. Druhá varianta je použití *LOO (Leave-one-out cross validation)*, která postupně z datového souboru skryje jednu hodnotu, otestuje kvalitu její predikce zbylými hodnotami, vrátí hodnotu zpět a vybere další. Tato druhá varianta byla použita i v našem modelování. Níže je vyobrazen příklad nařizování modelu pro N s variantou absorbance s využitím LOO validace (Kód 5).

```
N.res.abs ← pls(N ~ res.abs, data=soil.res, validation="LOO") (Kód 5).
```

Kromě zřejmých parametrů jako zvolení datové sady a varianty validace je možné v příkazu vidět ještě formuli  $X \sim Y$  (dle R terminologie), která nám určuje vstupní matice pro PLSR model. Jak již bylo zmíněno dříve, model PLSR je symetrický. To znamená, že nezáleží na pořadí obou matic při budování modelu. Jediným důvodem proč je zapotřebí dodržet určité pořadí je to, že při následné predikci se vždy nahradí datový soubor představující v tomto případě matici Y novými daty pro predikci příslušných hodnot v matici X.

Tabulka 10 zobrazuje charakteristiky modelů po nařizování s původními spektrálními informacemi, ze kterých byl odstraněn šum a nedocházelo k jinému spektrálnímu převzorkování.

Tab. 10 Hodnocení vytvořených modelů pro původní data ze spektrometru

	<b>Transformace</b>	<b>LVs</b>	<b>R<sup>2</sup></b>	<b>RMSEP</b>	<b>RPD</b>
<b>pH/H<sub>2</sub>O</b>	žádná	NA	NA	NA	NA
	Abs.	NA	NA	NA	NA
	Abs. + SG	NA	NA	NA	NA
	SG + 1. der.	NA	NA	NA	NA
	SG	NA	NA	NA	NA
	SNV	NA	NA	NA	NA
<b>C<sub>tot</sub> [%]</b>	žádná	NA	NA	NA	NA
	Abs.	7	0,1514	0,5277	1,0855466
	Abs. + SG	9	0,37899	0,4515	1,2689681
	SG + 1.der	5	0,12358	0,5363	1,0681786
	SG	NA	NA	NA	NA
	SNV	7	0,2101	0,5091	1,1251591

	<b>Transformace</b>	<b>LVs</b>	<b>R<sup>2</sup></b>	<b>RMSEP</b>	<b>RPD</b>
<b>N<sub>tot</sub> [%]</b>	žádná	4	0,355383	0,0195	1,2455155
	Abs.	6	0,30832	0,01986	1,2023956
	Abs. + SG	4	0,21129	0,02121	1,1260076
	SG + 1. der.	NA	NA	NA	NA
	SG	4	0,270442	0,0204	1,170766
	SNV	2	0,02170	0,02137	1,1173498
<b>MKK [%]</b>	žádná	NA	NA	NA	NA
	Abs.	NA	NA	NA	NA
	Abs. + SG	NA	NA	NA	NA
	SG + 1. der.	NA	NA	NA	NA
	SG	NA	NA	NA	NA
	SNV	NA	NA	NA	NA

Pozn.: Transformace – varianta předzpracování spektrální informace; LVs – počet latentních proměnných; R<sup>2</sup> – Koefficient deteminace; RMSEP – Střední kvadratická chyba predikce; RPD – Podíl predikční odchylky; Abs. - Absorbance; Abs. + SG – Absorbance se Savitzky-Golay smoothing; SG + 1.der – Savitzky-Golay smoothing s 1. derivací; SG – Savitzky-Golay smoothing; SNV – Standart Normal Variate; NA – nedostupné hodnoty díky negativnímu R<sup>2</sup> při použití jakéhokoli počtu komponent.

Tabulka 11 zobrazuje hodnocení modelů, které byly vybudovány pro predikci na konkrétním hyperspektrálním datasetu, u kterých tudíž došlo k převzorkování spektrální informace do rozlišení hyperspektrálních snímků.

Tab. 11 Hodnocení vytvořených modelů po převzorkování za účelem predikce na hyperspektrálních datech

	<b>Transformace</b>	<b>LVs</b>	<b>R<sup>2</sup></b>	<b>RMSEP</b>	<b>RPD</b>
<b>pH/H<sub>2</sub>O</b>	žádná	NA	NA	NA	NA
	Abs.	2	0,0229	0,4824	1,01165048
	Abs. + SG	2	0,0129	0,4849	1,00651308
	SG + 1. der.	NA	NA	NA	NA
	SG	NA	NA	NA	NA
	SNV	NA	NA	NA	NA
<b>C<sub>tot</sub> [%]</b>	žádná	NA	NA	NA	NA
	Abs.	NA	NA	NA	NA
	Abs. + SG	NA	NA	NA	NA
	SG + 1.der	NA	NA	NA	NA

	<b>Transformace</b>	<b>LVs</b>	<b>R<sup>2</sup></b>	<b>RMSEP</b>	<b>RPD</b>
	SG	NA	NA	NA	NA
	SNV	NA	NA	NA	NA
<b>N<sub>tot</sub> [%]</b>	žádná	6	0,0008726	0,02387	1,0004366
	Abs.	6	0,44454	0,0178	1,3417562
	Abs. + SG	5	0,23119	0,02094	1,1404874
	SG + 1. der.	9	0,05975	0,2355	1,0312842
	SG	5	0,33401	0,01949	1,2253669
	SNV	NA	NA	NA	NA
<b>MKK [%]</b>	žádná	NA	NA	NA	NA
	Abs.	NA	NA	NA	NA
	Abs. + SG	NA	NA	NA	NA
	SG + 1. der.	NA	NA	NA	NA
	SG	NA	NA	NA	NA
	SNV	NA	NA	NA	NA

Pozn.: Transformace – varianta předzpracování spektrální informace; LVs – počet latentních proměnných; R<sup>2</sup> – Koefficient deteminace; RMSEP – Střední kvadratická chyba predikce; RPD – Podíl predikční odchylky; Abs. - Absorbance; Abs. + SG – Absorbance se Savitzky-Golay smoothing; SG + 1.der – Savitzky-Golay smoothing s 1. derivací; SG – Savitzky-Golay smoothing; SNV – Standart Normal Variate; NA – nedostupné hodnoty díky negativnímu R<sup>2</sup> při použití jakéhokoli počtu komponent

Modely, u kterých není dostupná hodnota značí, že po křížové validaci hodnoty R<sup>2</sup> nabývaly záporných čísel. Tento statistický ukazatel popisuje kolik procent závislé proměnné je vysvětleno modelem a kolik jím zůstalo nevysvětleno (Dvořáček et al., 2014). Vzorec (14) pro výpočet koeficientu determinace (R<sup>2</sup>) je (Mevik a Wahrens, 2016):

$$R^2 = 1 - \frac{SSE}{SST} \quad (14),$$

přičemž SST je celkový součet čtverců odpovědi a SSE je celková chyba pro každou nařazenou hodnotu (reziduální součet čtverců). V této práci, kdy jsme dostali negativní hodnoty to znamená, že reziduální součet čtverců byl v určitých případech větší než celkový součet čtverců. Obecně z toho vyplývá, že dané modely PLSR nenalezly žádný vztah mezi hodnotou půdní vlastnosti a jejím naměřeným spektrálním chováním. Tuto skutečnost nám potvrdil i Dr. Thomas Möckel z Universität Kassel, který doporučil, aby tyto modely byly vyřazeny z dalšího zkoumání, protože by se zjednodušeně dalo říci, že byl vybudován pouze generátor náhodných čísel s nulovou predikční schopností.

#### 4.2.4 Predikce a vytvoření rastru

Před samotnou predikcí bylo zapotřebí posoudit jednotlivé možnosti importu hyperspektrálních snímků do prostředí R. Možnosti by se daly rozdělit do třech skupin.

První možnost je pomocí balíku *rgdal*. Tento balík pracuje s knihovnou GDAL pro zpracování rastrových dat a je základem pro správné fungování většiny balíků do R pracujících s datovou strukturou raster s geografickou lokalizací. Na druhou stranu i on sám umí načíst snímky. Zde je potřeba zmínit, že veškeré proměnné uložené v prostředí R jsou ukládány na dočasnou paměť RAM, což znamená, že při rozsáhlejších analýzách a zpracování většího objemu dat může na standardním stolním počítači nebo notebooku dojít k zaplnění paměti a zamezení další práce. Import pomocí tohoto balíku vloží naše data právě do této paměti a pokud například disponujeme kapacitou 8 GB, je tento způsob načítání značně nevhodný.


Dalším způsobem je import rastru pouze virtuálně. Znamená to, že v prostředí R (resp. RStudio), a tudíž v dočasné paměti, je uložena pouze struktura daného rastru s odkazem na uložení na pevném disku. Tuto možnost nabízí více balíků.

V práci bylo testováno použití balíků *HyperSpec* a *hsdar*, které byly vytvořeny právě pro práci s hyperspektrálními daty. Načítání snímků pomocí těchto balíků je ovšem komplexnější, neboť je umožněno volit více parametrů včetně zvolení předdefinovaného senzoru. Senzor, pomocí kterého byla snímána naše data, nebyl v nabídce bohužel dostupný. Pro tuto konkrétní práci bylo tedy rozhodnuto, že využití těchto nástrojů je až příliš sofistikované a pro náš výzkum je dostačující využití balíku *raster*. Tento balík obsahuje vícero funkcí pro import rastru. My jsme využili funkci *stack* (Kód 6), která je určena pro snímky s vícero pásmy.

```
image ← stack("data/hyperspektral/fuse_1.tif") (Kód 6).
```

Zde je zapotřebí zdůraznit, že dodaný snímek obsahoval pixely s hodnotou 0 v okrajích snímku (Obr. 7). Černou barvou jsou na snímku níže zobrazeny právě nulové hodnoty.





Obr. 7 Hyperspektrální snímek ze senzoru SASI v zobrazení Red: band 9, Green: band 40, Blue: band 67

Při modelování metodou PLSR vstupují do predikce bohužel i tyto hodnoty. Bylo tedy zapotřebí změnit tyto hodnoty na *NoData*. Toto bylo zajištěno GDAL příkazem, jež je možné vidět níže. Příkazem (Kód 7) bylo změněno celkem 385 595 pixelů, což tvoří 36 % dodaných dat.

```
gdal_translate -a_nodata 0 -of Gtiff $input $output (Kód 7).
```

Po načtení dat do R bylo nutné odstranění těch pásem z hyperspektrálního snímku, jejichž hodnoty již nejsou dostupné v převzorkované spektrální informaci z ručního spektrometru. Data, na kterých probíhá samotná predikce, musí mít naprosto totožný rozsah a formu jako data, na kterých byl model budován. V našem případě se jednalo především o rozsah (počet spektrálních pásem) a formu, ve které byly data vložena do formulí v *pls* funkci. Funkcí *dropLayer* byla odstraněna pásma se středem v hodnotě 1062,5 nm a více. Z údajů v tabulce 1 z kapitoly 2.1.1 je patrné, že v zájmové predikci

stačí použít pouze data ze senzoru CASI s rozsahem 380-1050 nm. Následně byly hodnoty uloženého rastru extrahovány do matice.

Předchozími kroky byla získána matice nových údajů o spektrálním chování snímaného povrchu. Tato matice tvoří novou logickou matici X, která je vkládána do modelu pro predikci nových hodnot v matici Y.

```
pre ← predict(N.res.abs, val, ncomp=7) (Kód 8).
```

Do samotné funkce *predict* vstupují tři hlavní parametry (Kód 8). Těmi jsou vybudovaný model, nové hodnoty pro matici X a počet komponent pro predikci extrahovaný dle textu v kapitole 4.2.3. V případě, že není vyplněn údaj o počtu komponent, algoritmus využije maximální možný počet komponent využitý při budování modelu.

Výsledné predikované hodnoty z proměnné *pre* byly následně vloženy do původního rastru pro zachování naprosto totožné struktury. Před samotným exportem byla odstraněna všechna pásma kromě prvního, protože stejné predikované údaje byly vloženy do všech pásem.

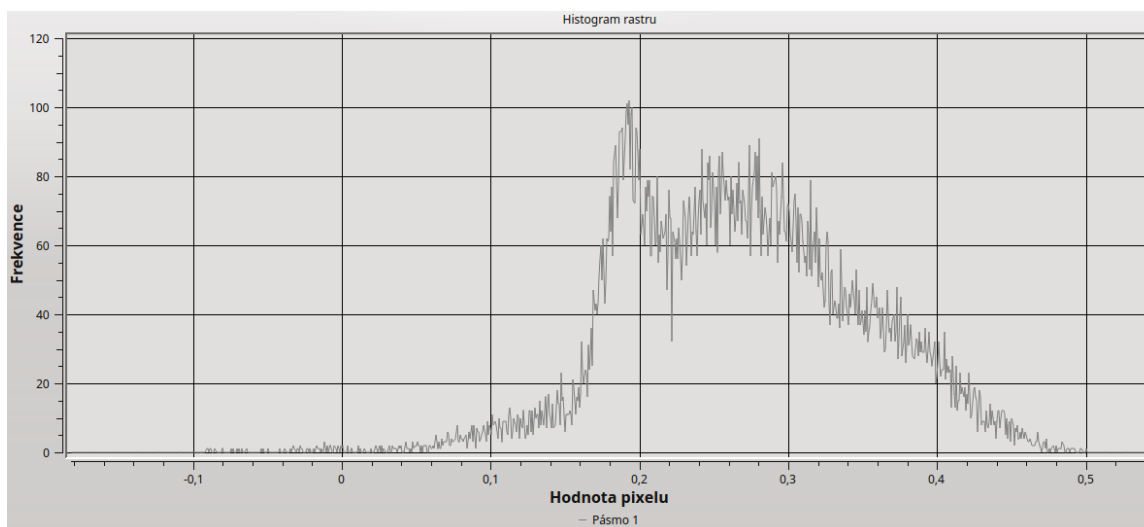
Posledním krokem zpracování v R byl samotný export do formátu \*.TIF, který proběhl tímto jednoduchým příkazem (Kód 9):

```
writeRaster(im, filename="N_abs.tif", format="GTiff",  
overwrite=TRUE) (Kód 9).
```

#### 4.2.5 Určení holé půdy

Posledním krokem pro přípravu samotné vizualizace predikovaných hodnot půdních vlastností bylo odstranění pixelů z nového rastru, které logicky neodpovídají možným hodnotám půdních vlastností a také určení holé půdy, pro kterou by měly být výsledné údaje korespondující. Tato finální část analýzy probíhala v softwaru SNAP.

Exportovaný raster pro celkový dusík vykazoval také určité množství záporných hodnot (Obr. 8, Tab. 12). Jedná se o logicky nemožnou hodnotu, neboť zkoumané veličiny nemohou nabývat negativních čísel. Tyto pixely byly odstraněny pro zachování pouze té části snímku s relevantními údaji.



Obr. 8 Histogram rastru s predikovanými hodnotami N


Tab. 12 Množství pixelů se zápornou hodnotou

<b>Model</b>	<b>Počet záporných pixelů</b>	<b>Poměr záporných pixelů [%]</b>	<b>Plocha se zápornými pixely [m<sup>2</sup>]</b>
N.abs	1255	0,17	7 845,75

Pozn.: N.abs – model pro N s variantou předzpracování spekter Absorbance

Maska pro učení holé půdy byla vytvořena pomocí indexů NDVI (Normalized Difference Vegetation Index) a CAI (Cellulose Absorption Index). Dle Daughtry et al. (2001) se jedná o jeden z nejspolehlivějších způsobů pro určení holé půdy. Největším problémem využití těchto indexů je určení prahové hodnoty pro stanovení zájmové lokality nebo kategorie. Ačkoliv existují určité konvenční kategorizování, pro přesnější odhad je zapotřebí využít experimentálních postupů a znalostí operátora.

Princip indexu NDVI byl již popsán dříve v této práci. Pro stanovení NDVI indexu z hyperspektrálních snímků se využívá vlnových délek 800 nm pro pásmo NIR, kde je zvýšená odrazivost vegetace a 670 nm pro pásmo RED (Haboudane et al., 2004). Hodnoty indexu NDVI vypočítaného z hyperspektrálních dat se pohybovaly od -0,247 do 0,82. Záporné hodnoty by měly znamenat nepropustné povrchy, čili umělé povrchy jako komunikace nebo stavby. Hodnoty blížíci se k 1 zase povrchy s vysokým množstvím chlorofylu, tedy hustou zelenou vegetací. Pro odstranění obou těchto extrémů muselo být využito dvou masek. Experimentálním způsobem bylo určeno, že první kategorie spadá do rozsahu -0,247 až 0,08 a druhá kategorie do rozmezí 0,3 až 0,82. Z vizuálního hlediska (Obr. 9) je patrné, že volbou těchto prahových hodnot byly vybrány téměř všechny louky, lesy a jiné povrchy s vegetací a zároveň také téměř veškeré komunikace. Zůstaly pouze některé komunikace a také větší množství budov.




Obr. 9 NDVI maska (odstínem červené jsou ty hodnoty, které nepředstavují holou půdu)

Index CAI je obecně využíván pro určení zdravotního stavu vegetace na základě obsahu celulózy. Gerighausen et al. (2015) používali index CAI pro určení orné půdy která byla pokryta vegetací. Index byl vyvinut pro hyperspektrální data a pracuje s vlnovými délkami 2000, 2100 a 2200 nm. Jeho předpis je (15) (Nagler et al., 2000):

$$CAI = \frac{R_{2000} + R_{2100}}{2} - R_{2200} \quad (15).$$

Vzhledem k tomu, že náš hyperspektrální dataset byl pořízen v listopadu až po agronomické sezóně, byla většina povrchu tvořícího ornou půdu bez viditelného vegetačního pokryvu. Na základě této skutečnosti bylo možné využití indexu CAI v této práci opačným způsobem než ve výše uvedené studii. Pomocí něj byly extrahovány další nepropustné povrchy s nulovým obsahem vegetace. Tímto indexem byl tedy doplněn index předchozí a určeny pixely zobrazující zbývající umělý povrch jako je komunikace a převážně budovy. Aplikace CAI indexu určila hodnoty od -1,281 až do extrémní 13.348. Hodnoty tohoto indexu stoupají lineárně od povrchu s 0% vegetací po 100%

pokrytí. Pomocí experimentálně-vizuálních metod byl určen rozsah -1,281 až -0,02 určující hledané nepropustné povrchy (Obr. 10).



Obr. 10: CAI maska (odstínem červené jsou ty hodnoty, které představují další nepropustné povrchy)

Obě výše popsané masky byly vytvářeny v softwaru SNAP, který nabízí funkci pro výpočet NDVI a také nabízí možnost napsání vlastního výpočtu. Problémem je, že daný program vytvoří masku s hodnotami 0 a 255, nikoliv dle konvenčních zvyklostí 0 a 1. Pro další zpracování bylo nutné převést hodnoty dle zvyklostí. Toto bylo zajištěno ve stejném softwaru tímto příkazem (Kód 10):

```
if CAI_mask == 255 then 1 else 0 (Kód 10).
```

Takto převedené hodnoty se bohužel uchovají jen ve zmiňovaném softwaru a po importu například do QGISu dostáváme opět hodnoty 0 a 255. Obě masky byly následně pomocí mapové algebry spojeny do jednoho souboru (Obr. 11) a aplikovány na rastr s predikovanými hodnotami.



Obr. 11: Výsledná maska zobrazující holou půdu (bílá - holá půda, černá - ostatní)

Na obrázku 11 je možné postřehnout, že některé struktury označené jako holé půdy mají pravidelnější tvar, a tudíž se pravděpodobně nejedná o holou půdu. Jak již bylo zmiňováno, určování této zájmové masky je závislé na znalostech operátora a na experimentálním posuzování za účelem určení stanovené prahové hodnoty. Na základě tohoto faktu je jasné, že nikdy není možné dosáhnout 100% výsledků při tomto druhu analýz. Je zapotřebí si uvědomit, že maska bude vždy vykazovat určitou míru nejistoty. Tabulka 12 zobrazuje základní charakteristiku zájmové masky.

Tab. 13 Základní charakteristika zájmové masky

<b>Snímek</b>	<b>Celkový počet pixelů</b>	<b>Poměr pixelů [%]</b>
Původní snímek	1 069 757	100
Odstraněná plocha pomocí NDVI	866 543	81
Odstraněná plocha pomocí CAI	8749	0,8
Celková odstraněná plocha	871 629	81,5
<b>Zájmová plocha</b>	<b>198 128</b>	<b>18,5</b>

Pozn.: Odstraněná plocha pomocí NDVI: -0,247 až 0,08 a 0,3 až 0,82, Odstraněná plocha pomocí CAI: -1,281 až -0,02

Z předchozí tabulky je možné vyčíst, že naše zájmová plocha se smrskla pouze na 18,5 % snímků. Nutno ovšem podotknout, že do původních 100 % byla zahrnuta i oblast s hodnotou 0 na snímku. Dále může být lehce matoucí, že po sečtení plochy odstraněné pomocí NDVI a plochy odstraněné pomocí CAI dostáváme 81,8 %, nikoliv 81,5 % jak je uvedeno v tabulce. Tato skutečnost je způsobena tím, že určitá část plochy byly zahrnuta v obou indexech.

## 5 VÝSLEDKY

V této práci byly posuzovány možnosti multispektrálních snímků a metody PLSR na konkrétních zájmových hyperspektrálních datech pro určování půdních vlastností. U multispektrálních snímků byla především zkoumána použitelnost zájmových spektrálních indexů, které byly zjištěny rešeršní částí jako vhodné. Pro použití metody PLSR bylo testováno několik způsobů předzpracování pro dosažení nejlepších výsledků. I přes četné varianty předzpracování a fitování modelů různými způsoby nebylo dosaženo potřebných výsledků. Tyto hodnoty se poměrně výrazně lišily při volbě varianty bez převzorkování spekter a tedy variantu budování modelu pro případná nová data ze spektrometru, nebo variantu s převzorkovanými spektry pro budování modelu pro predikci na zájmových hyperspektrálních datech. V práci bylo cílem stanovení použitelnosti pro predikci čtyřech půdních vlastností. Bohužel bylo zjištěno, že s našimi zájmovými daty není možné dosáhnout lepších výsledků, a tudíž kvalitní predikce pro všechny vlastnosti.

### 5.1 Výsledky analýz s multispektrálními snímky

Tabulka s výsledky a komentářem o použitelnosti vybraných spektrálních indexů na zájmových datech je k dispozici v kapitole 4.1. Už během rešeršní části bylo zjištěno, že spektrální indexy se sice používají, ale pro komplexní hodnocení půdních charakteristik, nikoliv jednotlivých půdních vlastností jak bylo cílem této práce. Spektrální indexy mají velké využití především ve vegetačních analýzách. Pro půdní analýzy je zapotřebí si uvědomit půdní procesy a vlastnosti jako celek a na základě toho určovat například kvalitu půdy obecně.

Použitelnost zájmových indexů na našich multispektrálních snímcích nebyla shledána nikterak velká. To také z toho důvodu, že chybělo určité spektrální pásmo, které je nutné použít pro vytvoření daného spektrálního indexu nebo nebyla dostupná samotná interpretace výsledků jednotlivých indexů. S indexy byly počítány korelace pro jednotlivé půdní vlastnosti. Z důvodu toho, že všechny informace o hodnotách půdních vlastností byly k dispozici pouze pro říjen 2016, byly korelace počítány pouze pro data Sentinel-2 a data Landsat-8, jež byly svým datem pořízení nejbliže. Samotné korelace nenabývaly vysokých hodnot. Rozdíly byly také při použití snímků z různých senzorů. Bylo zjištěno, že obsah půdního dusíku mírně koreluje s indexem NDVI, přičemž lepších výsledků bylo dosaženo systémem Landsat-8. Dalším zajímavým poznatkem je mírná negativní korelace půdního uhlíku a indexem COI určující texturu a barvu půdy. Podobných hodnot pro půdní uhlík bylo dosaženo i u indexu NBI určující půdní vlhkost. Index pro hodnocení organické půdní hmoty (OMI) vykazoval mírnou korelaci právě s předpokládanými hodnotami celkového půdního uhlíku. Korelace pro indexy COI, NBI a OMI vycházely lépe pro data ze Sentinel-2. Pro všechna zájmová data a indexy nebyla nalezena významnější korelace s aktivní půdní reakcí a půdní vlhkostí.

Obecně se ovšem dá říct, že některá multispektrální data, která byla použita i v této práci mají velký potenciál pro komplexní hodnocení půd. Na druhou stranu dostáváme často pouze hrubý odhad půdních vlastností, neboť téměř žádný index nám vybrané vlastnosti neurčuje přímo. Zájmové půdní vlastnosti lze určovat převážně na základě korelací s půdní vlhkostí, mezi sebou navzájem a popř. dalších charakteristik vstupujících do pedologických procesů. Dále je nutné brát v potaz nejenom spektrální



rozlišení, ale také rozlišení prostorové. Tato charakteristika je také odpovědná za hodnocení výsledné použitelnosti v konkrétních případech. Ze zájmových multispektrálních snímků vychází nejlepší použitelnost dat ze senzorů Sentinel-2 nebo Landsat-8. Toto je způsobeno především tím, že množství spektrálních pásem umožňuje použití pro větší množství indexů.

## 5.2 Výsledky analýz pomocí PLSR metody

Jak je vidět v tabulkách 10 a 11 nebylo možné predikovat, resp. alespoň vybudovat, model s nějakou predikční schopností pro všechny prvky. Použitelné vybudované modely s variantou pro data ze spektrometru byly pouze pro celkový uhlík a celkový dusík. U ostatních dvou vlastností nebyl nalezen žádný vztah mezi jejich hodnotou a spektrálním chováním. Pro celkový uhlík vyšla nejlépe varianta absorbance se Savitzky-Golay Smoothing s použitím 9 komponent. Pro tento model bylo dosaženo koeficientu determinace ( $R^2$ ) 0,38, RMSEP 0,4515 a RPD 1,08. Pro celkový dusík nejlépe vyšel model s použitím 4 komponent a čisté reflektance ( $R^2$  0,36; RMSEP 0,0195 a RPD 1,25). Ostatní varianty pro oba prvky vyšly s nižší predikční schopností.

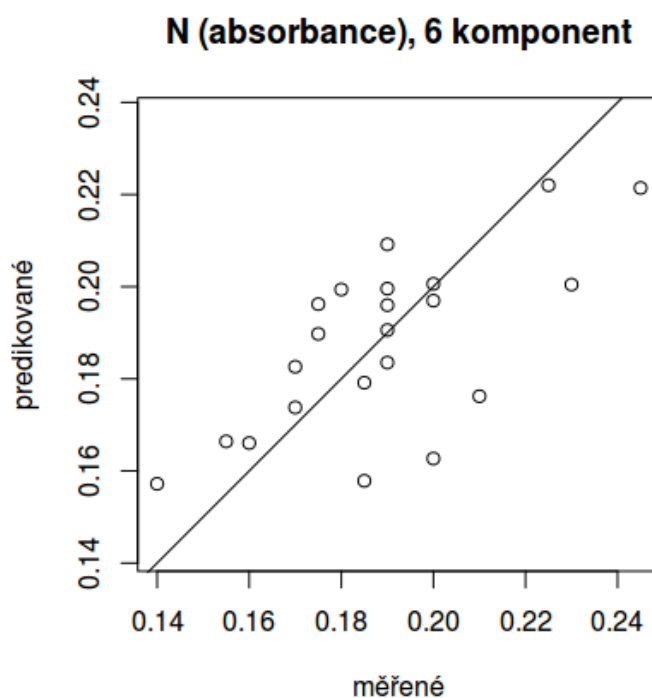
Studie byla především zaměřena na predikci z hyperspektrálních snímků, u kterých byla zjištěna schopnost predikce pouze pro aktivní půdní reakci a celkový dusík. Během budování modelů pro ostatní prvky nebyl zjištěn žádný vztah, a proto byly vypuštěny pro další zkoumání.

U aktivní půdní reakce byl sice nalezen určitý vztah mezi její hodnotou a spektrálním chováním, ale tento vztah byl tak zanedbatelný, že po zjištění  $R^2$  0,0229 u varianty s absorbancí a  $R^2$  0,0129 u varianty absorbance s 1. derivací bylo rozhodnuto se dále nevěnovat ani této veličině. Potenciální výsledky by měly asi 1% nebo 2% predikční schopnost, což znamená, že by nebylo dosaženo žádných relevantních hodnot. Predikční modely pro celkový dusík dosahovaly v některých případech lepších výsledků. U modelů s dusíkem nebyl nalezen vztah pouze s variantou Standart Normal Variate.

### 5.2.1 Nejlepší model

Celkově nejlepší výsledky byly zjištěny u modelu pro hyperspektrální data pro predikci celkového půdního uhlíku a opět u modelu s absorbancí a to  $R^2$  0,44; RMSEP 0,01 a RPD 1,34. Model vykazoval ze všech 48 vybudovaných modelů nejlepší predikční schopnost. Na tomto modelu byla také následně testována samotná aplikace a postup predikce metodou PLSR.

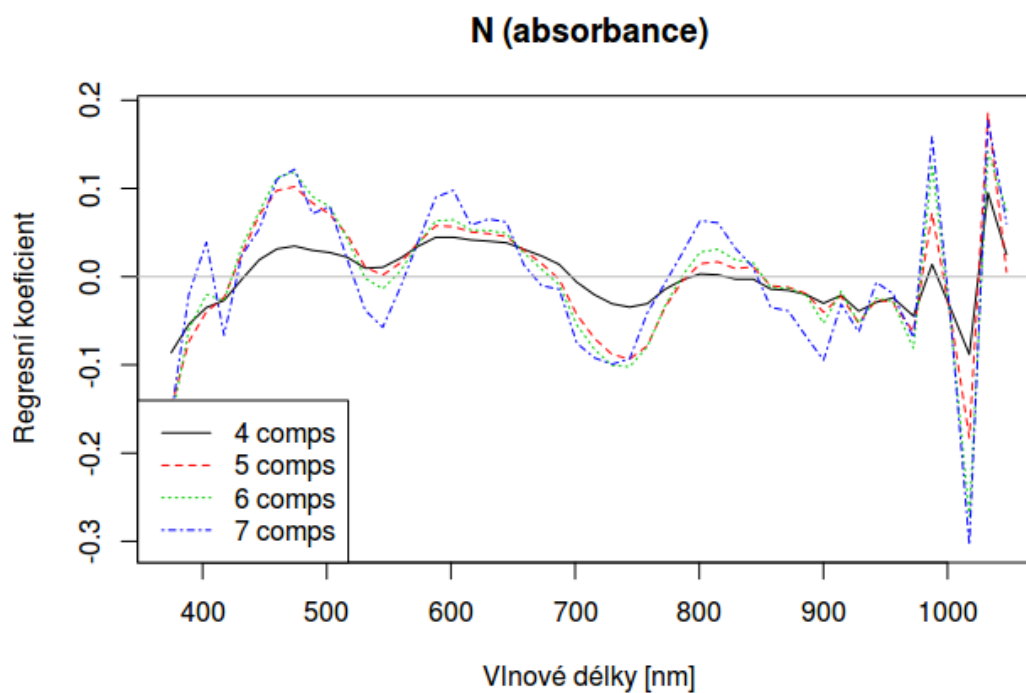
Vzhledem k tomu, že vstupní datový vzorek obsahoval pouze 22 vzorků byl maximální počet komponent okolo 20 v závislosti na předzpracování. Zde je důležité si povšimnout, že i pro náš nejlepší model bylo nutné použít 6 komponent, což tvoří asi třetinu všech možných. Už i tato skutečnost říká, že ani v tomto modelu nebyly nalezeny žádné jasné vztahy mezi oběma maticemi už při několika prvních komponentách. Toto ovšem není záležitost pouze zmiňovaného modelu, ale dalo by se říci, že to charakterizuje celý vstupní vzorek.



Obr. 12 Predikční graf modelu pro predikci N pomocí absorbance s použitím 6 komponent

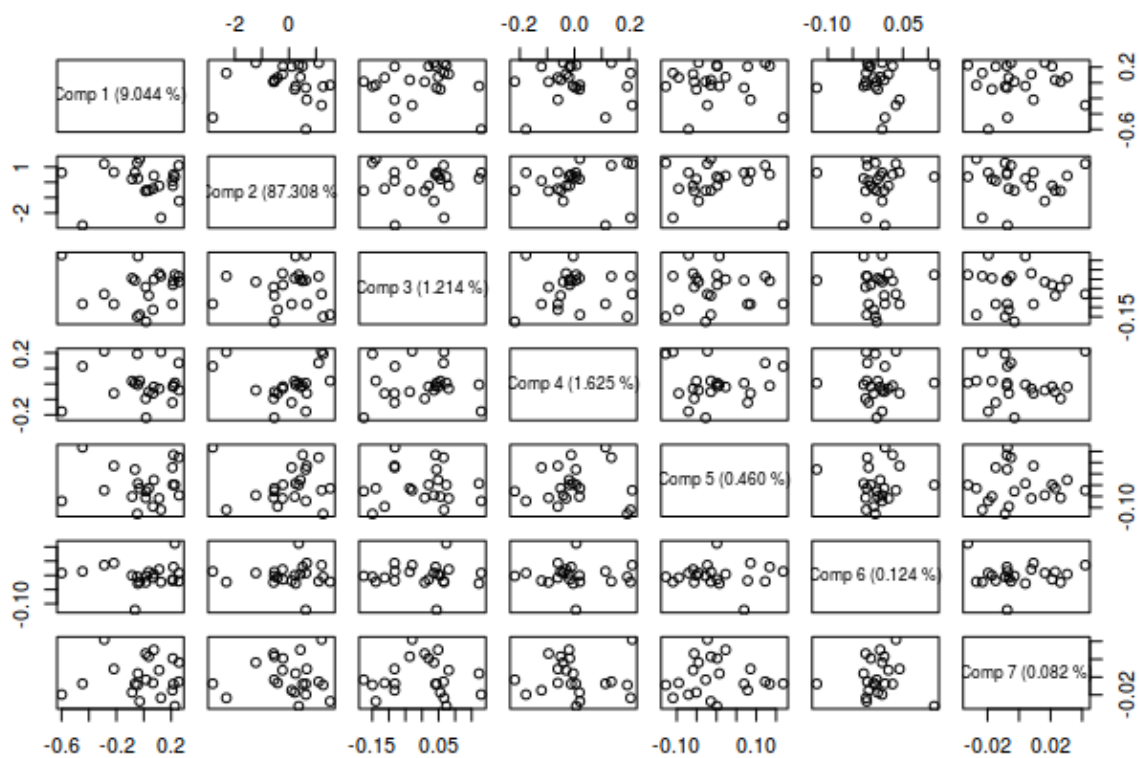
Obrázek 12 je grafem ukazujícím základní předpovědní schopnost. Jedná se o hodnoty zjištěné na základě křížové validace. Čím blíže jsou jednotlivé hodnoty ukloněné linii, tím lepší model byl dosažen. Graf zobrazuje výsledky pro nejlepší dosažený model s použitím 6 komponent.

Zobrazení regresních vektorů (Obr. 13) nám sice ukazuje, že například i použití 7 komponent predikci přispívá, ale tento příspěvek není nijak závratně velký a dle křížové validace (Obr. 6) je možné vidět, že dojde i k mírnému zhoršení predikční schopnosti. Použití 7 komponent by ale nebylo chybou. Jak již bylo zmiňováno v předchozích kapitolách, jedná se převážně o počet zjištěný experimentálním šetřením. V této práci bylo zvoleno pouze 6 komponent, aby nedošlo k přefitování modelu, a tudíž ke zvýšené míře šumu.



Obr. 13 Regresní koeficienty pro 4 až 7 komponent

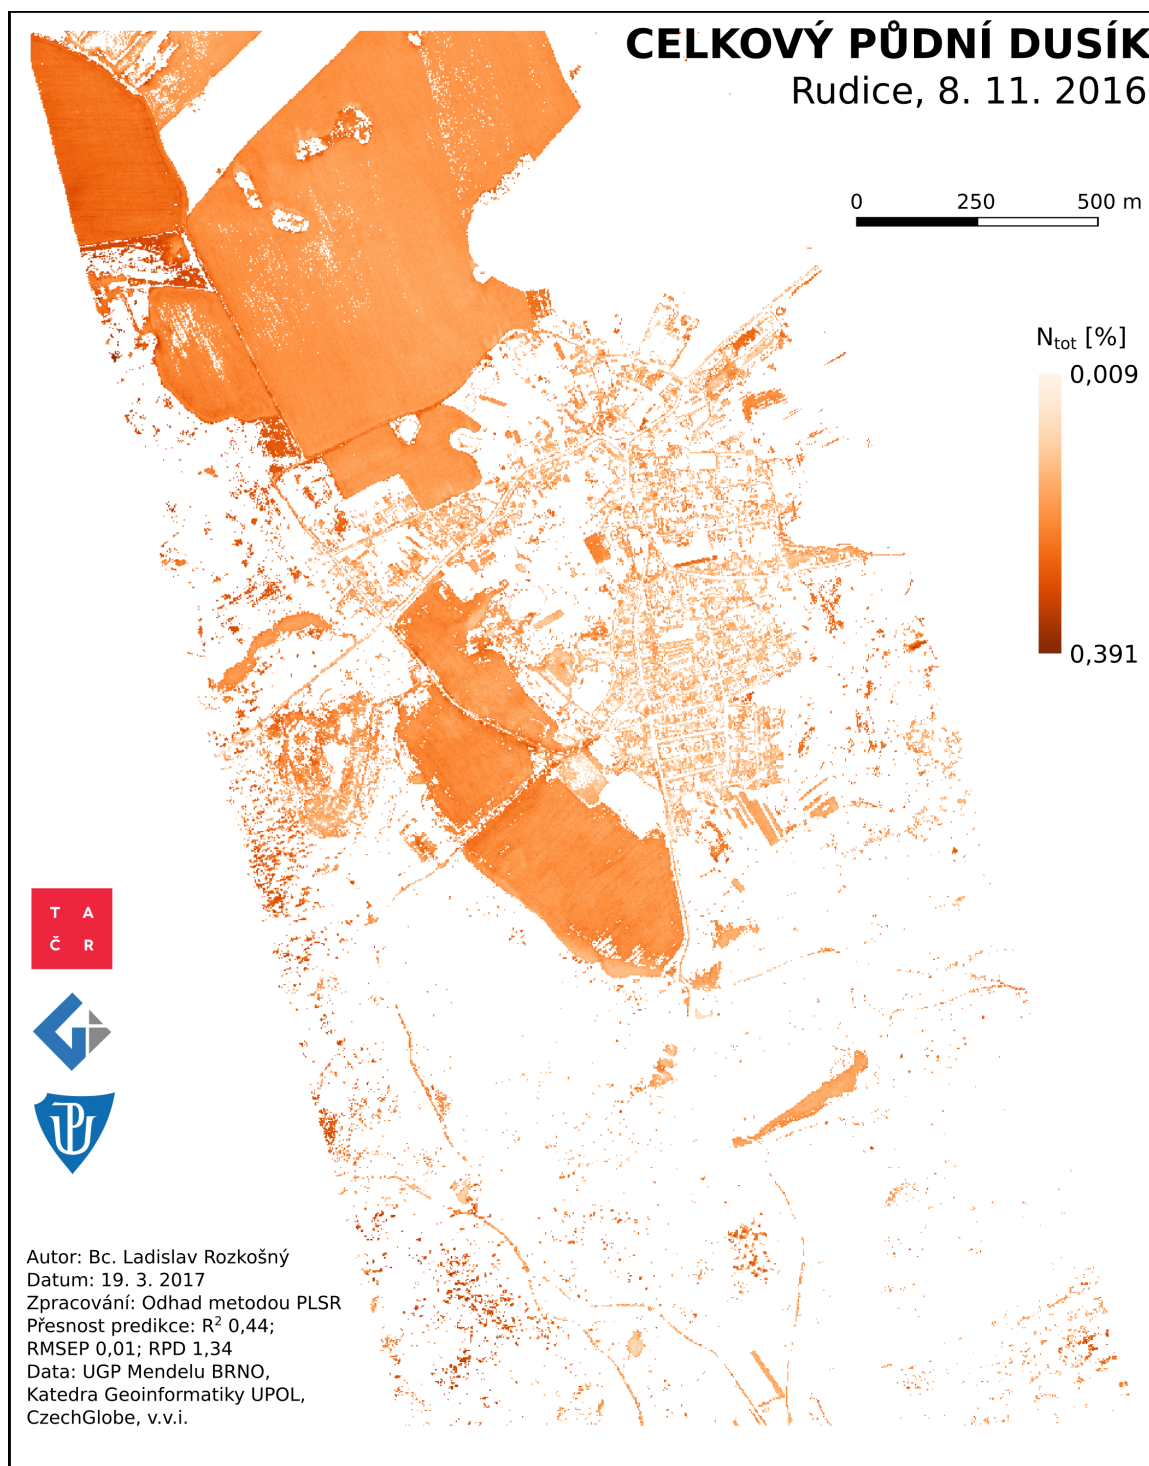
Skutečnost popsanou výše je možné ještě podpořit hodnotovým (scores) grafem (Obr. 14), který zobrazuje varianci dat, které tvoří hlavní komponenty (Dunn, 2016). Z grafu je možné vyčíst varianci dat mezi jednotlivými komponenty. Nejdůležitější komponentou, tvořící samotný model byla druhá komponenta, popisující data z 87 %. Toto je poměrně překvapivý výsledek, neboť u většiny modelů budovaných tímto způsobem je nejdůležitější komponentou právě komponenta první. Pro druhou část modelování a predikci je nejdůležitější komponenta šestá. Vizuálním hlediskem můžeme vidět, že hodnoty, které jsou popsány šestou komponentou jsou hodnoty s nejmenším rozptylem a až na dva outliery popisují data velmi dobře.



Obr. 14 Score plot nejlepšího modelu pro 1 až 7 komponent

### 5.2.2 Predikce

Finálním výsledkem predikce je raster ve formátu \*.TIF (Obr. 15). Tento raster obsahuje predikované hodnoty pro celkový půdní dusík. Tento raster je závěrem celé analýzy, na které bylo demonstrováno použití metody PLSR pro predikci půdních vlastností.



Obr. 15 Mapa výsledných predikovaných hodnot pro celkový půdní dusík

Výsledky predikce byly zpřesněny odstraněním několika záporných hodnot, které mohou vzniknout nízkou koncentrací nebo variabilitou zkoumaného prvku. Další zpřesnění proběhlo odstraněním těch pixelů, které představují povrch, pro který nebyl model budován, a tudíž výsledné hodnoty u těchto povrchů nemohou být relevantní. Z tabulky 14 je vidět, že predikované hodnoty nabývaly mírně vyšších koncentrací než hodnoty získané pedologickým měřením. Toto bylo pravděpodobně způsobeno obecně vyššími hodnotami reflektance na hyperspektrálních snímcích v porovnání s hodnotami, jež byly změřeny ručním spektrometrem.

Tab. 14 Porovnání základní charakteristiky naměřených a predikovaných hodnot

	<b>Naměřené <math>N_{tot}</math> [%]</b>	<b>Predikované <math>N_{tot}</math> [%]</b>
<b>Min</b>	0,1400	0,0035
<b>1. kvartil</b>	0,1750	0,1792
<b>Median</b>	0,1900	0,1942
<b>Mean</b>	0,1889	0,1989
<b>3. kvartil</b>	0,2000	0,2158
<b>Max</b>	0,2450	0,3912

Na obrázku 15 je také vidět, že vyšší koncentrace se objevovaly na severozápadě v oblasti, ze které nebylo dostupné žádné terénní měření. Můžeme tedy předpokládat, že vyšší hodnoty nebyly způsobeny jen kvalitou snímku, resp. dalšího měření, ale i tím, že tyto koncentrace se v dané oblasti mohou opravdu objevovat.

Pro určení nejpřesnějších a nejpoužívanějších metod a algoritmů byla provedena rozsáhlá rešerše. Byla provedena pro každou půdní vlastnost zvlášť, přičemž je nutné konstatovat, že v některých případech se metody stanovení a posouzení mezi jednotlivými prvky překrývaly. Zjištěné metody byly posuzovány z hlediska vhodnosti pro konkrétní aplikaci s konkrétními daty, přičemž použitelnost spektrálních indexů byla posuzována praktickým hlediskem a z druhé skupiny metod (statistické predikční modely) byla vybrána nejpoužívanější a to PLSR. Tato metoda byla následně aplikována pro predikci nových hodnot a její výsledky byly statisticky zhodnoceny. Samotné PLSR modelování bylo zhodnoceno jako použitelné pro predikci půdních vlastností na hyperspektrálních snímcích. Metoda je relativně jednoduše aplikovatelná se znalostí základních principů. Je potřeba říci, že v této práci vyšly výsledky i nejlepších modelů s poměrně nízkou predikční schopností. Dalo by se ale zmínit, že tento fakt nemusí znamenat špatné výsledky samotného PLSR modelování. Již dle rešerše je známo, že existuje množství parametrů, které mohly kvalitu výstupů snížit a to bez nutnosti posouzení kvality samotné metody. Parametry, jež snížily přesnost, jsou dále vysvětleny v kapitole Diskuse.

## 6 DISKUZE

Z vybraných multispektrálních snímků vykazovaly větší použitelnost snímky Landsat-8 a Sentinel-2, protože obsahují více spektrálních pásem což nabízí větší variabilitu. Výhodou těchto dat je bezplatné šíření. NDVI index neukázal předpokládané výsledky. Korelace s půdní vlhkostí, pro kterou se index také nepřímo používá vyšla velmi nízká. Naopak mírná korelace vyšla pro půdní dusík. Pro relevantnost těchto výsledků by bylo zapotřebí provést sérii stejných analýz a zjistit, zda se tento trend objevuje i na datech z jiného období. Je zapotřebí zmínit, že výsledky musely být ovlivněny prostorovým rozlišením jednotlivých snímků. Při prostorovém rozlišení například 10 m u Sentinel-2 nebo 30 m u Landsat-8 a zároveň blízkosti odběrných míst mezi sebou, ale také blízkosti povrchů s naprosto odlišným pokrytím jakým je například les, dostáváme tzv. *mixed pixels*, které svoji polohou sice pokrývají odběrné místo, ale jejich hodnota je průměrem pro všechny povrchy, jež jsou pixelem pokrývány. Tento fakt zákonitě musel ovlivnit výsledné hodnoty. Přesnost a kvalita by mohly být zvýšeny, pokud by odběrná místa byla lokalizována s ohledem na prostorové rozlišení zájmového senzoru.

Další tři zájmové indexy vyvinuté týmem Sylvain et al. (2012) nabízí velký potenciál. Autoři bohužel nenabídlí interpretační pravidla, a tudíž nelze posoudit kvalitu výstupů. Tyto indexy je zapotřebí dále zkoumat a vytvořit jednoznačná pravidla pro interpretaci a aplikovatelnost nejenom pro data Landsat-7, pro které byly původně vyvinuty. Je zapotřebí provést časovou sérii a konfrontovat ji s terénním průzkumem.

Použití metody PLSR bylo na základě předchozích studií ve velkém očekávání. Bohužel výsledné parametry a predikční schopnosti toto očekávání nenaplnily. Tato skutečnost ovšem nemusí znamenat pouze vyvrácení předchozích předpokladů a využitelnosti metody. Předchozí studie několikrát dokázaly, že touto metodou lze dosáhnout přesnosti vyšší než  $R^2$  0,8 (Vagen et al., 2006; Lu et al., 2013). Koeficient determinace u našeho nejlepšího PLSR modelu vyšel po křížové validaci 0,44, což značí, že tento model popisuje pouze ze 44 % data, ze kterých bych vytvořen. Možných vlivů a požadavků, které by mohly výslednou přesnost zlepšit existuje celá řada.

Jedním z velmi důležitých parametrů pro toto modelování je spektrální rozsah použitého spektrometru. Použitý přístroj Field Spec HandHeld2 měří pouze v rozsahu 325 – 1075 nm, přičemž je nutné počítat ještě s určitým množstvím šumu při krajních hodnotách. Například dle Vohland et al. (2014) vyšlo najevo, že klíčové vlnové délky pro vybudování modelu postaveného na vztahu spektrální chování a půdní vlastnost se pohybují v pásmech NIR (Near-Infrared) a MIR (Mid-Infrared), jež začínají právě až od 750 nm. Zornoza et al. (2008), kteří používali spektrální informace naměřené až v infračerveném pásmu elektromagnetického spektra, dosáhli výsledků až  $R^2$  0,98 pro půdní organický uhlík nebo  $R^2$  0,95 pro celkový půdní dusík.

Dalším velkým problémem byly srážkové a teplotní poměry během měření spektrometrem, ale také i rozdílné poměry v období před pořízením hyperspektrálního snímku a před pořízením spektrálních dat ručním spektrometrem. 7. října 2016, kdy byla měřena data v terénu přecházela přes zájmovou lokalitu vysoká proměnlivá oblačnost, která zákonitě musela způsobit horší odhad irradiance na Spektralonu, a tudíž méně přesné výsledné hodnoty reflektance. Z tohoto důvodu bylo měření každého vzorku provedeno celkem třikrát a byly vybrány ty spektrální informace, jež měly co nejpodobnější podmínky se situací během snímání reference na Spektralonu.

I přes tuto snahu je potřeba zdůraznit, že tento fakt mohl zanést určitou míru nejistoty do výsledného datového souboru. Dle meteorologických údajů z nejbližší stanice Vranová, které byly již popsány v kapitole 2.1, vyplývá, že došlo k pořízení obou datových sad v různých podmínkách. Hyperspektrální snímek byl měřen za nižších teplot, kdy se vyskytovaly i přízemní mrazíky, ale srážkové úhrny byly minimální, zatímco data z ručního spektrometru byla naměřena v období vyšších teplot s výrazně vyšším srážkovým úhrnem. Dle Wang et al. (2010) víme, že hodnoty zájmových půdních vlastností a tím i charakteristika samotného spektrálního chování je velmi ovlivněna vlhkostí.

Množství samotných naměřených vzorků ovlivnilo celý výpočet. Z hlediska budování jakéhokoliv statistického predikčního modelu je počet vzorků 22 spíše nedostačující a i v tomto případě nízký počet vzorků neumožnil provést druhý standardní krok validace. Téměř v každém modelování se nachází několik outlierů, které mohou sice představovat extrémní hodnoty, ale ve větší míře se jedná spíše o chybu měření. S počtem 22 vzorů nám bohužel nebylo umožněno důslednější statistické zpracování a hodnocení datového souboru a vybrání těch nejoptimálnějších vzorků. Malý počet vzorků samozřejmě způsobil i nízkou variabilitu dané půdní vlastnosti, což mohlo znamenat, že nebyly zachyceny některé klíčové vztahy mezi ní a příslušné spektrální informace. Studie, které měly datový soubor se stovky vzorků (Zornoza et al., 2008; Hively et al., 2011) dosahovaly výsledků i vyšších než  $R^2$  0,8. Na druhou stranu je zapotřebí říci, že cílem práce bylo především představení dané nejpřesnější metody a představení její samotné aplikace.

Z hlediska vzorků mohla být určitá míra nejistoty způsobena i laboratorním měřením. Výsledné procentuální zastoupení jednotlivých půdních prvků nebo hodnoty půdních vlastností byly zjištěny s přesností na setiny. Charakterem měření nebylo možné dosáhnout přesnějších hodnot, přičemž větší přesnost by mohla zvýšit predikční schopnost námi zvolenou metodou.

Výsledná predikce byla tedy velkou měrou ovlivněna množstvím parametrů a charakteristik, které byly popsány v předchozím textu. Posledním krokem predikce bylo stanovení zájmové masky na holé půdy. Jak již bylo popsáno dříve, tato maska byla extrahována na základě znalostí a experimentálních šetření analytika. Tento fakt mohl také způsobit, že sledované území na němž se nachází holá půda nebylo stanoveno s nejvyšší přesností a výsledný rastr vykazuje určitou míru nejistoty. Toto je platné především pro lokality okolo komunikací a zástavby, které sice mohou představovat holou půdu, ale také nemusí. Takovéto pixely zůstaly v zájmové masce, protože vykazovaly stejné hodnoty reflektance jako některé holé půdy.

Použitelnost samotné metody PLSR byla shledána pozitivní. I přes počáteční složitost dané metody se dá říci, že aplikace metody je relativně jednoduchá. Díky velkému množství již vybudovaných nástrojů lze metodu pochopit a použít i lidmi, kteří nejsou v oboru statistiky nebo geoinformaticky více vzděláni. Mezi tyto nástroje patří například vícero nástrojových balíků do prostředí jazyka R, přičemž jeden *pls* byl využit i v této práci. Během samotné aplikace je zapotřebí klást důraz na předzpracování zájmových dat představující spektrální charakteristiky. Už v této práci je možné vidět, že různé varianty předzpracování vykazovaly naprosto odlišné výsledky. Jedná se možná o jeden z nejklíčovějších kroků, protože je zapotřebí otestovat vícero variant a následně vybrat tu, která vykazuje nejlepší predikční schopnost. Volba varianty předzpracování a následného počtu komponent může být pro neodborníka složitější záležitostí a proto je zapotřebí, aby byl na tuto část kladen větší důraz.



Velkou pozornost je tedy potřeba věnovat datovým sadám. Pro samotnou predikci je nutné využít tři datové soubory a každý může vykazovat určitou míru nepřesností. Obecně by se daly shrnout předchozí poznatky do několika klíčových parametrů, na které se musí brát zřetel:

- 1) meteorologické podmínky,
- 2) množství vzorků,
- 3) použitý spektrometr.

Druhý a třetí bod lze zajistit existencí veřejné spektrální knihovny. Bohužel v dnešní době neexistuje veřejně dostupná spektrální knihovna půd pro Českou republiku. Jediná vhodná spektrální knihovna pro naše území byla vytvořena na České zemědělské univerzitě v Praze (Brodský et al., 2011). Tato knihovna ovšem není v současnosti veřejně dostupná. Použitá hyperspektrální data pořízená ústavem CzechGlobe byla pro tuto práci dostačující. Pro široké využití této metody v precizním zemědělství jsou zmiňovaná data bohužel poměrně drahá a prostorové rozlišení 2,5 m nemusí být ve všech případech dostačující. Budoucností je volně dostupná spektrální knihovna půd s daty v různých obdobích a s různými meteorologickými charakteristikami a také pořizování hyperspektrálních snímků pomocí UAV, který zajistí vyšší prostorové rozlišení a nižší pořizovací cenu.

## 7 ZÁVĚR

Práce měla hlavní cíl stanovení nejpoužívanějších a nejpřesnějších metod pro monitoring půdních vlastností. Tyto metody následně otestovat praktickým použitím na zájmových datech ze zájmového území a na závěr posoudit jejich použitelnost v našich podmínkách a podat určitá doporučení pro další aplikaci.

Stěžejní částí práce byla tedy rešeršní část, které bylo věnováno velké množství prostoru. Teoretická část byla rozdělena dle zájmových půdních vlastností, ačkoliv se metody a postupy pro jejich stanovení vzájemně velmi překrývaly. Během této části bylo zjištěno, že nejpoužívanější metody představují metody statistického predikčního modelování. K tomuto přístupu bylo zapotřebí zajistit další datové sady jako informace o spektrálním chování jednotlivých odběrných míst a hyperspektrální snímek.

V praktické části byly metody rozděleny na analýzy pomocí multispektrálních snímků a analýzy pomocí hyperspektrálních snímků. Použitelnost multispektrálních snímků byla dle rešeršní části shledána v aplikaci spektrálních indexů. Bylo také zjištěno, že pomocí těchto indexů lze převážně stanovovat komplexní charakteristiky půd a určovat půdní vlastnosti na základě korelací s výsledky těchto indexů. To znamená, že vhodnost pro stanovení izolovaných půdních vlastností, které byly stanoveny cílem práce, byla nižší. I přesto byly v práci některé indexy testovány a byla posuzována především aplikovatelnost na vybrané satelitní multispektrální data a vzájemné vztahy s půdními vlastnostmi pomocí korelačních koeficientů. Jako nejlepší multispektrální data pro aplikaci zájmových indexů se jevila data ze systémů Sentinel-2 nebo Landsat-8 a to především proto, že nabízí větší množství spektrálních pásem, a tudíž umožňují větší variabilitu. Výhodou je, že tato data jsou dostupná zdarma. Korelační koeficienty nenabývaly významnějších hodnot, což mohlo být způsobeno prostorovým rozlišením snímků, které jsou pro tento druh analýz klíčové. Na druhou stranu se dá z výsledných hodnot určit alespoň přibližný charakter a trend při porovnání vztahů konkrétního indexu s půdními vlastnostmi.

Z informací zjištěných během rešeršní části bylo stanoveno, že největší důraz bude kladen právě na statistické predikční modelování s hyperspektrálními daty. V předchozích studiích vycházely nejlépe modely vytvořené metodou PLSR, jejichž použitelnost byla následně také testována v této práci. Samotná aplikace a použitelnost metody byla shledána jako dobrá. I bez hlubších znalostí statistických principů je možné metodou zájmové vlastnosti predikovat. Metoda se používá i pro velké množství analýz z různých oborů, ale jedním z nejdůležitějších a nejpoužívanějších přístupů je právě predikční modelování s informacemi o spektrálním chování. V této studii byla daná metoda bohužel nepoužitelná pro některé půdní vlastnosti a i ten nejlepší model vyšel pouze se střední predikční schopností ( $R^2$  0,44). Je zde ale zapotřebí zmínit, že tato hodnota nebyla pravděpodobně dosažena z důvodu nevhodnosti metody, ale z důvodu horšího charakteru vstupních dat. V těchto datech nebyly dodrženy některé principy zjištěné již při rešeršní části. Mezi neklíčovější patří rozdílné atmosférické podmínky v období před pořízením leteckého hyperspektrálního snímku a v období před a během pořízení dat ručním spektrometrem. Samotný konkrétní ruční spektrometr použitý v této práci se dále nejeví jako nejvhodnější pro vstup do PLSR modelování půdních vlastností. V rozsahu vlnových délek, které daný přístroj snímá chybí klíčové vlnové délky, ve kterých by na základě rešerše měla být odrazivost významněji ovlivňována právě zájmovými půdními vlastnostmi. Detailnější charakteristika těchto principů

a tedy i doporučení pro případnou další konkrétní aplikaci je dostupná v kapitole Diskuse.

Z hlediska předem stanovených cílů došlo tedy k podání přehledu a charakterizace postupů pro stanovování konkrétních půdních vlastností. Z těchto vlastností byly vybrány nejklíčovější, které byly následně otestovány aplikací na konkrétních datech z konkrétního území. K této aplikaci byl podán přehled důležitých kroků pro PLSR modelování v případech, jež jsou blízké našemu. Nakonec byly zhodnoceny výsledky a použitelnost, které byly podpořeny určitým doporučením pro další použití.

## POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE

- [1.] Absorpční pás. *Terminologický slovník zeměměřičství a katastru nemovitosti* [online]. 2005 [cit. 2016-09-30]. Dostupné z: [https://www.vugtk.cz/slovník/4942\\_absorpcni-pas](https://www.vugtk.cz/slovník/4942_absorpcni-pas)
- [2.] BAJOUAN, Zheng. *Using satellite hyperspectral imagery to map soil organic matter, total nitrogen and total phosphorus*. Indiana University, 2008.
- [3.] BARNES, Edward M., Kenneth A. SUDDUTH, John W. HUMMEL, Scott M. LESCH, Dennis L. CORWIN, Chenghai YANG, Craig S.T. DAUGHTRY a Walter C. BAUSCH. Remote- and Ground-Based Sensor Techniques to Map Soil Properties. *Photogrammetric Engineering* [online]. 2003, **69**(6), 619-630 [cit. 2016-10-04]. DOI: 10.14358/PERS.69.6.619. ISSN 00991112. Dostupné z: <http://openurl.ingenta.com/content/xref?genre=article>
- [4.] BELLON-MAUREL, Véronique, Elvira FERNANDEZ-AHUMADA, Bernard PALAGOS, Jean-Michel ROGER, Alex MCBRATNEY, Chenghai YANG, Craig S.T. DAUGHTRY a Walter C. BAUSCH. Critical review of chemometric indicators commonly used for assessing the quality of the prediction of soil attributes by NIR spectroscopy. *TrAC Trends in Analytical Chemistry* [online]. 2010, **29**(9), 1073-1081 [cit. 2016-10-04]. DOI: 10.1016/j.trac.2010.05.006. ISSN 01659936. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0165993610001585>
- [5.] BEN-DOR, E. *Quantitative remote sensing of soil properties* [online]. s. 173 [cit. 2016-09-30]. DOI: 10.1016/S0065-2113(02)75005-0. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0065211302750050>
- [6.] BEN-DOR, E., A. BANIN, Bernard PALAGOS, Jean-Michel ROGER, Alex MCBRATNEY, Chenghai YANG, Craig S.T. DAUGHTRY a Walter C. BAUSCH. Near-Infrared Analysis as a Rapid Method to Simultaneously Evaluate Several Soil Properties. *Soil Science Society of America Journal* [online]. 1995, **59**(2), 364- [cit. 2016-10-04]. DOI: 10.2136/sssaj1995.03615995005900020014x. ISSN 0361-5995. Dostupné z: <https://www.soils.org/publications/sssaj/abstracts/59/2/SS0590020364>
- [7.] BEN-DOR, E., K. PATKIN, A. BANIN, A. KARNIELI, Alex MCBRATNEY, Chenghai YANG, Craig S.T. DAUGHTRY a Walter C. BAUSCH. Mapping of several soil properties using DAIS-7915 hyperspectral scanner data - a case study over clayey soils in Israel. *International Journal of Remote Sensing* [online]. 2002, **23**(6), 1043-1062 [cit. 2016-10-04]. DOI: 10.1080/01431160010006962. ISSN 0143-1161. Dostupné z: <http://www.informaworld.com/openurl?genre=article>
- [8.] BEN-DOR, E., S. CHABRILLAT, J.A.M. DEMATTÉ, G.R. TAYLOR, J. HILL, M.L. WHITING a S. SOMMER. Using Imaging Spectroscopy to study soil properties. *Remote Sensing of Environment* [online]. 2009, **113**, S38-S55 [cit. 2016-09-30]. DOI: 10.1016/j.rse.2008.09.019. ISSN 00344257. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0034425709000753>

- [9.] BLUM, W. E. H. Soil Resources – The Basis of Human Society and the Environment. *Ressource Boden – Grundlage für Mensch und Umwelt* [online]. 2006, **57**(4), 1-6 [cit. 2016-10-04]. Dostupné z: <https://diebodenkultur.boku.ac.at/volltexte/band-57/heft-4/blum.pdf>
- [10.] BRODSKÝ, Lukáš, Aleš KLEMENT, Vít PENÍZEK, Radka KODEŠOVÁ a Luboš BORŮVKA. Building Soil Spectral Library of the Czech Soils for Quantitative Digital Soil Mapping. *Soil & Water Res.* [online]. 2011, **6**(4), 13 s. [cit. 2017-01-04]. Dostupné z: <http://www.agriculturejournals.cz/publicFiles/51680.pdf>
- [11.] CARLSON, Toby N., Robert R. GILLIES a Thomas J. SCHMUGGE. An interpretation of methodologies for indirect measurement of soil water content. *Agricultural and Forest Meteorology* [online]. 1995, **77**(3-4), 191-205 [cit. 2016-10-01]. DOI: 10.1016/0168-1923(95)02261-U. ISSN 01681923. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/016819239502261U>
- [12.] CÉCILLON, L., B. G. BARTHÈS, C. GOMEZ, D. ERTLEN, V. GENOT, M. HEDDE, A. STEVENS a J. J. BRUN. Assessment and monitoring of soil quality using near-infrared reflectance spectroscopy (NIRS). *European Journal of Soil Science* [online]. 2009, **60**(5), 770-784 [cit. 2016-10-04]. DOI: 10.1111/j.1365-2389.2009.01178.x. ISSN 13510754. Dostupné z: <http://doi.wiley.com/10.1111/j.1365-2389.2009.01178.x>
- [13.] CLAPS, Pierluigi; LAGUARDIA, Giovanni. Assessing spatial variability of soil water content through Thermal Inertia and NDVI. In: *Remote Sensing*. International Society for Optics and Photonics, 2004. p. 378-387.
- [14.] CLARK, Roger N. Spectroscopy of Rocks and Minerals, and Principles of Spectroscopy. *Manual of remote sensing*. New York: J. Wiley, 1999, s. 3-58. ISBN 0471294055.
- [15.] CROFT, H., K. ANDERSON a N. J. KUHN. Evaluating the influence of surface soil moisture and soil surface roughness on optical directional reflectance factors. *European Journal of Soil Science* [online]. 2014, **65**(4), 605-612 [cit. 2016-10-01]. DOI: 10.1111/ejss.12142. ISSN 13510754. Dostupné z: <http://doi.wiley.com/10.1111/ejss.12142>
- [16.] DALAL, R. C. a R. J. HENRY. Simultaneous Determination of Moisture, Organic Carbon, and Total Nitrogen by Near Infrared Reflectance Spectrophotometry1. *Soil Science Society of America Journal* [online]. 1986, **50**(1), 120- [cit. 2016-04-12]. DOI: 10.2136/sssaj1986.03615995005000010023x. ISSN 03615995. Dostupné z: <https://www.soils.org/publications/sssaj/abstracts/50/1/SS0500010120>
- [17.] DANIEL, K. W., N. K. TRIPATHI a K. HONDA. Artificial neural network analysis of laboratory and in situ spectra for the estimation of macronutrients in soils of Lop Buri (Thailand). *Australian Journal of Soil Research* [online]. 2003, **41**(1), 47-

- [cit. 2016-10-04]. DOI: 10.1071/SR02027. ISSN 0004-9573. Dostupné z: <http://www.publish.csiro.au/?paper=SR02027>
- [18.] DAUGHTRY, Craig, E. R. HUNT, Charlie WALTHALL a E. J. KRAMER. *ASSESSING THE SPATIAL DISTRIBUTION OF PLANT LITTER* [online]. 2014 [cit. 2017-03-19]. Dostupné z: [https://www.researchgate.net/publication/265038260\\_ASSESSING\\_THE\\_SPATIAL\\_DISTRIBUTION\\_OF\\_PLANT\\_LITTER](https://www.researchgate.net/publication/265038260_ASSESSING_THE_SPATIAL_DISTRIBUTION_OF_PLANT_LITTER)
- [19.] DE JONG, Sijmen. Multivariate calibration, H. Martens and T. Naes, Wiley, New York, 1989. ISBN 0 471 90979 3. Price: £75.00, US\$138.00. No. of pages. *Journal of Chemometrics* [online]. 1990, **4**(6), 441-441 [cit. 2016-10-04]. DOI: 10.1002/cem.1180040607. ISSN 0886-9383. Dostupné z: <http://doi.wiley.com/10.1002/cem.1180040607>
- [20.] DEWITTE, O., A. JONES, H. ELBELRHITI, S. HORION a L. MONTANARELLA. Satellite remote sensing for soil mapping in Africa: An overview. *Progress in Physical Geography* [online]. 2012, **36**(4), 514-538 [cit. 2016-09-30]. DOI: 10.1177/0309133312446981. ISSN 0309-1333. Dostupné z: <http://ppg.sagepub.com/cgi/doi/10.1177/0309133312446981>
- [21.] DIVIŠ, Marián. *Monitoring půd* [online]. Karviná, 2010 [cit. 2016-09-26]. Dostupné z: [http://www.spskarvina.cz/web/uploady/File/chemie/Monitoring\\_pud\(1\).pdf](http://www.spskarvina.cz/web/uploady/File/chemie/Monitoring_pud(1).pdf). Texty pro obor Průmyslová ekologie.
- [22.] DOBROVOLNÝ, Petr. *Dálkový průzkum Země: digitální zpracování obrazu*. Brno: Masarykova univerzita, 1998. ISBN 80-210-1812-7.
- [23.] DOMENIKIOTIS, C., M. SPILIOPOULOS, E. TSIROS a N. R. DALEZIOS. Early cotton yield assessment by the use of the NOAA/AVHRR derived Vegetation Condition Index (VCI) in Greece. *International Journal of Remote Sensing* [online]. 2004, **25**(14), 2807-2819 [cit. 2016-09-30]. DOI: 10.1080/01431160310001632729. ISSN 0143-1161. Dostupné z: <http://www.tandfonline.com/doi/abs/10.1080/01431160310001632729>
- [24.] DONG, Angang, Xingchen YE, Jun CHEN, Yijin KANG, Thomas GORDON, James M. KIKKAWA a Christopher B. MURRAY. A Generalized Ligand-Exchange Strategy Enabling Sequential Surface Functionalization of Colloidal Nanocrystals. *Journal of the American Chemical Society* [online]. 2011, **133**(4), 998-1006 [cit. 2017-01-04]. DOI: 10.1021/ja108948z. ISSN 0002-7863. Dostupné z: <http://pubs.acs.org/doi/abs/10.1021/ja108948z>
- [25.] DUNN, Kevin. Interpreting the scores in PLS. *Process Improvement Using Data* [online]. 2016 [cit. 2017-03-19]. Dostupné z: <https://learnche.org/pid/latent-variable-modelling/projection-to-latent-structures/interpreting-pls-scores-and-loadings>

- [26.] DVOŘÁČEK, Václav, Anna PROHASKOVÁ a Lenka ŠTOČKOVÁ. *Efektivní využití blízké infračervené spektroskopie s Fourierovou transformací pro hodnocení technologických vlastností pšenice: metodika pro praxi*. Praha: Výzkumný ústav rostlinné výroby, 2014. ISBN 978-80-7427-151-9.
- [27.] DVOŘÁKOVÁ, Tereza. *Půdní organická hmota: nejmodernější poznatky ve vztahu k obsahům PAHs ve vybraných půdách ČR* [online]. Brno, 2013 [cit. 2016-10-05]. Dostupné z: [http://is.muni.cz/th/270404/prif\\_b/BP\\_Dvorakova.pdf](http://is.muni.cz/th/270404/prif_b/BP_Dvorakova.pdf). Bakalářská práce.
- [28.] ENGMAN, Edwin T. a Narinder CHAUHAN. Status of microwave soil moisture measurements with remote sensing. *Remote Sensing of Environment* [online]. 1995, **51**(1), 189-198 [cit. 2016-10-01]. DOI: 10.1016/0034-4257(94)00074-W. ISSN 00344257. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/003442579400074W>
- [29.] ENVI. *ARCDATA PRAHA* [online]. 2017 [cit. 2017-01-06]. Dostupné z: <https://www.arcdata.cz/produkty/envi>
- [30.] FEILHAUER, Hannes, Gregory P. ASNER, Roberta E. MARTIN a Sebastian SCHMIDTLEIN. Brightness-normalized Partial Least Squares Regression for hyperspectral data. *Journal of Quantitative Spectroscopy and Radiative Transfer* [online]. 2010, **111**(12-13), 1947-1957 [cit. 2017-01-08]. DOI: 10.1016/j.jqsrt.2010.03.007. ISSN 00224073. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0022407310000932>
- [31.] FERNÁNDEZ-BUCES, N., C. SIEBE, S. CRAM, J.L. PALACIO a Abdul Mounem MOUAZEN. Mapping soil salinity using a combined spectral response index for bare soil and vegetation: A case study in the former lake Texcoco, Mexico. *Journal of Arid Environments* [online]. 2006, **65**(4), 644-667 [cit. 2017-01-04]. DOI: 10.1016/j.jaridenv.2005.08.005. ISSN 01401963. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0140196305001989>
- [32.] FIDÊNCIO, Paulo H., Ronei J. POPPI a João Carlos DE ANDRADE. Determination of organic matter in soils using radial basis function networks and near infrared spectroscopy. *Analytica Chimica Acta* [online]. 2002, **453**(1), 125-134 [cit. 2016-10-04]. DOI: 10.1016/S0003-2670(01)01506-9. ISSN 00032670. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0003267001015069>
- [33.] FROUZ, J., V. KRIŠTŮFEK, M. LIVEČKOVÁ, D. VAN LOO, P. JACOBS a L. VAN HOOREBEKE. Microbial properties of soil aggregates created by earthworms and other factors: spherical and prismatic soil aggregates from unreclaimed post-mining sites. *Folia Microbiologica* [online]. 2011, **56**(1), 36-43 [cit. 2017-01-04]. DOI: 10.1007/s12223-011-0011-7. ISSN 0015-5632. Dostupné z: <http://link.springer.com/10.1007/s11270-005-5991-y>

- [34.] FROUZ, Jan, Václav KRIŠTŮFEK, Jan BASTL, Jiří KALČÍK a Hana VAŇKOVÁ. Determination of Toxicity of Spoil Substrates After Brown Coal Mining Using a Laboratory Reproduction Test with *Enchytraeus crypticus* (Oligochaeta): A case study in the former lake Texcoco, Mexico. *Water, Air*, [online]. 2005, **162**(1-4), 37-47 [cit. 2017-01-04]. DOI: 10.1007/s11270-005-5991-y. ISSN 0049-6979. Dostupné z: <http://link.springer.com/10.1007/s11270-005-5991-y>
- [35.] FUNG, A.K., Z. LI a K.S. CHEN. Backscattering from a randomly rough dielectric surface. *IEEE Transactions on Geoscience and Remote Sensing* [online]. **30**(2), 356-369 [cit. 2016-10-01]. DOI: 10.1109/36.134085. ISSN 01962892. Dostupné z: <http://ieeexplore.ieee.org/document/134085/>
- [36.] GAJA, Pavel. *Analýza půdní vlhkosti a charakteristik sucha prostředky DPZ*. Brno, 2013. Diplomová práce. Masarykova univerzita v Brně.
- [37.] GAO, Bo-Cai a Alexander F. H. GOETZ. Column atmospheric water vapor and vegetation liquid water retrievals from Airborne Imaging Spectrometer data. *Journal of Geophysical Research* [online]. 1990, **95**(D4), 3549- [cit. 2016-10-04]. DOI: 10.1029/JD095iD04p03549. ISSN 0148-0227. Dostupné z: <http://doi.wiley.com/10.1029/JD095iD04p03549>
- [38.] GERIGHAUSEN, Heike, Gunter MENZ a Hermann KAUFMANN. Spatially Explicit Estimation of Clay and Organic Carbon Content in Agricultural Soils Using Multi-Annual Imaging Spectroscopy Data. *Applied and Environmental Soil Science* [online]. 2012, **2012**, 1-23 [cit. 2017-03-13]. DOI: 10.1155/2012/868090. ISSN 1687-7667. Dostupné z: <http://www.hindawi.com/journals/aess/2012/868090/>
- [39.] GILLIES, R. R., W. P. KUSTAS a K. S. HUMES. A verification of the 'triangle' method for obtaining surface soil water content and energy fluxes from remote measurements of the Normalized Difference Vegetation Index (NDVI) and surface *e*. *International Journal of Remote Sensing* [online]. 1997, **18**(15), 3145-3166 [cit. 2016-10-01]. DOI: 10.1080/014311697217026. ISSN 0143-1161. Dostupné z: <http://www.tandfonline.com/doi/abs/10.1080/014311697217026>
- [40.] GODDU, R. F. a D. A. DELKER. Spectra-Structure Correlations for Near-Infrared Region. *Analytical Chemistry* [online]. 1960, **32**(1), 140-141 [cit. 2016-10-04]. DOI: 10.1021/ac60157a048. ISSN 0003-2700. Dostupné z: <http://pubs.acs.org/doi/abs/10.1021/ac60157a048>
- [41.] GOMEZ, Cécile, Philippe LAGACHERIE a Guillaume COULOUMA. Continuum removal versus PLSR method for clay and calcium carbonate content estimation from laboratory and airborne hyperspectral measurements. *Geoderma* [online]. 2008, **148**(2), 141-148 [cit. 2016-04-12]. DOI: 10.1016/j.geoderma.2008.09.016. ISSN 00167061. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0016706108002644>



- [42.] GOMEZ, Cécile, Raphael A. VISCARRA ROSSEL a Alex B. MCBRATNEY. Soil organic carbon prediction by hyperspectral remote sensing and field vis-NIR spectroscopy: An Australian case study. *Geoderma* [online]. 2008, **146**(3-4), 403-411 [cit. 2016-10-04]. DOI: 10.1016/j.geoderma.2008.06.011. ISSN 00167061. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0016706108001729>
- [43.] GRANT, Lawrence. *Using satellite imagery and novel low altitude aerial imagery to classify coastal wetland vegetation for change detection at Whatipu Scientific Reserve* [online]. Auckland, NZ, 2015 [cit. 2017-03-19]. Dostupné z: <http://aut.researchgateway.ac.nz/bitstream/handle/10292/9774/LawrenceG.pdf?sequence=3>
- [44.] HABOUDANE, Driss, John R. MILLERA, Elizabeth PATTEY, Pablo J. ZARCO-TEJADA a Ian B. STRACHANE. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment* [online]. 2004, **90**(3), 337-352 [cit. 2017-03-19]. DOI: 10.1016/j.rse.2003.12.013. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0034425704000264>
- [45.] HALOUNOVÁ, Lena a Karel PAVELKA. *Dálkový průzkum Země*. Praha: Vydavatelství ČVUT, 2005. ISBN 80-01-03124-1.
- [46.] HandHeld 2: Hand-held VNIR Spectroradiometer. *ASDI Inc.* [online]. 2017 [cit. 2017-03-19]. Dostupné z: <https://www.asdi.com/products-and-services/fieldspec-spectroradiometers/handheld-2-portable-spectroradiometer>
- [47.] HANUŠ, J., FAJMON, L., FABIÁNEK, T. 2016. UPOL Rudice – 1602. Souhrnná výzkumná zpráva. Brno: Ústav výzkumu globální změny AV ČR, v. v. i., Oddělení dálkového průzkumu Země, 13 s.
- [48.] HANUŠ, J., T. FABIÁNEK, V. KAPLAN a L. HOMOLOVÁ. Flying laboratory of imaging systems (FLIS) at CzechGlobe. In: *14th International Multidisciplinary Scientific GeoConference SGEM 2014*. 2014, s. 177-182. ISBN 978-619-7105-12-4. ISSN 1314-2704.
- [49.] HARALD MARTENS AND TORMOD NAES. *Multivariate calibration*. Reprint. Chichester [u.a.]: Wiley, 1998. ISBN 9780471930471.
- [50.] HBIRKOU, Christine, Stefan PÄTZOLD, Anne-Katrin MAHLEIN a Gerhard WELP. Airborne hyperspectral imaging of spatial soil organic carbon heterogeneity at the field-scale. *Geoderma* [online]. 2012, **175-176**, 21-28 [cit. 2016-10-04]. DOI: 10.1016/j.geoderma.2012.01.017. ISSN 00167061. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0016706112000432>
- [51.] HENDERSON, T. L., M. F. BAUMGARDNER, D. P. FRANZMEIER, D. E. STOTT a D. C. COSTER. High Dimensional Reflectance Analysis of Soil Organic Matter. *Soil Science Society of America Journal* [online]. 1992, **56**(3), 865- [cit. 2016-10-04]. DOI: 10.2136/sssaj1992.03615995005600030031x. ISSN 0361-5995.

Dostupné z:

<https://www.soils.org/publications/sssaj/abstracts/56/3/SS0560030865>

- [52.] HIVELY, W. Dean, Gregory W. MCCARTY, James B. REEVES, Megan W. LANG, Robert A. OESTERLING a Stephen R. DELWICHE. Use of Airborne Hyperspectral Imagery to Map Soil Properties in Tilled Agricultural Fields. *Applied and Environmental Soil Science* [online]. 2011, **2011**, 1-13 [cit. 2016-04-12]. DOI: 10.1155/2011/358193. ISSN 16877667. Dostupné z: <http://www.hindawi.com/journals/aess/2011/358193/>
- [53.] HOMOLOVÁ, Lucie, Jan HANUŠ, Tobiáš FABIÁNEK a František ZEMEK. Hyperspetrální data. ZEMEK, František. *Letecký dálkový průzkum Země: teorie a příklady hodnocení terestrických ekosystémů*. Brno: Centrum výzkumu globální změny AV ČR, c2014, s. 35-48. ISBN 978-80-87902-07-3.
- [54.] HONSOVÁ, Dagmar. Vlhkost půdy a metody jejího měření. *Příroda.cz* [online]. 2004, **2008**, 1 [cit. 2016-09-26]. ISSN 1801-2787. Dostupné z: <http://www.priroda.cz/clanky.php?detail=1101>
- [55.] HOSSAIN, A. K. M. Azad a Greg EASSON. Evaluating the Potential of VI-LST Triangle Model for Quantitative Estimation of Soil Moisture using Optical Imagery. In: *IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium* [online]. IEEE, 2008, III - 879-III - 882 [cit. 2016-10-01]. DOI: 10.1109/IGARSS.2008.4779490. ISBN 978-1-4244-2807-6. Dostupné z: <http://ieeexplore.ieee.org/document/4779490/>
- [56.] HRUDOVÁ, Eva. Půda a výživa rostlin. *Abionozologie pro rostlinolékaře* [online]. 2011 [cit. 2017-01-03]. Dostupné z: [http://vitejtenazemi.cz/cenia/index.php?p=kyselost\\_pudy\\_pudni\\_reakce&site=puda](http://vitejtenazemi.cz/cenia/index.php?p=kyselost_pudy_pudni_reakce&site=puda)
- [57.] HUETE, Alfredo, Chris JUSTICE a Wim VAN LEEUWEN. *MODIS Vegetation Index (Mod 13): Algorithm Theoretical Basis Document* [online]. Arizona, 1999 [cit. 2016-09-30]. Dostupné z: [https://vip.arizona.edu/documents/MODIS/MODIS\\_VI\\_ATBD.pdf](https://vip.arizona.edu/documents/MODIS/MODIS_VI_ATBD.pdf). University of Arizona, USA.
- [58.] CHANG, Cheng-Wen a David A. LAIRD. NEAR-INFRARED REFLECTANCE SPECTROSCOPIC ANALYSIS OF SOIL C AND N. *Soil Science* [online]. 2002, **167**(2), 110-116 [cit. 2016-10-04]. DOI: 10.1097/00010694-200202000-00003. ISSN 0038-075x. Dostupné z: <http://content.wkhealth.com/linkback/openurl?sid=WKPTLP:landingpage&an=00010694-200202000-00003>
- [59.] CHANG, Cheng-Wen, David A. LAIRD, Maurice J. MAUSBACH a Charles R. HURBURGH. Near-Infrared Reflectance Spectroscopy–Principal Components Regression Analyses of Soil Properties. *Soil Science Society of America Journal* [online]. 2001, **65**(2), 480- [cit. 2016-10-04]. DOI: 10.2136/sssaj2001.652480x. ISSN 1435-0661. Dostupné z: <https://www.soils.org/publications/sssaj/abstracts/65/2/480>

- [60.] CHAUHAN, N. S., S. MILLER a P. ARDANUY. Spaceborne soil moisture estimation at high resolution: a microwave-optical/IR synergistic approach. *International Journal of Remote Sensing* [online]. 2003, **24**(22), 4599-4622 [cit. 2016-10-01]. DOI: 10.1080/0143116031000156837. ISSN 0143-1161. Dostupné z: <http://www.tandfonline.com/doi/abs/10.1080/0143116031000156837>
- [61.] I. BOGREKCI a W. S. LEE. IMPROVING PHOSPHORUS SENSING BY ELIMINATING SOIL PARTICLE SIZE EFFECT IN SPECTRAL MEASUREMENT. *Transactions of the ASAE* [online]. 2005, **48**(5), 1971-1978 [cit. 2017-03-13]. DOI: 10.13031/2013.19989. ISSN 2151-0059. Dostupné z: <http://elibrary.asabe.org/abstract.asp??JID=3&AID=19989&CID=t2005&v=48&i=5&T=1>
- [62.] Inkscape: Overview. *Inkscape: Draw Freerly* [online]. 2017 [cit. 2017-01-07]. Dostupné z: <https://inkscape.org/en/about/>
- [63.] ISLAM, Kamrunnahar, Balwant SINGH a Alex MCBRATNEY. Simultaneous estimation of several soil properties by ultra-violet, visible, and near-infrared reflectance spectroscopy. *Australian Journal of Soil Research* [online]. 2003, **41**(6) [cit. 2017-01-04]. DOI: 10.1071/SR02137. ISSN 0004-9573. Dostupné z: <http://www.publish.csiro.au/?paper=SR02137>
- [64.] JACKSON, T.J. a David E. LE VINE. Mapping surface soil moisture using an aircraft-based passive microwave instrument: algorithm and example. *Journal of Hydrology* [online]. 1996, **184**(1-2), 85-99 [cit. 2016-10-01]. DOI: 10.1016/0022-1694(95)02969-9. ISSN 00221694. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0022169495029699>
- [65.] JAIN, Sanjay K., et al. Identification of drought-vulnerable areas using NOAA AVHRR data. *International Journal of Remote Sensing*, 2009, 30.10: 2653-2668.
- [66.] JI, Wenjun, Shuo LI, Songchao CHEN, Zhou SHI, Raphael A. VISCARRA ROSSEL a Abdul M. MOUAZEN. Prediction of soil attributes using the Chinese soil spectral library and standardized spectra recorded at field conditions: spherical and prismatic soil aggregates from unreclaimed post-mining sites. *Soil and Tillage Research* [online]. 2016, **155**(1), 492-500 [cit. 2017-01-04]. DOI: 10.1016/j.still.2015.06.004. ISSN 01671987. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S016719871500121X>
- [67.] KANG, Seunghun a Baoshan XING. Phenanthrene Sorption to Sequentially Extracted Soil Humic Acids and Humins. *Environmental, Science & Technology* [online]. 2005, **39**(1), 134-140 [cit. 2016-10-04]. DOI: 10.1021/es0490828. Dostupné z: <http://pubs.acs.org/doi/abs/10.1021/es0490828>
- [68.] KERRY, R., M. A. OLIVER a Z. L. FROGBROOK. Sampling in Precision Agriculture. *Geostatistical Applications for Precision Agriculture* [online]. Dordrecht: Springer Netherlands, 2010, s. 35 [cit. 2016-10-04]. DOI:

10.1007/978-90-481-9133-8\_2. ISBN 978-90-481-9132-1. Dostupné z:  
[http://link.springer.com/10.1007/978-90-481-9133-8\\_2](http://link.springer.com/10.1007/978-90-481-9133-8_2)

- [69.] KOGAN, F.N. Application of vegetation index and brightness temperature for drought detection. *Advances in Space Research* [online]. 1995, **15**(11), 91-100 [cit. 2016-09-30]. DOI: 10.1016/0273-1177(95)00079-T. ISSN 02731177. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/027311779500079T>
- [70.] KRISHNAN, P., John D. ALEXANDER, B. J. BUTLER a John W. HUMMEL. Reflectance Technique for Predicting Soil Organic Matter1. *Soil Science Society of America Journal* [online]. 1980, **44**(6), 1282- [cit. 2016-10-04]. DOI: 10.2136/sssaj1980.03615995004400060030x. ISSN 0361-5995. Dostupné z: <https://www.soils.org/publications/sssaj/abstracts/44/6/SS0440061282>
- [71.] KUANG, Boyan, Yucel TEKIN a Abdul M. MOUAZEN. Comparison between artificial neural network and partial least squares for on-line visible and near infrared spectroscopy measurement of soil organic carbon, pH and clay content. *Soil and Tillage Research* [online]. 2015, **146**, 243-252 [cit. 2017-01-04]. DOI: 10.1016/j.still.2014.11.002. ISSN 01671987. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0167198714002475>
- [72.] Kyselost půdy – půdní reakce. *Vítejte na Zemi..* [online]. CENIA, 2013 [cit. 2017-01-03]. Dostupné z: [http://vitejtenazemi.cz/cenia/index.php?p=kyselost\\_pudy\\_pudni\\_reakce&site=puda](http://vitejtenazemi.cz/cenia/index.php?p=kyselost_pudy_pudni_reakce&site=puda)
- [73.] LAKHANKAR, Tarendra; KRAKAUER, Nir; KHANBILVARDI, Reza. Applications of microwave remote sensing of soil moisture for agricultural applications. *Int. J. Terraspace Sci. Eng*, 2009, 2.1: 81-91.
- [74.] LI, J a S ISLAM. On the estimation of soil moisture profile and surface fluxes partitioning from sequential assimilation of surface layer soil moisture. *Journal of Hydrology* [online]. 1999, **220**(1-2), 86-103 [cit. 2016-09-26]. DOI: 10.1016/S0022-1694(99)00066-9. ISSN 00221694. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0022169499000669>
- [75.] LI, Shuo, Wenjun JI, Songchao CHEN, Jie PENG, Yin ZHOU a Zhou SHI. Potential of VIS-NIR-SWIR Spectroscopy from the Chinese Soil Spectral Library for Assessment of Nitrogen Fertilization Rates in the Paddy-Rice Region, China. *Remote Sensing* [online]. 2015, **7**(6), 7029-7043 [cit. 2016-04-12]. DOI: 10.3390/rs70607029. ISSN 20724292. Dostupné z: <http://www.mdpi.com/2072-4292/7/6/7029/>
- [76.] LILIENTHAL, H., et al. Ground based remote sensing-a new tool for agricultural monitoring. In: *Proceedings of the 6th International Conference on Precision Agriculture and Other Precision Resources Management, Minneapolis, MN, USA, 14-17 July, 2002*. American Society of Agronomy, 2003. p. 1659-1667.

- [77.] LINDGREN, Fredrik, Paul GELADI a Svante WOLD. The kernel algorithm for PLS. *Journal of Chemometrics* [online]. 1993, **7**(1), 45-59 [cit. 2017-01-08]. DOI: 10.1002/cem.1180070104. ISSN 0886-9383. Dostupné z: <http://doi.wiley.com/10.1002/cem.1180070104>
- [78.] LIU W., F. BARET, Gu XINGFA, Tong QINGXI, Zheng LANFEN a Zhang BING. Relating soil surface moisture to reflectance. *Remote Sensing of Environment* [online]. 2002, **81**(2-3), 238-246 [cit. 2016-10-04]. DOI: 10.1016/S0034-4257(01)00347-9. ISSN 00344257. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0034425701003479>
- [79.] LÓPEZ-GRANADOS, F., M. JURADO-EXPÓSITO, J.M. PEÑA-BARRAGÁN, L. GARCÍA-TORRES, Aakriti SHARMA, Sathi PAUL a Md. Nasim ALI. Using geostatistical and remote sensing approaches for mapping soil properties: Total carbon and total nitrogen. *European Journal of Agronomy* [online]. 2005, **23**(3), 279-289 [cit. 2017-01-04]. DOI: 10.1016/j.eja.2004.12.003. ISSN 11610301. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1161030104001340>
- [80.] LU, Peng, Li WANG, Zheng NIU, Linghao LI a Wenhao ZHANG. Prediction of soil properties using laboratory VIS–NIR spectroscopy and Hyperion imagery. *Journal of Geochemical Exploration* [online]. 2013, **132**, 26-33 [cit. 2016-04-12]. DOI: 10.1016/j.gexplo.2013.04.003. ISSN 03756742. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0375674213000812>
- [81.] LU, Peng, Li WANG, Zheng NIU, Linghao LI a Wenhao ZHANG. Prediction of soil properties using laboratory VIS–NIR spectroscopy and Hyperion imagery. *Journal of Geochemical Exploration* [online]. 2013, **132**(12), 26-33 [cit. 2017-01-04]. DOI: 10.1016/j.gexplo.2013.04.003. ISSN 03756742. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0375674213000812>
- [82.] LUKAS, Vojtěch, Fernando Rodriguez MORENO, František ZEMEK, Petr HLAVINKA, Jan KŘEN, Daniela SEMERÁDOVÁ a Zdeněk ŽALUD. Aplikace DPZ v precizním zemědělství. ZEMEK, František. *Letecký dálkový průzkum Země: teorie a příklady hodnocení terestrických ekosystémů*. Brno: Centrum výzkumu globální změny AV ČR, c2014, s. 95-109. ISBN 978-80-87902-07-3.
- [83.] MACELLONI, G., S. PALOSCIA, P. PAMPALONI a E. SANTI. Global scale monitoring of soil and vegetation using SSM/I and ERS wind scatterometer. *International Journal of Remote Sensing* [online]. 2003, **24**(12), 2409-2425 [cit. 2016-10-01]. DOI: 10.1080/01431160210154830. ISSN 0143-1161. Dostupné z: <http://www.tandfonline.com/doi/abs/10.1080/01431160210154830>
- [84.] MALLEY, D. F., P. D. MARTIN, L. M. MCCLINTOCK, L. YESMIN, R. G. EILERS a P. HALUSCHAK. Feasibility of analysing archived Canadian prairie agricultural soils by near infrared reflectance spectroscopy. *Near Infrared Spectroscopy: Proceedings of the 9th International Conference* [online]. Chichester UK: NIR Publications, 2000, , 579-585 [cit. 2016-10-04]. Dostupné z:

[https://www.impublications.com/subs/books/978-1-906715-21-2/978-1-906715-21-2\\_ch97.pdf](https://www.impublications.com/subs/books/978-1-906715-21-2/978-1-906715-21-2_ch97.pdf)

- [85.] MARÍN-GONZÁLEZ, Omar, Boyan KUANG, Mohammed Z. QURAISHI, Miguel Ángel MUNÓZ-GARCÍA a Abdul Mounem MOUAZEN. On-line measurement of soil properties without direct spectral response in near infrared spectral range. *Soil and Tillage Research* [online]. 2013, **132**(6), 21-29 [cit. 2017-01-04]. DOI: 10.1016/j.still.2013.04.004. ISSN 01671987. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0167198713000767>
- [86.] MARTIN, P D, D F MALLEY, G. MANNING a L. FULLER. Determination of soil organic carbon and nitrogen at the field level using near-infrared spectroscopy. *Canadian Journal of Soil Science* [online]. 2002, **82**(4), 413-422 [cit. 2016-10-04]. DOI: 10.4141/S01-054. ISSN 0008-4271. Dostupné z: <http://pubs.aic.ca/doi/abs/10.4141/S01-054>
- [87.] MEKONNEN, D.F. 2009. Satellite Remote Sensing for Soil Moisture Estimation: Gumara Catchment, Ethiopia. Enschede. 90 s. International Institute for Geoinformation Science and Earth Observation.
- [88.] MELVIK, Bjorn-Helge a Ron WAHRENS. *Introduction to the pls Package* [online]. In: . 2016, s. 1-24 [cit. 2017-01-08]. Dostupné z: <https://cran.r-project.org/web/packages/pls/vignettes/pls-manual.pdf>
- [89.] MEVIK, Bjørn-Helge a Ron WEHRENS. *Introduction to the pls Package* [online]. 2016, , 1-24 [cit. 2017-03-19]. Dostupné z: <https://cran.r-project.org/web/packages/pls/vignettes/pls-manual.pdf>
- [90.] MORRA, M. J., M. H. HALL a L. L. FREEBORN. Carbon and Nitrogen Analysis of Soil Fractions Using Near-Infrared Reflectance Spectroscopy. *Soil Science Society of America Journal* [online]. 1991, **55**(1), 288- [cit. 2016-04-12]. DOI: 10.2136/sssaj1991.03615995005500010051x. ISSN 03615995. Dostupné z: <https://www.soils.org/publications/sssaj/abstracts/55/1/SS0550010288>
- [91.] MORTIMORE, Joanne L, Lisa-Jane R MARSHALL, Matthew J ALMOND, Peter HOLLINS a Wendy MATTHEWS. Analysis of red and yellow ochre samples from Clearwell Caves and Çatalhöyük by vibrational spectroscopy and other techniques. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy* [online]. 2004, **60**(5), 1179-1188 [cit. 2016-10-04]. DOI: 10.1016/j.saa.2003.08.002. ISSN 13861425. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1386142503003767>
- [92.] MOUAZEN, A. M., B. KUANG, J. DE BAERDEMAEKER a H. RAMON. Comparison between Principal Component Regression, Partial Least Squares Regression and Artificial Neural Network analyses of vis-NIR spectra for the prediction of selected soil properties. *Geoderma* [online]. 2010, **158**, 23-31 [cit. 2016-10-04]. Dostupné z: <http://adsabs.harvard.edu/abs/2009EGUGA.11.1408K>

- [93.] MUSILOVÁ, Romana. *Využití dat DPZ pro hodnocení aktuálního stavu a vývoje smrkových porostů v Krkonoších*. Karlova Univerzita v Praze, 2008.
- [94.] NAGLER, P.L., C.S.T. DAUGHTRY a S.N. GOWARD. Plant Litter and Soil Reflectance. *Remote Sensing of Environment* [online]. 2000, **71**(2), 207-215 [cit. 2017-03-13]. DOI: 10.1016/S0034-4257(99)00082-6. ISSN 00344257. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0034425799000826>
- [95.] NAWI, N. M., G. CHEN a T. JENSEN. VISIBLE AND SHORTWAVE NEAR INFRARED SPECTROSCOPY TO PREDICT SUGARCANE QUALITY FROM CLEAR AND RAW JUICE SAMPLES. *3rd Malaysian Postgraduate Conference (MPC2013)* [online]. 2013, , 167-174 [cit. 2017-03-19]. Dostupné z: [https://eprints.usq.edu.au/23998/2/Nawi\\_Chen\\_Jensen\\_MPC2013\\_PV.pdf](https://eprints.usq.edu.au/23998/2/Nawi_Chen_Jensen_MPC2013_PV.pdf)
- [96.] NJOKU, Eni G. a Dara ENTEKHABI. Passive microwave remote sensing of soil moisture. *Journal of Hydrology* [online]. 1996, **184**(1-2), 101-129 [cit. 2016-10-01]. DOI: 10.1016/0022-1694(95)02970-2. ISSN 00221694. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0022169495029702>
- [97.] Partial Least Squares regrese (PLS - R). *TriloByte: Statistical Software* [online]. 2017 [cit. 2017-01-08]. Dostupné z: <http://www.trilobyte.cz/downloadfree/qcemanual/pls.pdf>
- [98.] Pechanec V., Svobodová, J. 2015. Analýza potenciálu základních a pokročilých geoinformačních technologií pro studium půdní variability v zemědělství a lesnictví. Analýza potenciálu dálkového průzkumu Země (DPZ). Výzkumná zpráva č. VZ-TA04020888-2b. Olomouc, Univerzita Palackého v Olomouci, 32 s.
- [99.] PIEKARCZYK, J., C. KAŻMIEROWSKI, S. KRÓLEWICZ, Miguel Ángel MUNÓZ-GARCÍA a Abdul Mounem MOUAZEN. Relationships between soil properties of the abandoned fields and spectral data derived from the advanced spaceborne thermal emission and reflection radiometer (ASTER). *Advances in Space Research* [online]. 2012, **49**(2), 280-291 [cit. 2017-01-04]. DOI: 10.1016/j.asr.2011.09.010. ISSN 02731177. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0273117711006752>
- [100.] PIRIE, Adam, Balwant SINGH a Kamrunnahar ISLAM. Simultaneous estimation of several soil properties by ultra-violet, visible, and near-infrared reflectance spectroscopy. *Australian Journal of Soil Research* [online]. 2005, **43**(6), 713- [cit. 2017-01-04]. DOI: 10.1071/SR04182. ISSN 0004-9573. Dostupné z: <http://www.publish.csiro.au/?paper=SR04182>
- [101.] Pleiades-1A Satellite Sensor. *Satellite Imaging Corporation* [online]. 2017a [cit. 2017-01-06]. Dostupné z: <http://www.satimagingcorp.com/satellite-sensors/pleiades-1/>

- [102.] Přehled družicových systémů: Landsat-8. *Gisat* [online]. 2017 [cit. 2017-03-21]. Dostupné z: <http://www.gisat.cz/content/cz/dpz/prehled-druzicovych-systemu/satelite/landsat-8>
- [103.] *QGIS: A Free and Open Source Geographic Information System* [online]. Open Source Geospatial Consortium, 2017 [cit. 2017-01-06]. Dostupné z: <https://www.qgis.org/en/site/index.html>
- [104.] QIU, Fang, Mohamed ABDELSALAM a Pathik THAKKAR. Spectral analysis of ASTER data covering part of the Neoproterozoic Allaqi-Heiani suture, Southern Egypt. *Journal of African Earth Sciences* [online]. 2006, **44**(2), 169-180 [cit. 2016-09-30]. DOI: 10.1016/j.jafrearsci.2005.10.009. ISSN 1464343x. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1464343X05001901>
- [105.] REEVES III, James B., Ronald F. FOLLETT, Gregory W. MCCARTY a John M. KIMBLE. Can Near or Mid-Infrared Diffuse Reflectance Spectroscopy Be Used to Determine Soil Carbon Pools? *Communications in Soil Science and Plant Analysis* [online]. 2006, **37**(15-20), 2307-2325 [cit. 2016-04-12]. DOI: 10.1080/00103620600819461. ISSN 00103624. Dostupné z: <http://www.tandfonline.com/doi/abs/10.1080/00103620600819461>
- [106.] REEVES, III, J., G. MCCARTY a J. MEISINGER. Near infrared reflectance spectroscopy for the analysis of agricultural soils. *Journal of Near Infrared Spectroscopy* [online]. 1999, **7**(1), 179- [cit. 2016-10-04]. DOI: 10.1255/jnirs.248. ISSN 0967-0335. Dostupné z: [http://www.impublications.com/content/abstract?code=J07\\_0179](http://www.impublications.com/content/abstract?code=J07_0179)
- [107.] RIVERO, R.G., S. GRUNWALD, M.W. BINFORD a T.Z. OSBORNE. Integrating spectral indices into prediction models of soil phosphorus in a subtropical wetland. *Remote Sensing of Environment* [online]. 2009, **113**(11), 2389-2402 [cit. 2016-04-12]. DOI: 10.1016/j.rse.2009.07.015. ISSN 00344257. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0034425709002120>
- [108.] ROELOFSEN, Hans D., Peter M. VAN BODEGOM, Lammert KOOISTRA, Jorg J. VAN AMERONGEN a Jan-Philip M. WITTE. An evaluation of remote sensing derived soil pH and average spring groundwater table for ecological assessments. *International Journal of Applied Earth Observation and Geoinformation* [online]. 2015, **43**, 149-159 [cit. 2016-10-04]. DOI: 10.1016/j.jag.2015.05.005. ISSN 03032434. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0303243415001142>
- [109.] ROELOFSEN, Hans D., Peter M. VAN BODEGOM, Lammert KOOISTRA, Jorg J. VAN AMERONGEN a Jan-Philip M. WITTE. An evaluation of remote sensing derived soil pH and average spring groundwater table for ecological assessments. *International Journal of Applied Earth Observation and Geoinformation* [online]. 2015, **43**(12), 149-159 [cit. 2017-01-04]. DOI: 10.1016/j.jag.2015.05.005. ISSN 03032434. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0303243415001142>



- [110.] RStudio: Download. *RStudio* [online]. 2017 [cit. 2017-01-06]. Dostupné z: <https://www.rstudio.com/products/rstudio/download/>
- [111.] SAEYS, W., A.M. MOUAZEN a H. RAMON. Potential for Onsite and Online Analysis of Pig Manure using Visible and Near Infrared Reflectance Spectroscopy. *Biosystems Engineering* [online]. 2005, **91**(4), 393-402 [cit. 2016-04-12]. DOI: 10.1016/j.biosystemseng.2005.05.001. ISSN 15375110. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1537511005000838>
- [112.] SAVITZKY, Abraham. a M. J. E. GOLAY. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry* [online]. 1964, **36**(8), 1627-1639 [cit. 2017-03-13]. DOI: 10.1021/ac60214a047. ISSN 0003-2700. Dostupné z: <http://pubs.acs.org/doi/abs/10.1021/ac60214a047>
- [113.] SELIGE, Thomas, Jürgen BÖHNER a Urs SCHMIDHALTER. High resolution topsoil mapping using hyperspectral image and field data in multivariate regression modeling procedures. *Geoderma* [online]. 2006, **136**(1-2), 235-244 [cit. 2016-10-04]. DOI: 10.1016/j.geoderma.2006.03.050. ISSN 00167061. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0016706106001030>
- [114.] Sentinel-2: Overview. *ESA Sentinel Online* [online]. 2017a [cit. 2017-01-06]. Dostupné z: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/overview>
- [115.] SHEPHERD, Keith D. a Markus G. WALSH. Development of Reflectance Spectral Libraries for Characterization of Soil Properties. *Soil Science Society of America Journal* [online]. 2002, **66**(3), 988- [cit. 2016-10-04]. DOI: 10.2136/sssaj2002.9880. ISSN 1435-0661. Dostupné z: <https://www.soils.org/publications/sssaj/abstracts/66/3/988>
- [116.] SHI, Tiezhu, Lijuan CUI, Junjie WANG, Teng FEI, Yiyun CHEN a Guofeng WU. Comparison of multivariate methods for estimating soil total nitrogen with visible/near-infrared spectroscopy. *Plant and Soil* [online]. 2013, **366**(1-2), 363-375 [cit. 2016-04-12]. DOI: 10.1007/s11104-012-1436-8. ISSN 0032079x. Dostupné z: <http://link.springer.com/10.1007/s11104-012-1436-8>
- [117.] SHOSHANY, M., T. SVORAY, P. J. CURRAN, G. M. FOODY a A. PEREVOLOTSKY. The relationship between ERS-2 SAR backscatter and soil moisture: Generalization from a humid to semi-arid transect. *International Journal of Remote Sensing* [online]. 2000, **21**(11), 2337-2343 [cit. 2016-10-01]. DOI: 10.1080/01431160050029620. ISSN 0143-1161. Dostupné z: <http://www.tandfonline.com/doi/abs/10.1080/01431160050029620>
- [118.] SCHIRRMANN, Michael, Robin GEBBERS, Eckart KRAMER, Jan SEIDEL a Luboš BORŮVKA. Soil pH Mapping with an On-The-Go Sensor. *Sensors* [online]. 2011, **11**(12), 573-598 [cit. 2017-01-04]. DOI: 10.3390/s110100573. ISSN 1424-8220. Dostupné z: <http://www.agriculturejournals.cz/publicFiles/51680.pdf>

- [119.] SCHMUGGE, Thomas a Thomas JACKSON. Passive Microwave Remote Sensing of Soil Moisture. *Land Surface Processes in Hydrology* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 1997, s. 239 [cit. 2016-10-01]. DOI: 10.1007/978-3-642-60567-3\_14. ISBN 978-3-642-64458-0. Dostupné z: [http://link.springer.com/10.1007/978-3-642-60567-3\\_14](http://link.springer.com/10.1007/978-3-642-60567-3_14)
- [120.] SCHMUGGE, Thomas J., et al. Remote sensing in hydrology. *Advances in water resources*, 2002, 25.8: 1367-1385.
- [121.] SINGH, Ramesh P.; ROY, Sudipa; KOGAN, F. Vegetation and temperature condition indices from NOAA AVHRR data for drought monitoring over India. *International Journal of Remote Sensing*, 2003, 24.22: 4393-4402
- [122.] SNAP. *ESA Step: Science Toolbox Exploitation* [online]. 2017b [cit. 2017-01-06]. Dostupné z: <http://step.esa.int/main/toolboxes/snap/>
- [123.] SPOT-6 Satellite Sensor. *Satellite Imaging Corporation* [online]. 2017b [cit. 2017-01-06]. Dostupné z: <http://www.satimagingcorp.com/satellite-sensors/spot-6/>
- [124.] STENBERG, Bo, Raphael A. VISCARRA ROSSEL, Abdul Mounem MOUAZEN a Johanna WETTERLIND. *Visible and Near Infrared Spectroscopy in Soil Science* [online]. s. 163 [cit. 2016-10-04]. DOI: 10.1016/S0065-2113(10)07005-7. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0065211310070057>
- [125.] STENBERG, Bo. Effects of soil sample pretreatments and standardised rewetting as interacted with sand classes on Vis-NIR predictions of clay and soil organic carbon. *Geoderma* [online]. 2010, **158**(1-2), 15-22 [cit. 2016-10-04]. DOI: 10.1016/j.geoderma.2010.04.008. ISSN 00167061. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0016706110001151>
- [126.] STEVENS, Antoine, Bas VAN WESEMAEL, Grégoire VANDENSCHRICK, Souleymane TOURÉ a Bernard TYCHON. Detection of Carbon Stock Change in Agricultural Soils Using Spectroscopic Techniques. *Soil Science Society of America Journal* [online]. 2006, **70**(3), 844- [cit. 2016-10-04]. DOI: 10.2136/sssaj2005.0025. ISSN 1435-0661. Dostupné z: <https://www.soils.org/publications/sssaj/abstracts/70/3/844>
- [127.] STEVENS, Antoine, Bas VAN WESEMAEL, Harm BARTHOLOMEUS, Damien ROSILLON, Bernard TYCHON a Eyal BEN-DOR. Laboratory, field and airborne spectroscopy for monitoring organic carbon content in agricultural soils. *Geoderma* [online]. 2008, **144**(1-2), 395-404 [cit. 2016-10-04]. DOI: 10.1016/j.geoderma.2007.12.009. ISSN 00167061. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S001670610700362X>
- [128.] STEVENS, Antoine, Thomas UDELHOVEN, Antoine DENIS, Bernard TYCHON, Rocco LIOY, Lucien HOFFMANN a Bas VAN WESEMAEL. Measuring soil organic carbon in croplands at regional scale using airborne imaging spectroscopy. *Geoderma* [online]. 2010, **158**(1-2), 32-45 [cit. 2016-04-12]. DOI:

10.1016/j.geoderma.2009.11.032. ISSN 00167061. Dostupné z:  
<http://linkinghub.elsevier.com/retrieve/pii/S0016706109004078>

- [129.] ŠARAPATKA, Bořivoj. *Agroekologie: východiska pro udržitelné zemědělské hospodaření*. Olomouc: Bioinstitut, 2010. ISBN 978-80-87371-10-7.
- [130.] ŠARAPATKA, Bořivoj. *Pedologie a ochrana půdy*. 1. vyd. Olomouc: Univerzita Palackého v Olomouci, 2014. ISBN 978-80-244-3736-1.
- [131.] ŠIMEK, Miroslav. *Základy nauky o půdě. Základy nauky o půdě*. Vyd. 1. České Budějovice: Jihočeská univerzita, 2003, s. 11-24. ISBN 80-7040-630-5.
- [132.] TADELE, Amare, Christian HERGARTEN, Hans HURNI, Bettina WOLFGGRAMM, Birru YITAFERU a Yihenew G. SELASSIE. Prediction of Soil Organic Carbon for Ethiopian Highlands Using Soil Spectroscopy. *ISRN Soil Science* [online]. 2013, **2013**, 1-11 [cit. 2016-10-04]. DOI: 10.1155/2013/720589. ISSN 2090-875x. Dostupné z: <http://www.hindawi.com/journals/isrn/2013/720589/>
- [133.] TEKIN, Yücel, Boyan KUANG, Abdul MOUAZEN, Miguel Ángel MUNÓZ-GARCÍA a Abdul Mounem MOUAZEN. Potential of On-Line Visible and Near Infrared Spectroscopy for Measurement of pH for Deriving Variable Rate Lime Recommendations. *Sensors* [online]. 2013, **13**(8), 21-29 [cit. 2017-01-04]. DOI: 10.3390/s130810177. ISSN 1424-8220. Dostupné z: <http://www.mdpi.com/1424-8220/13/8/10177/>
- [134.] TRAMUTOLI, Valerio, et al. Feasibility of hydrological application of thermal inertia from remote sensing. In: *2nd Plinius Conference on Mediterranean Storms, Siena, Italy*. 2000. p. 16-18.
- [135.] TUCKER, Compton J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment* [online]. 1979, **8**(2), 127-150 [cit. 2016-09-30]. DOI: 10.1016/0034-4257(79)90013-0. ISSN 00344257. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0034425779900130>
- [136.] UNGANAI, Leonard S a Felix N KOGAN. Drought Monitoring and Corn Yield Estimation in Southern Africa from AVHRR Data. *Remote Sensing of Environment* [online]. 1998, **63**(3), 219-232 [cit. 2016-09-30]. DOI: 10.1016/S0034-4257(97)00132-6. ISSN 00344257. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0034425797001326>
- [137.] URBÁNKOVÁ, OLGA. Role uhlíku v půdě a biouhel jako možnost hospodaření v zemědělství. *Příroda.cz* [online]. 2004, **2015**, 1 [cit. 2016-10-05]. ISSN 1801-2787. Dostupné z: <http://www.priroda.cz/clanky.php?detail=2702>
- [138.] USTIN, Susan L., A.A. GITELSON, Stéphane JACQUEMOUD, Michael SCHAEPMAN, Gregory P. ASNER, John A. GAMON a Pablo ZARCO-TEJADA. Retrieval of foliar information about plant pigment systems from high resolution spectroscopy. *Remote Sensing of Environment* [online]. 2009, **113**, S67-S77 [cit.

2017-01-05]. DOI: 10.1016/j.rse.2008.10.019. ISSN 00344257. Dostupné z:  
<http://linkinghub.elsevier.com/retrieve/pii/S0034425709000789>

- [139.] VÅGEN, Tor-G., Keith D. SHEPHERD a Markus G. WALSH. Sensing landscape level change in soil fertility following deforestation and conversion in the highlands of Madagascar using Vis-NIR spectroscopy. *Geoderma* [online]. 2006, **133**(3-4), 281-294 [cit. 2016-04-12]. DOI: 10.1016/j.geoderma.2005.07.014. ISSN 00167061. Dostupné z:  
<http://linkinghub.elsevier.com/retrieve/pii/S0016706105002284>
- [140.] VAUDOUR, E., J.M. GILLIOT, L. BEL, J. LEFEVRE a K. CHEHDI. Regional prediction of soil organic carbon content over temperate croplands using visible near-infrared airborne hyperspectral imagery and synchronous field spectra. *International Journal of Applied Earth Observation and Geoinformation* [online]. 2016, **49**, 24-38 [cit. 2016-10-04]. DOI: 10.1016/j.jag.2016.01.005. ISSN 03032434. Dostupné z:  
<http://linkinghub.elsevier.com/retrieve/pii/S0303243416300058>
- [141.] VISCARRA ROSSEL, R. A. a R. M. LARK. Improved analysis and modelling of soil diffuse reflectance spectra using wavelets. *European Journal of Soil Science* [online]. 2009, **60**(3), 453-464 [cit. 2016-10-04]. DOI: 10.1111/j.1365-2389.2009.01121.x. ISSN 13510754. Dostupné z:  
<http://doi.wiley.com/10.1111/j.1365-2389.2009.01121.x>
- [142.] VISCARRA ROSSEL, R.A. Robust modelling of soil diffuse reflectance spectra by bagging- partial least squares regression. *Journal of Near Infrared Spectroscopy* [online]. 2007, **15**(2), 39- [cit. 2016-10-04]. DOI: 10.1255/jnirs.694. ISSN 0967-0335. Dostupné z: [http://www.impublications.com/content/abstract?code=J15\\_0039](http://www.impublications.com/content/abstract?code=J15_0039)
- [143.] VISCARRA ROSSEL, R.A. a T. BEHRENS. Using data mining to model and interpret soil diffuse reflectance spectra. *Geoderma* [online]. 2010, **158**(1-2), 46-54 [cit. 2016-10-04]. DOI: 10.1016/j.geoderma.2009.12.025. ISSN 00167061. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0016706109004315>
- [144.] VISCARRA ROSSEL, R.A., D.J.J. WALVOORT, A.B. MCBRATNEY, L.J. JANIK a J.O. SKJEMSTAD. Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma* [online]. 2006, **131**(1-2), 59-75 [cit. 2016-04-12]. DOI: 10.1016/j.geoderma.2005.03.007. ISSN 00167061. Dostupné z:  
<http://linkinghub.elsevier.com/retrieve/pii/S0016706105000728>
- [145.] VISCARRA ROSSEL, R.A., R.N. MCGLYNN a A.B. MCBRATNEY. Determining the composition of mineral-organic mixes using UV-vis-NIR diffuse reflectance spectroscopy. *Geoderma* [online]. 2006, **137**(1-2), 70-82 [cit. 2016-10-04]. DOI: 10.1016/j.geoderma.2006.07.004. ISSN 00167061. Dostupné z:  
<http://linkinghub.elsevier.com/retrieve/pii/S0016706106002321>

- [146.] VOHLAND, M., M. LUDWIG, S. THIELE-BRUHN a B. LUDWIG. Determination of soil properties with visible to near- and mid-infrared spectroscopy: Effects of spectral variable selection. *Geoderma* [online]. 2014, **223-225**, 88-96 [cit. 2016-04-12]. DOI: 10.1016/j.geoderma.2014.01.013. ISSN 00167061. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0016706114000226>
- [147.] Vranov. *IN-Počasi* [online]. 2017 [cit. 2017-03-19]. Dostupné z: <http://www.in-pocasi.cz/meteostanice/stanice.php?stanice=vranov>
- [148.] WANG, Dandan, Somsubhra CHAKRABORTY, David C. WEINDORF, Bin LI, Aakriti SHARMA, Sathi PAUL a Md. Nasim ALI. Synthesized use of VisNIR DRS and PXRF for soil characterization: Total carbon and total nitrogen. *Geoderma* [online]. 2015, **243-244**, 157-167 [cit. 2017-01-04]. DOI: 10.1016/j.geoderma.2014.12.011. ISSN 00167061. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0016706114004455>
- [149.] WANG, Lingli a John J. QU. NMDI: A normalized multi-band drought index for monitoring soil and vegetation moisture with satellite remote sensing. *Geophysical Research Letters* [online]. 2007, **34**(20), - [cit. 2016-09-30]. DOI: 10.1029/2007GL031021. ISSN 0094-8276. Dostupné z: <http://doi.wiley.com/10.1029/2007GL031021>
- [150.] WILHITE, Donald A. *Drought and water crises: science, technology, and management issues* [online]. Boca Raton: Taylor, c2005 [cit. 2016-09-26]. ISBN 08-247-2771-1.
- [151.] WOLD, Svante, Michael SJÖSTRÖM a Lennart ERIKSSON. PLS-regression: a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems* [online]. 2001, **58**(2), 109-130 [cit. 2017-01-08]. DOI: 10.1016/S0169-7439(01)00155-1. ISSN 01697439. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0169743901001551>
- [152.] WOLF, Antonio. *Using WorldView 2 Vis - NIR MSI Imagery to Support Land Mapping and Feature Extraction Using Normalized Difference Index Ratios* [online]. DigitalGlobe, 2010, 1-13 s. [cit. 2017-03-20]. Dostupné z: [www.harrisgeospatial.com/portals/0/pdfs/envi/8\\_bands\\_Antonio\\_Wolf.pdf](http://www.harrisgeospatial.com/portals/0/pdfs/envi/8_bands_Antonio_Wolf.pdf)
- [153.] WORLD, H. Estimation of principal components and related models by iterative least squares. In P.R. Krishnaiah (Ed.). 1996. 391-420 [cit. 2017-01-08]. *Multivariate Analysis.*, New York, Academic Press.
- [154.] WorldView-2 Satellite Sensor. *Satellite Imaging Corporation* [online]. 2017c [cit. 2017-01-06]. Dostupné z: <http://www.satimagingcorp.com/satellite-sensors/worldview-2/>
- [155.] XING, Bao-Shan, Ju-Dong LIU a Xiao-Zeng HAN. Extraction and characterization of humic acids and humin fractions from a black soil of China. *Pedosphere* [online]. 2005, **15**(1), 1-8 [cit. 2016-10-04]. ISSN 1002-0160/CN 32-1315/P. Dostupné z:

[http://pedosphere.issas.ac.cn/trqcn/ch/reader/view\\_abstract.aspx?file\\_no=20050101&flag=1](http://pedosphere.issas.ac.cn/trqcn/ch/reader/view_abstract.aspx?file_no=20050101&flag=1)

- [156.] ZAJONCOVÁ, Ludmila a Vladimír VINTER. *Stanovení půdní reakce* [online]. UNIVERZITA PALACKÉHO V OLOMOUCI. 2013 [cit. 2017-01-03]. Dostupné z: <http://www.vedajezabava.upol.cz/docs/analyza%20pudy.pdf>
- [157.] Zheng LH, Li MZ, Pan L, Sun JY, Tang N. Estimation of soil organic matter and soil total nitrogen based on NIR spectroscopy and BP neural network [online]. 2008, *Guang Pu Xue Yu Guang Pu Fen Xi*. 2008. **28**(5):1160-4. Chinese. PubMed PMID: 18720824.
- [158.] ZORNOZA, R., C. GUERRERO, J. MATAIX-SOLERA, K.M. SCOW, V. ARCENEGUI a J. MATAIX-BENEYTO. Near infrared spectroscopy for determination of various physical, chemical and biochemical properties in Mediterranean soils. *Soil Biology and Biochemistry* [online]. 2008, **40**(7), 1923-1930 [cit. 2017-03-19]. DOI: 10.1016/j.soilbio.2008.04.003. ISSN 00380717. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0038071708001302>

## **PŘÍLOHY**

# SEZNAM PŘÍLOH

## **Vázané přílohy:**

Příloha 1    Manuál k softwaru SNAP 4.0

Příloha 2    Manuál k softwaru ENVI 4.7

## **Volné přílohy**

Příloha 3    Poster

Příloha 4    CD



## Příloha 1 – Manuál k softwaru SNAP 4.0

### ZÁKLADNÍ PRÁCE

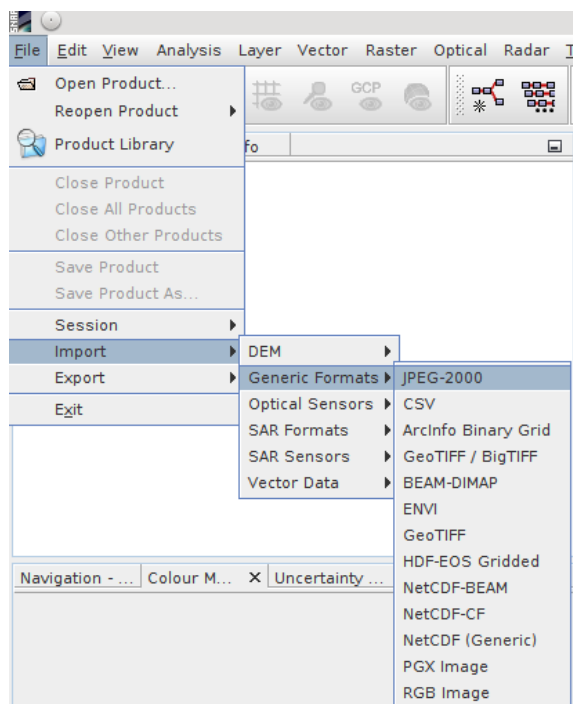
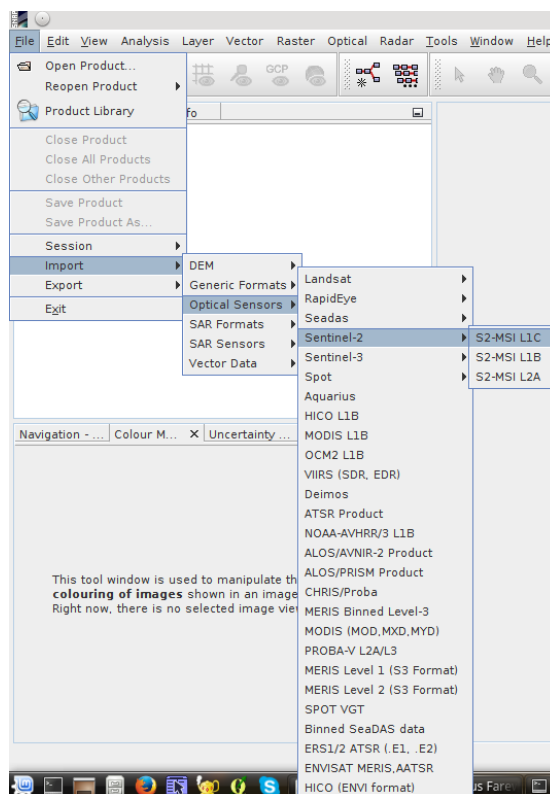
#### 1. načtení snímku

Pro načtení snímku je vhodné využít nástroj *Import* z nabídky *File*. Zde máme k dispozici šest nabídek, přičemž nás nejvíce zajímá část *Optical Sensors*, kde si vybíráme senzor, ze kterého jsou data, které se snažíme importovat.

V několika případech se dá dále vybírat i úroveň předzpracování jako třeba u *Sentinel-2* a například u nabídky *Landsat* vybíráme, zda se jedná o snímek ze systému 7, 8 apod.

V případě načítání snímku z *Sentinel-2*, ve většině případů vybereme *S2-MSI L1C*, což značí úroveň předzpracování Level 1C, který je od 6. prosince 2016 dostupný na Sentinel Scientific Data Hub, kde máme tyto snímky volně k dispozici.

Dále vybereme XML soubor s metadaty pro příslušný snímek.

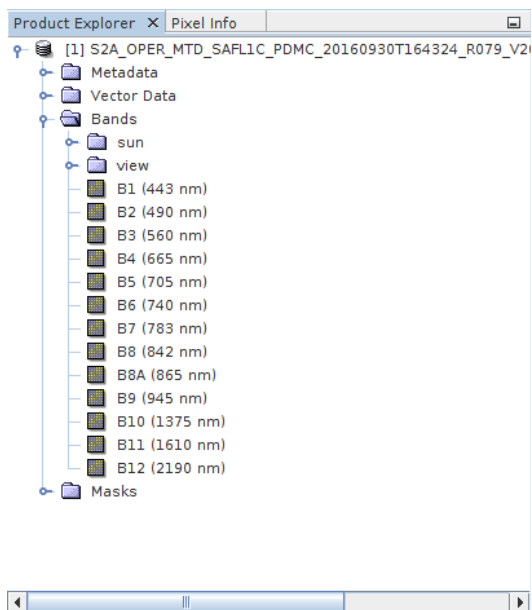


Pokud máme k dispozici nějaký snímek, který nebyl vytvořen žádným se senzorů z nabídky, nebo snímek, který už byl nějak zpracovaný, je zapotřebí ho importovat na základě formátu.

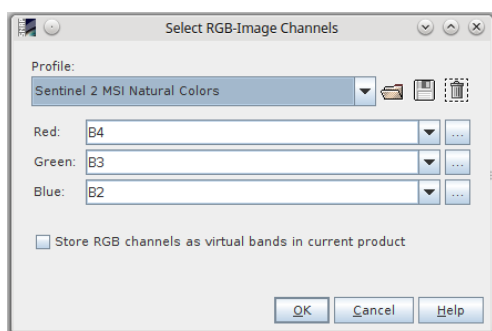
To provedeme tak, že opět z nabídky *File* – *Import* vybereme *Generic Formats* a zde následně zvolíme formát, ve kterém máme naše data.

Snímek se nám otevře v levém okně s názvem *Product Explorer*. V další záložce je k dispozici ještě *Pixel Info*, která se hodí při určování hodnot zobrazených pixelů pointrem. Níže můžete vidět ještě několik dalších panelů pro práci se snímkem. Tyto všechny panely je možné zapínat a vypínat v nabídce *View – Tool Windows*.

V *Product Explorer* máme 4 skupiny dat u jednoho snímku. *Metadata*, která nám poskytují informace o snímku, *Vector Data*, která jsou ve většinu případů prázdná, protože slouží pro přidání například GCP, *Band*, kde najdeme naše pásma a doplňující informace o azimutu a zenitu u jednotlivých pásmech a slunce. V poslední skupině *Masks* nalezneme několik masek ukazující například oblačnost, *NoData* v jednotlivých pásmech, *detector foot print* apod.



Popsané kategorie se vztahují k původnímu snímku ze Sentinelu-2. U jiného satelitního systému mohou některé části chybět nebo nebyť naplněny daty.



Pro zobrazení snímků klikneme pravým na název a vybereme zobrazení podle požadovaného barevného modelu – *Open RGB Image Window* nebo *Open HSV Image Window*. V zobrazeném okně si vybereme pásma které chceme zobrazit. U Sentinelu máme předchystané barevné modely, ale u některých dalších si musíme pásma sami vybrat, ale existuje možnost uložení modelu pro pozdější užití.

## 2. metadata


Name	Value	Type	Unit	Description
Orbit_State_Vectors				
SRGR_Coefficients				
Doppler_Centroid_Coefficients				
PRODUCT	S2A_OPER_MTD_SAF1LC_PDMC_20160930T164324_R079_V2	ascii		Product name
PRODUCT_TYPE	S2_MSI_Level-1C	ascii		Product type
SPH_DESCRIPTOR	-	ascii		Description
MISSION	SENTINEL-2-MSI-MultRes-UTM33N	ascii		Satellite mission
ACQUISITION_MODE	-	ascii		Acquisition mode
antenna_pointing	-	ascii		Right or left facing
BEAMS	-	ascii		Beams used
SWATH	-	ascii		Swath name
PROC_TIME	01-JAN-2000 00:00:00.000000	uint32	utc	Processed time
Processing_system_identifier	-	ascii		Processing system identifier
orbit_cycle	99999	int32		Cycle
REL_ORBIT	99999	int32		Track
ABS_ORBIT	99999	int32		Orbit
STATE_VECTOR_TIME	01-JAN-2000 00:00:00.000000	uint32	utc	Time of orbit state vector
VECTOR_SOURCE	-	ascii		State vector source
incidence_near	99.999	float64	deg	
incidence_far	99.999	float64	deg	

V předchozí kapitole bylo popsáno, že metadata je možné nalézt v jedné ze skupině informací o snímku po jeho načtení. Metadata se dělí do velkého množství skupin a kategorií a jsou velmi podrobně propracována. Bohužel ani u Sentinelu, pro který jsou primárně určena nejsou vyplněny všechny údaje.

### 3. zvýraznění snímku

Metody zvýrazňování obrazu zde nemají takové možnosti jako například v softwaru ENVI.

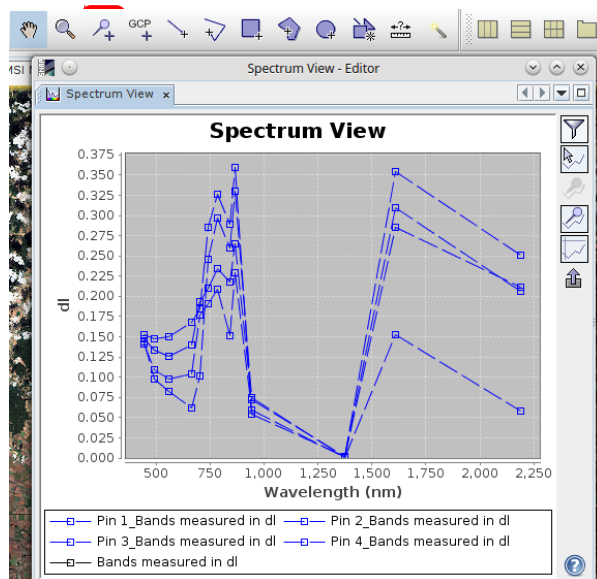
V levém panelu ve spodní části je k dispozici panel *Colour Manipulation*. Zde můžeme pomocí dvou trojúhelníčků posunout zobrazenou část dle histogramu. K dispozici jsou také v pravé části tlačítka, které nám například ořezou zobrazenou část a zobrazí jen 95%. Musíme si ale vybrat, na kterém pásmu ze třech zobrazených toto chceme provést.



Po rozkliknutí *More Options* můžeme zvolit v části *Histogram Matching* způsob úpravy zobrazení. Bohužel máme k dispozici jen *Equalize* a *Normalize* a zase volíme, na které pásmo toto chceme aplikovat.

Přesnost zobrazeného histogramu a tak i přesnost celého zvýraznění můžeme zvážit tím, že klikneme na *Rough Statistic* v okně histogramu. To nám vypočítá přesnější histogram.

### 4. spektrální charakteristiky

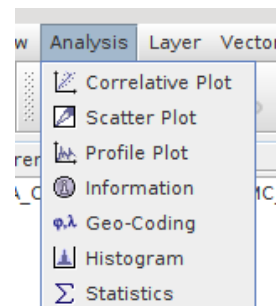


Pro zobrazení spektrální křivky odrazivosti existuje nástroj *Spectrum View*, který nalezneme v nabídce *Optical*. Následně můžeme pointrem přejíždět po snímku a zobrazovat si spektrální charakteristiky v místech kde se zrovna nachází pointer. Pro zobrazení charakteristik v určitých bodech musíme použít nástroj *Pin Placing Tool* a naklikat naše body. Ty poté zobrazí v grafu pomocí nástroje *Show spectra for all pins*. Oba nástroje jsou zvýrazněny na obrázku vedle. Grafický výstup lze upravit, když


klikneme pravým na graf a zvolíme *Properties*. Spektra lze následně exportovat posledním tlačítkem ve formátu CSV.

## 5. Statistika

Pro počítání nejrůznějších statistik máme k dispozici balík nástrojů *Analysis* v hlavním panelu. Máme zde k dispozici množství nástrojů, které poskytují statistické charakteristiky a grafy jako *Correlative Plot*, *Scatter Plot*, *Histogram* atd. Zde si můžeme například pomocí *Profile Plot* zobrazit křivku odrazivosti v předem definované vektorové linii.



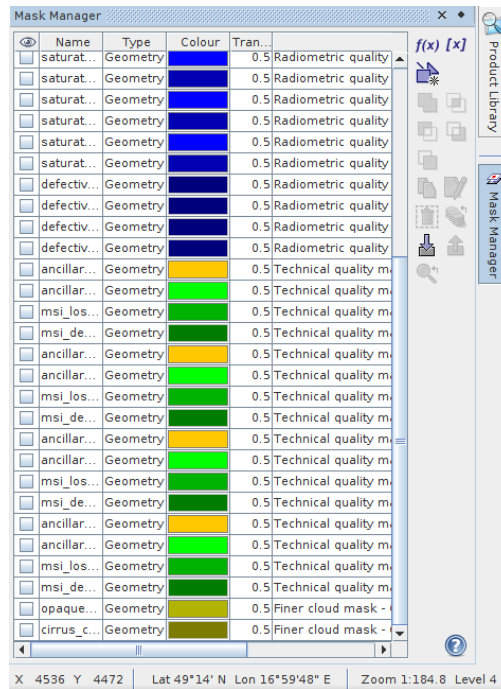
Pomocí nástroje *Statistics* je možné vypočítat souhrnné statistiky pro celé zájmové pásmo, které ale musíme mít nejprve zakliknuté v *Product Explorer* (popsáno výše). Po otevření nástroje musíme kliknout na dvě šipky vytvářející svým průběhem kruh, abychom statistiky spočítali.



V případě, že chceme statistiky jen lokální pro zájmové území, musíme si nejprve definovat ROI (region of interest) nebo vybrat z nějaké masky, kterou už daný snímek může obsahovat. ROI můžeme vytvořit z nějakého existujícího vektorového souboru nebo úplně nově kdy použijeme jeden z nástrojů z panelu níže.

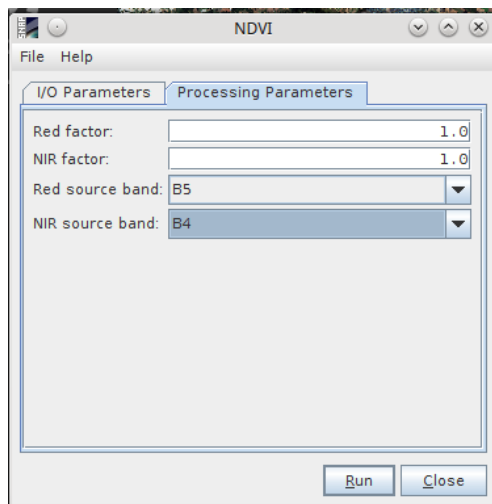
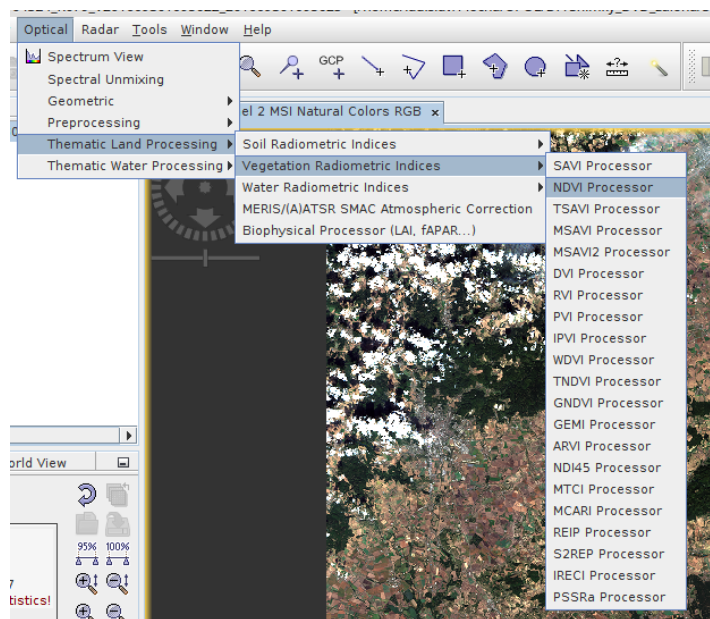


Tato vrstva je pak uložena pouze jako dočasný soubor a nalezneme jej v seznamu masek jako masku s názvem *geometry*. Jednotlivé masky lze také spravovat v panelu *Mask Manager*, který se nachází v pravé části nebo si ho můžeme zobrazit v nabídce *View*. Můžeme přidávat, mazat, měnit popisek, barvu ale také dočasnou masku exportovat. Exporty a importy zde probíhají pomocí formátu XML.



## 6. indexy

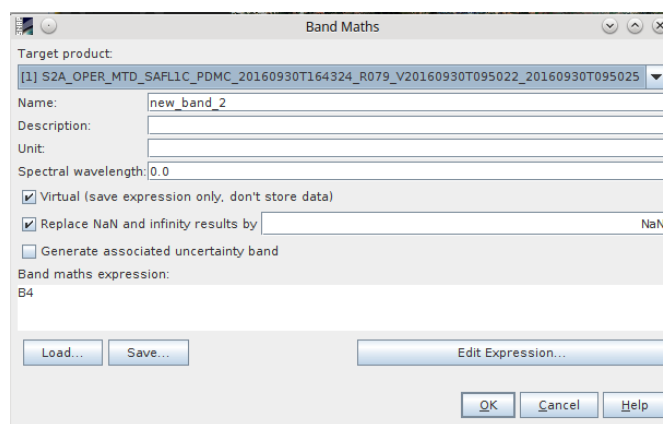
Pro počítání indexů mezi pásmy slouží balík nástrojů *Thematic Band processor*, který se nachází v balíku nástrojů *Optical*. V tomto balíku je několik předdefinovaných indexů, které jsou řazeny do čtyřech kategorií. Například NDVI s názvem *NDVI Processor* se nachází v balíku *Vegetation Radiometric Indices*



Při aplikaci konkrétního indexu máme k dispozici dvě záložky. Na první *I/O Parametres* zvolíme zdrojový snímek a výstup, kde máme k dispozici asi 18 formátů.

Na druhé záložce *Processing Parameters* zvolíme zdroj jednotlivých pásem a můžeme nastavit k jednotlivým pásmům také faktory.

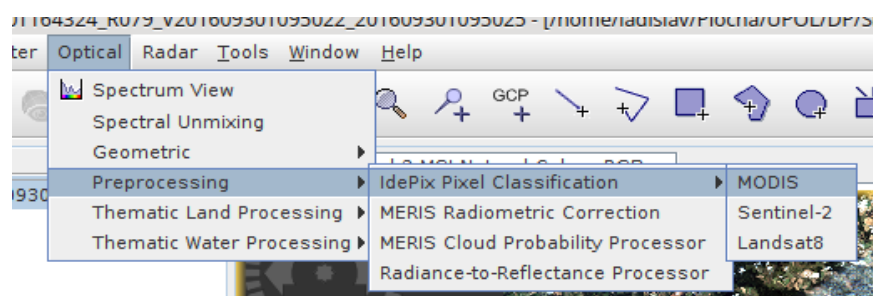
V případě, že mezi indexy nenalezneme žádný, který chceme použít, máme k dispozici nástroj *Band Math* v panelu *Raster*. Zde si vlastní rovnicí pomocí *Edit Expression* můžeme vytvořit námi požadovaný index a k němu si zvolit příslušná pásma.



## **PŘEDZPRACOVÁNÍ DAT**

### 1. radiometrické korekce

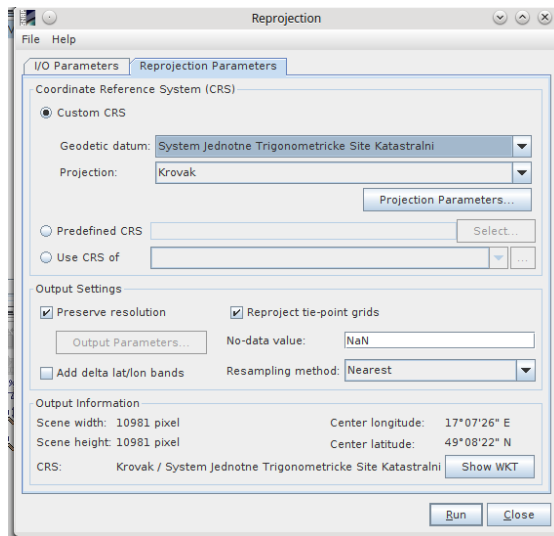
Pro radiometrické korekce se v tomto softwaru používá balík nástrojů *Preprocessing* v záložce *Optical*. Máme k dispozici čtyři nástroje, které fungují jako black box, a tudíž do nich nevidíme. Jedná se o modely, do kterých můžou vstupovat nějaké podpůrné soubory s metadaty. Samotným procesem se ale tolik zabývat zde nebudeme, protože na většině dostupných snímků už tyto korekce proběhly.



### 2. atmosférické korekce

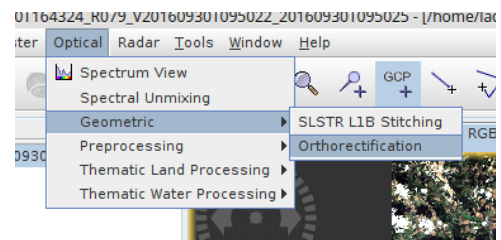
V tomto softwaru není k dispozici žádný známý balík na atmosférické korekce. Využívají se pouze nástroje s balíku *Preprocessing*, který byl popsán výše.

### 3. geometrické korekce



Pro geometrické korekce máme dva hojně používané nástroje. Jedním z nich je Reprojecting, který nalezneme v záložce Raster pod volbou Geometric Operations. Zde si kromě vstupních a výstupních dat na další záložce volíme výslednou projekci a souřadnicový systém. Velkou výhodou pro českou lokalizaci je, že v tomto softwaru je již k dispozici Křovák (EPSG: 5514).

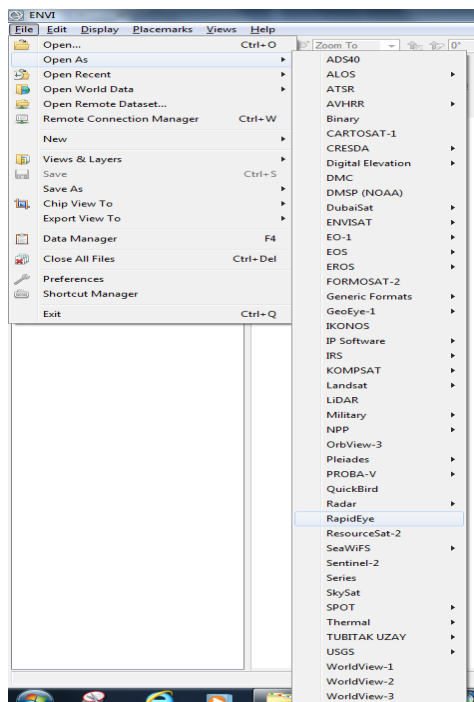
Dalším je nástroj Orthorectification, který nalezneme pod Optical – Geometric. Zde musíme zvolit výsledný souřadnicový systém a na druhé záložce zvolit vstupní a výstupní data a poté stisknout Run a provést ortorektifikaci. Právě se vstupními daty se ale vyskytuje problém. Při načtení jakéhokoliv snímku do tohoto nástroje, software zahlásí chybu.



## Příloha 2 – Manuál k softwaru ENVI 4.7

### ZÁKLADNÍ PRÁCE

#### 1. Načtení snímku

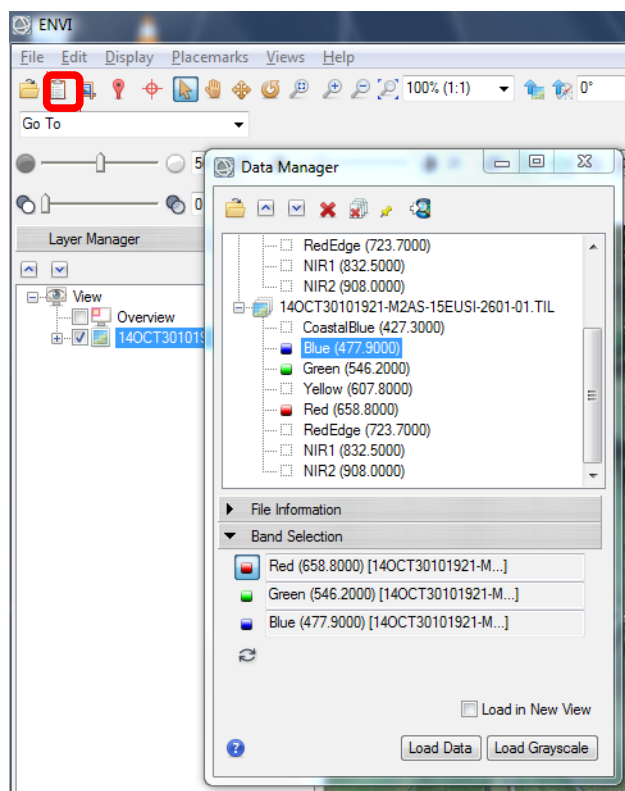


Pro načtení snímku je vhodné použít *File – Open As* a následně si vybrat příslušný senzor.

Pozn.: U některých snímků je k dispozici i formát. V našem případě u snímků ze SPOT-6 a Pleiades-1A vybíráme formát *DIMAP (\*.XML)*.

Snímek se otevře v základní kombinaci pásem (většinou RGB). Kombinace se dá změnit v *Data Manageru*, kde lze uživatelsky měnit zobrazená pásma

Pozn.: V případě, že mámě každé pásmo ve zvláštní vrstvě, je možné využít funkci z toolboxu *Layer Stack*.



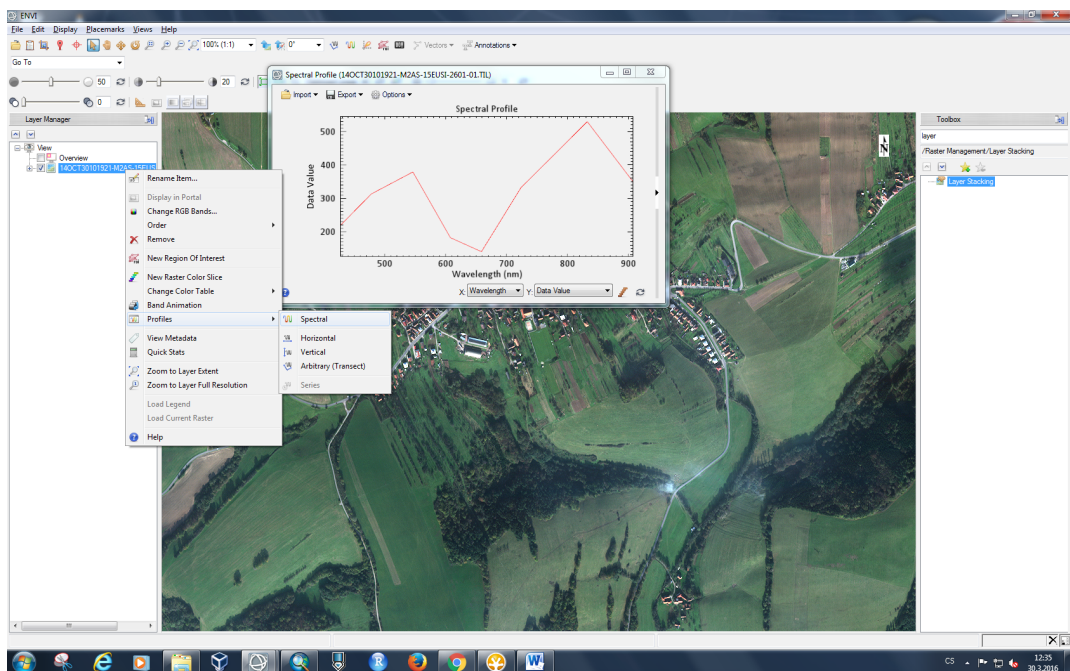


## 2. Metadata

Metadata jsou k nalezení po kliknutí pravým tlačítkem myši na název snímku a stisknutí *View metadata*. Pokud snímek otevřeme přes *Open As* s vybráním senzoru a údaje jsou u snímku k dispozici, zobrazí se zde veškeré informace, včetně údajů pro korekce.

## 3. Spektrální charakteristiky

K zobrazení spektrální křivky existuje několik cest. Jako nejvhodnější byla zvolena cesta: kliknout pravým tlačítkem myši na název snímku, najet na *profiles* a vybrat *spectral*.



Při ponechání otevřeného grafu můžeme, pomocí šipky z nástrojové lišty kliknout kamkoliv do snímku a tím zobrazíme spektrální charakteristiku jednotlivého pixelu v grafické podobě. Pomocí červeného křížku s kolečkem je možné zobrazit hodnoty pixelu v jednotlivých pásmech v textové podobě.

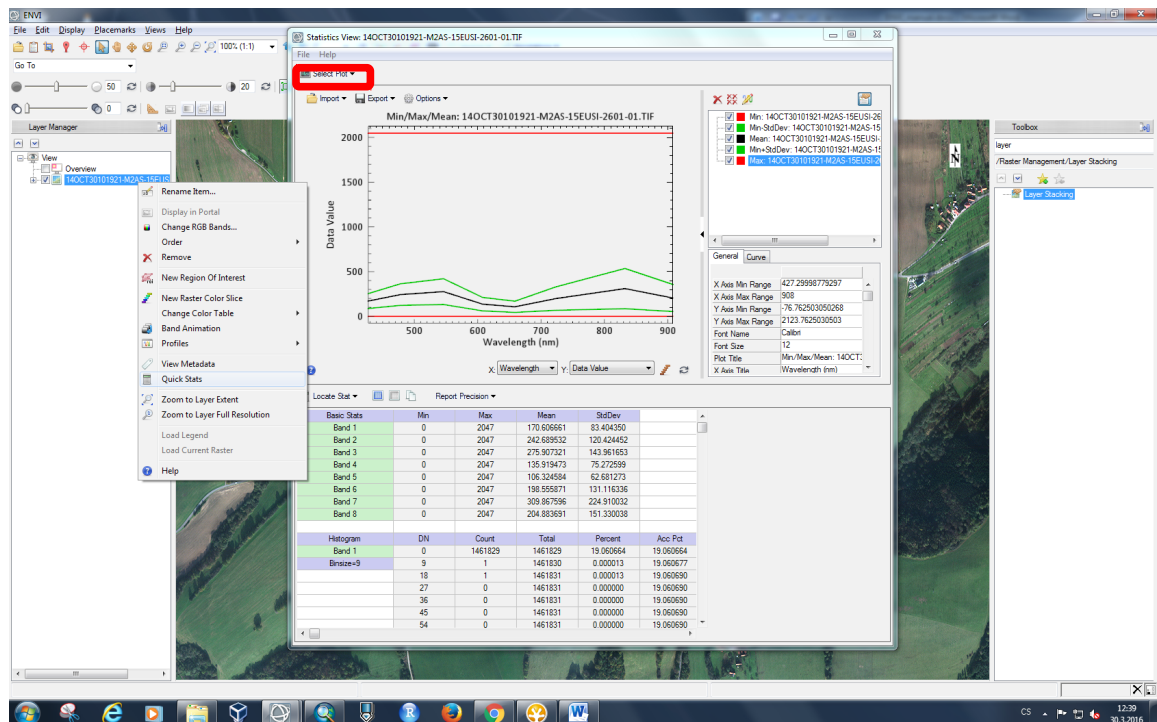


Dále je možné zobrazit hodnoty odrazivosti v určitém profilu (horizontální, vertikální) nebo ve vlastní křivce. Zobrazíme je stejným postupem jako bylo uvedeno dříve, jen místo *spectral* zvolíme *Horizontal*, *Vertical* nebo *Arbitrary (Transect)*. Pro zobrazení více spektrálních křivek dohromady existuje několik způsobů. Asi nejkomplikovanější je provést *export to ASCII* a v grafu, do kterého chceme předchozí křivku vložit, použijeme *import to ASCII*. Další možností je jednoduše přetáhnout křivku (položku v seznamu křivek zobrazených v grafu) do dalšího grafu. V případě, že máme vizualizovanou křivku pro bod (pixel), můžeme podržet tlačítko *Shift* a kliknout na další pixel ve snímku.

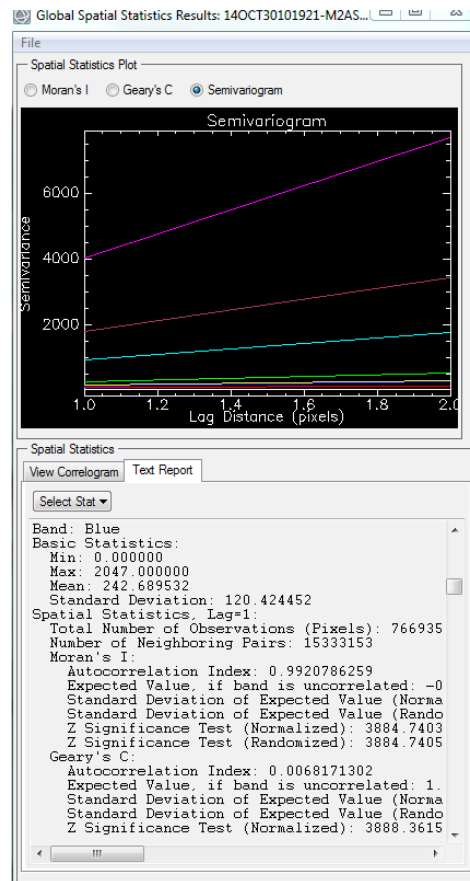
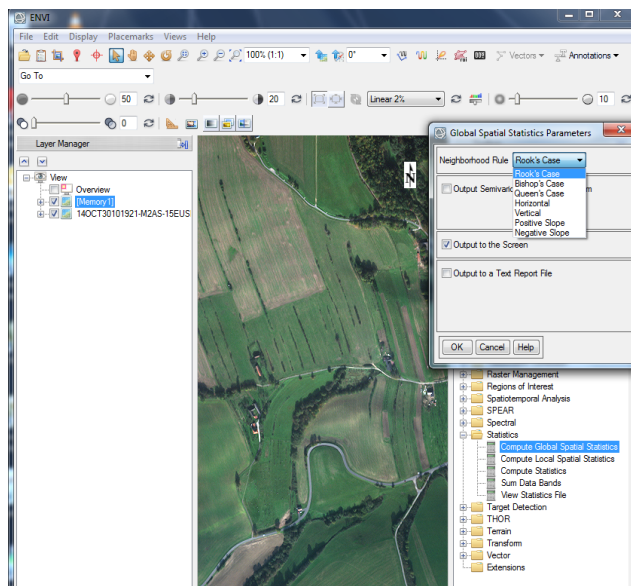
#### 4. Statistika

V ENVI jsou rozděleny na tři druhy: základní, globální a lokální:

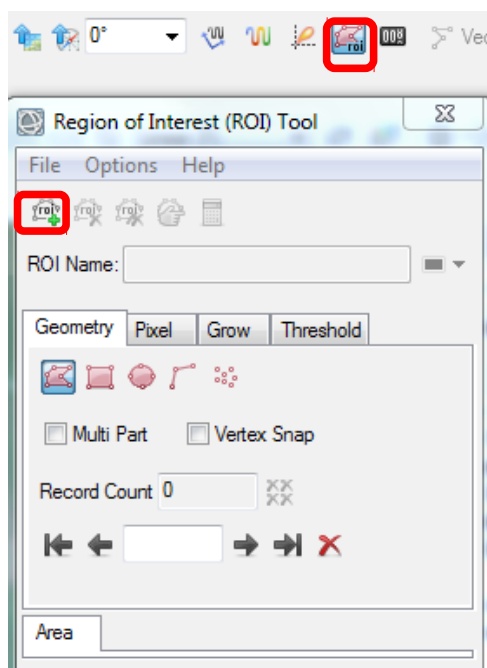
Základní statistiky se spočítají po kliknutí pravým tlačítkem myši na název snímku a výběru *Quick Stats*. Zobrazí se min, max, průměr, směrodatná odchylka, histogram pro jednotlivá pásma apod.. Lze se také přepínat mezi grafy – celkové, histogramy pro jednotlivá pásma apod. Data lze následně exportovat. Základní statistiky lze spočítat také pomocí nástroje z toolboxu *Compute Statistics*, u kterého je možné zvolit rozsah pásem, masku apod. Dá se ještě vybrat možnost spočítat navíc kovarianci a statistiky rovnou uložit.



Globální statistiky pro celý snímek ve všech pásmech se spočítají pomocí nástroje z toolboxu s názvem *Compute Global Spatial Statistics*. Je zde také možné vybrat masku, rozsah pásem apod. Následně se zvolí pravidlo sousedství, dle kterého budou hodnoty počítány a zda chceme vypočítat i semivariogram a korelogram a pro kolik pixelů. V základu globální statistiky vypočítají hodnoty Moran's I a Geary's C pro každé pásmo.

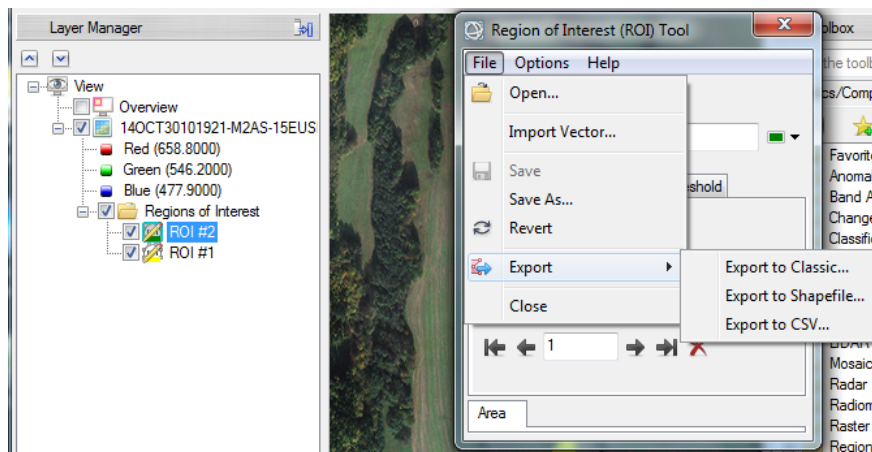


Lokální statistiky je nevhodnější dělat pomocí ROIs (Regions of Interest). Vytvoříme si tyto plochy a z nich vypočteme statistiky. Pokud již máme oblast vytvořenou v nějaké další vrstvě, je možné zvolit nástroj *Compute Local Spatial Statistic*, kde naši vrstvu vybereme. Zde se budeme věnovat jen lokálním statistikám pomocí ROIs.



Zaklikneme vrstvu nad kterou chceme tvořit ROIs a otevřeme nástroj pro tvorbu těchto oblastí.

Nové ROI lze dělat podle několika metod. Nejvíce využívané je na základě geometrie nebo polohy a množství pixelů. Tyto plochy pojmenujeme a například pomocí geometrie vybereme zájmovou oblast. V případě že chceme nový polygon, ale ve stejné kategorii (ROI), klikneme jen na šipku doprava a vymezujeme další oblast. Pokud chceme novou kategorii (nový ROI), klikneme nahoře na tlačítko ROI se zeleným plus a můžeme pokračovat. Vytvořené ROI se ukládají jen do dočasné paměti ale lze je uložit (*Save as*) ve formátu XML, který ale další analýzy v ENVI tolik nepodporují nebo exportovat (*Export*) do formátů ROI, SHP a CSV.

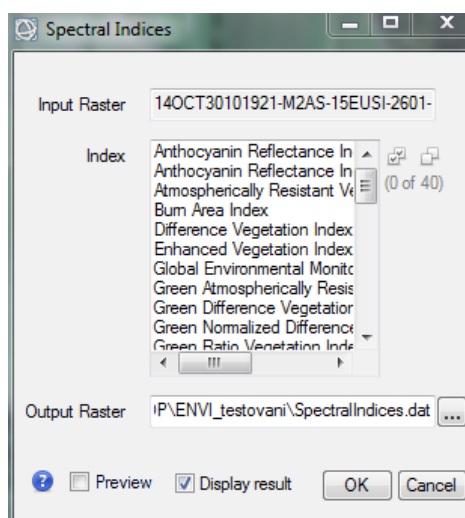


Z těchto ploch vypočteme statistiky buď v okně pro tvorbu ROIs: *Options* → *Compute statistics from ROIs*, kde si vybereme pro které plochy statistiky chceme a nebo klikneme v okně *Layer Manager* pravým na *Region of Interest* a zvolím *Statistics for All ROIs*.

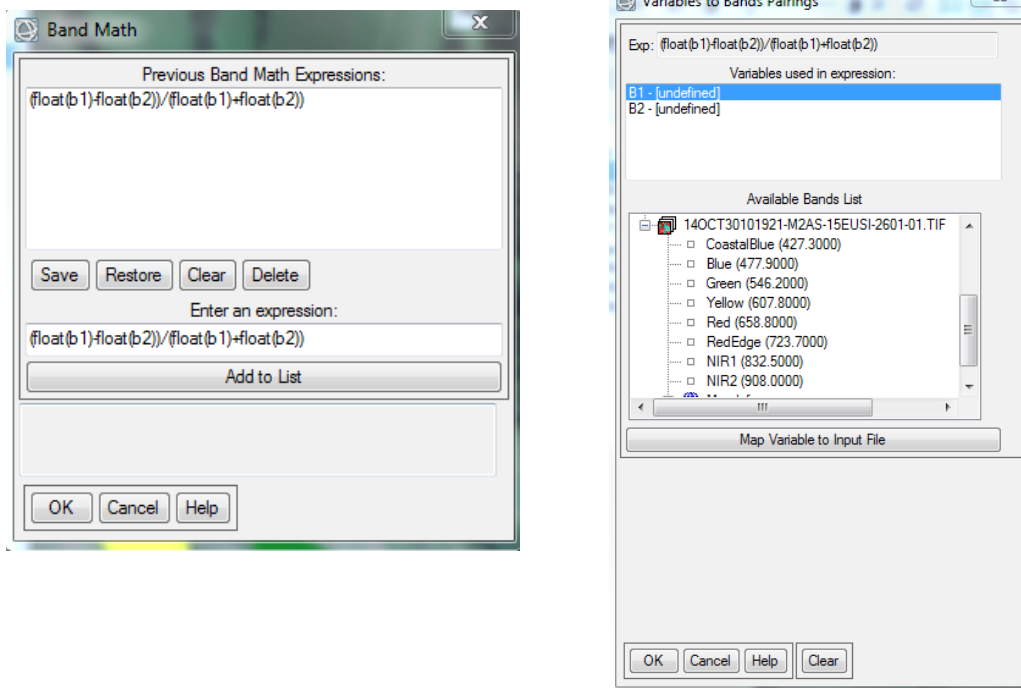
## 5. Indexy

Pro počítání mezi pásmy slouží balík nástrojů *Band Algebra* v toolboxu. V balíku jsou tři nástroje. První je *Band Ratios* pro počítání poměrů mezi pásmy. Další nástroj *Spectral Indices* obsahuje předdefinované indexy.

Pozn.: Nástroj ukládá moure do formátu DAT, což je interní formát ENVI



Třetím nástrojem ve zmiňovaném balíku je *Band Math*, ve kterém si můžeme zapsat vlastní indexy. Před jednotlivá pásma v rovnici je potřeba napsat *float*, jinak je výstupem pouze černý snímek. Jako pásma se v prvním kroku napíší proměnné, ke kterým se v druhém kroku přiřadí příslušná pásma. Oba kroky je možné vidět níže na příkladu NDVI.



## **PŘEDZPRACOVÁNÍ DAT**

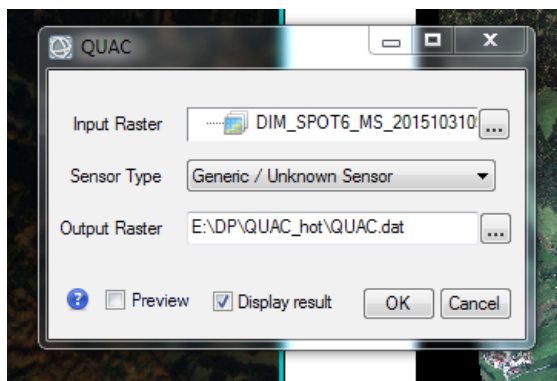
### 1. Radiometrické korekce

Pro radiometrické korekce je v toolboxu celý velký balík nástrojů. Ovšem tyto korekce na všech pořízených snímcích již proběhly, takže se jimi zabývat nebudeme.

### 2. Atmosferické korekce

V ENVI jsou pro atmosférické korekce dostupné dva modely: *QUAC* a *FLAASH*. Pro naši práci bude využit model *QUAC*, který je používanější. Do modelu mohou vstupovat pouze multispektrální a hyperspektrální snímky.

Spustíme nástroj *Quick Atmospheric Correction (QUAC)* a vybereme náš snímek. Následně vybereme senzor, ze kterého je snímek pořízen. V případě, že náš senzor není v nabídce, ponecháme *Generic/Unknown Sensor*. V nabídce jsou kromě senzorů ještě možnosti *Highly Vegetated Scenes*, *Near Infrared (NIR)* a *Near-Shortwave Infrared (NIR-SWIR)*. Tyto další možnosti jsou ovšem pouze



pro hyperspektrální data. Nakonec nastavíme výstup. Korekce proběhnou na pozadí. Do modelu nevidíme a nic v něm nenastavujeme.

### 3. Geometrické korekce

Zakoupené snímky už mají některé geometrické korekce. Jsou také transformovány do souřadnicového systému. Na snímcích nebyla provedena ortorektifikace, která ovšem může být pro naše účely vynechána. Naše geometrické korekce je vhodné provést až po atmosférických, protože během transformace a uložení do jiného formátu se ztratí některá metadata, která jsou důležitá pro atmosférické korekce.

Pomocí nástroje *Reproject Raster* v balíku *Raster Management* je možné snímky transformovat do jiného souřadnicového systému (např. EPSG: 5514). Je potřeba zvolit snímek, výsledný souřadnicový systém a parametry konverze. Metoda převzorkování byla zvolena pro naše účely *Nearest Neighbor* s krokem (Grid Spacing) 15 a ostatní hodnoty byly dopočítány na základě *Triangulace*. Výstupní formát se musí nechat ENVI. Další možnost je TIFF, ale do tohoto formátu nejde uložit transformovaný snímek v epsg:5514.

