

**Univerzita Pardubice
Fakulta ekonomicko-správní
Ústav systémového inženýrství a informatiky**

Identifikace změn v krajině na základě družicových dat

Jiří Kopřiva

**Diplomová práce
2019**

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Jiří Kopřiva**
Osobní číslo: **E16672**
Studijní program: **N6209 Systémové inženýrství a informatika**
Studijní obor: **Regionální a informační management**
Název tématu: **Identifikace změn v krajině na základě družicových dat**
Zadávající katedra: **Ústav systémového inženýrství a informatiky**

Z á s a d y p r o v y p r a c o v á n í :

Cílem práce je identifikovat změny ve vybraném území Železných hor. Součástí práce bude výběr vhodných družicových dat. Využity budou metody spektrálního zvýraznění obrazu a automatické klasifikace.

Osnova:

- Úvod do problematiky dálkového průzkumu Země.
- Charakteristika vybraného zájmového území.
- Výběr dat a identifikace změn ve zvoleném zájmovém území.
- Vizualizace a interpretace výsledků.

Rozsah grafických prací:

Rozsah pracovní zprávy: **cca 50 stran**

Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam odborné literatury:

DOBROVOLNÝ, P. Dálkový průzkum Země: Digitální zpracování obrazu. Brno: MU Brno, 1998. ISBN 80-210-1812-7.

HALOUNOVÁ, L., PAVELKA, K. Dálkový průzkum Země. V Praze: Česká technika - nakladatelství ČVUT, 2005. ISBN 80-01-03124-1.

KHORRAM, S. Remote sensing. Berkeley, CA: Springer, c2012. SpringerBriefs in space development. ISBN 978-1-4614-3102-2.

KUPKOVÁ, L., KRÁL, L. Země očima satelitů: vzdělávací modul Geografie: výukový a metodický text. 1. Vyd. Praha: Nakladatelství P3K s. r. o., 2011. ISBN 978-80-87186-55-8.

LILLESAND, T. M., KIEFER, R.W. Remote Sensing and Image Interpretation. 4th ed. N.York: John Wiley and Sons, 2000. ISBN 978-0471255154.

PAVELKA, K. Dálkový průzkum Země. 1. vyd. Praha: Vydavatelství ČVUT, 2005. ISBN 80-01-03124-1.

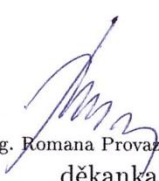
Vedoucí diplomové práce:


doc. Ing. Jitka Komárková, Ph.D.


Ústav systémového inženýrství a informatiky

Datum zadání diplomové práce: **3. září 2018**

Termín odevzdání diplomové práce: **30. dubna 2019**


doc. Ing. Romana Provažníková, Ph.D.
děkanka

L.S.


doc. Ing. Pavel Petr, Ph.D.
vedoucí ústavu

V Pardubicích dne 3. září 2018

PROHLÁŠENÍ

Prohlašuji, že jsem tuto práci vypracoval/a samostatně. Veškeré literární prameny a informace, které jsem v práci využil/a, jsou uvedeny v seznamu použité literatury.

Byl/a jsem seznámen/a s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorský zákon, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako Školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 9/2012, bude práce zveřejněna v Univerzitní knihovně a prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 30. 4. 2019

Bc. Jiří Kopřiva

PODĚKOVÁNÍ:

Tímto bych rád poděkoval své vedoucí práce doc. Ing. Jitce Komárkové, Ph.D. za její odbornou pomoc, cenné rady a poskytnuté materiály, které mi pomohly při zpracování diplomové práce.

ANOTACE

Tato diplomová práce se zabývá identifikací změn v krajině na základě družicových dat. Nejprve je v úvodní části uvedena problematika dálkového průzkumu Země. V další fázi je provedena rešerše odborných studií, na základě které, budou vybrány metody pro provedení klasifikace družicových snímků. Nakonec byla analyzována vybraná zájmová oblast a provedena samotná klasifikace družicových snímků.

KLÍČOVÁ SLOVA

klasifikace, spektrální index, dálkový průzkum Země, Landsat

TITLE

Identification of landscape changes based on satellite data

ANNOTATION

The thesis deals with the identification of landscape changes based on satellite data. Firstly, the introductory part introduces the issue of remote sensing. Secondly, a review of expert studies is carried out, based on which methods will be selected for performing the classification of satellite images. Finally, the selected area of interest is analyzed and the satellite images are classified.

KEYWORDS

classification, spectral index, remote sensing, Landsat

OBSAH

SEZNAM TABULEK	8
SEZNAM OBRÁZKŮ	9
SEZNAM GRAFŮ	9
ÚVOD	12
1. DÁLKOVÝ PRŮZKUM ZEMĚ	13
1.1. PODSTATA DPZ.....	13
1.2. DRUŽICOVÉ SYSTÉMY	14
1.3. KLASIFIKACE OBRAZU	15
1.3.1. Řízená klasifikace.....	15
1.3.2. Neřízená klasifikace	17
1.4. KOREKCE	18
2. SHRNTÍ STÁVAJÍCÍHO STAVU	19
2.1. ODBORNÉ STUDIE.....	19
2.2. CELKOVÉ SHRNTÍ KLASIFIKAČNÍCH TŘÍD	27
2.3. CELKOVÉ SHRNTÍ KLASIFIKAČNÍCH METOD A ZDROJŮ SNÍMKŮ	29
3. VÝBĚR METOD A PROGRAMOVÉ PROSTŘEDÍ	30
3.1. KLASIFIKACE POMOCÍ SPEKTRÁLNÍCH INDEXŮ	30
3.2. METODY ŘÍZENÉ KLASIFIKACE	31
3.2.1. Algoritmus podpůrných vektorů (SVM)	31
3.2.2. Klasifikátor maximální pravděpodobnosti (MLC)	31
3.2.3. Klasifikátor minimálních vzdáleností (MINDP)	32
3.2.4. Mahalanobiův klasifikátor minimálních vzdáleností (MAHADP).....	32
3.3. HODNOCENÍ PŘESNOSTI KLASIFIKACE	32
3.3.1. Celková přesnost klasifikace	32
3.3.2. Kappa koeficient.....	33
3.4. ZVOLENÉ PROGRAMOVÉ PROSTŘEDÍ.....	33
4. ANALÝZA VYBRANÉHO ÚZEMÍ	35
4.1. CHARAKTERISTIKA ZÁJMOVÉ ÚZEMÍ	35
4.2. VÝBĚR A STAŽENÍ DAT.....	36
5. ZDROJOVÁ DATA A VÝBĚR RELEVANTNÍCH SPEKTRÁLNÍCH INDEXŮ	39
5.1. ZDROJOVÁ DATA	39
5.2. VÝBĚR RELEVANTNÍCH SPEKTRÁLNÍCH INDEXŮ	40
6. KLASIFIKACE DAT A OVĚŘENÍ PŘESNOSTI KLASIFIKACE	46
6.1. KLASIFIKACE DAT ZA OBDOBÍ ROKU 2013.....	47
6.2. KLASIFIKACE DAT ZA OBDOBÍ ROKU 2016.....	53
6.3. KLASIFIKACE DAT ZA OBDOBÍ ROKU 2018.....	60
6.4. VYHODNOCENÍ ZMĚN V ZÁJMOVÉM ÚZEMÍ	68
ZÁVĚR	72
POUŽITÁ LITERATURA	73
SEZNAM PŘÍLOH	78

SEZNAM TABULEK

TABULKA 1: PŘEHLED VYHLEDÁVANÝCH KLÍČOVÝCH SLOV A NALEZENÝCH VÝSLEDKŮ VE WOS 19	
TABULKA 2: PŘEHLED PŘESNOSTI KLASIFIKAČNÍCH METOD VE STUDII Č. 1	20
TABULKA 3: PŘEHLED PŘESNOSTI KLASIFIKAČNÍCH METOD VE STUDII Č. 2	20
TABULKA 4: PŘEHLED PŘESNOSTI KLASIFIKAČNÍCH METOD VE STUDII Č. 3	21
TABULKA 5: PŘEHLED PŘESNOSTI KLASIFIKAČNÍCH METOD VE STUDII Č. 4	22
TABULKA 6: PŘEHLED PŘESNOSTI KLASIFIKAČNÍCH METOD VE STUDII Č. 8	24
TABULKA 7: PŘEHLED PŘESNOSTI KLASIFIKAČNÍCH METOD VE STUDII Č. 9	24
TABULKA 8: PŘEHLED PŘESNOSTI KLASIFIKAČNÍCH METOD VE STUDII Č. 12	25
TABULKA 9: PŘEHLED PŘESNOSTI KLASIFIKAČNÍCH METOD VE STUDII Č. 13	26
TABULKA 10: PŘEHLED PŘESNOSTI KLASIFIKAČNÍCH METOD VE STUDII Č. 14	26
TABULKA 11: PŘEHLED PŘESNOSTI KLASIFIKAČNÍCH METOD VE STUDII Č. 15	27
TABULKA 12: CELKOVÉ SHRNUÍ KLASIFIKAČNÍCH TŘÍD A JEJICH ČETNOSTI.....	27
TABULKA 13: CELKOVÉ SHRNUÍ KLASIFIKAČNÍCH METOD A JEJICH PŘESNOSTI	29
TABULKA 14: PŘÍKLAD CHYBOVÉ MATICE.....	33
TABULKA 15: LANDSAT 8 PŘEHLED PÁSEM A VYUŽITÍ.....	37
TABULKA 16: MNOŽSTVÍ TRÉNOVACÍCH BODŮ PRO JEDNOTLIVÉ TŘÍDY ZA ROK 2013.....	47
TABULKA 17: PŘEHLED PŘESNOSTÍ KLASIFIKAČNÍCH METOD ZA SLEDOVANÉ OBDOBÍ V ROCE 2013	47
TABULKA 18: CHYBOVÁ MATICE V RÁMCI METODY SVM (LIN) ZA SLEDOVANÉ OBDOBÍ V ROCE 2013	47
TABULKA 19: PLOCHY JEDNOTLIVÝCH TŘÍD V RÁMCI METODY SVM (LIN) ZA SLEDOVANÉ OBDOBÍ V ROCE 2013.....	49
TABULKA 20: CHYBOVÁ MATICE V RÁMCI METODY SVM (RBF) ZA SLEDOVANÉ OBDOBÍ V ROCE 2013	49
TABULKA 21: PLOCHY JEDNOTLIVÝCH TŘÍD V RÁMCI METODY SVM (RBF) ZA SLEDOVANÉ OBDOBÍ V ROCE 2013.....	51
TABULKA 22: CHYBOVÁ MATICE V RÁMCI METODY MLC ZA SLEDOVANÉ OBDOBÍ V ROCE 2013.....	51
TABULKA 23: PLOCHY JEDNOTLIVÝCH TŘÍD V RÁMCI METODY MLC ZA SLEDOVANÉ OBDOBÍ V ROCE 2013.....	52
TABULKA 24: PŘEHLED KLASIFIKAČNÍCH METOD ZA SLEDOVANÉ OBDOBÍ V ROCE 2016.....	53
TABULKA 25: CHYBOVÁ MATICE V RÁMCI METODY SVM (LIN) ZA SLEDOVANÉ OBDOBÍ V ROCE 2016	53
TABULKA 26: PLOCHY JEDNOTLIVÝCH TŘÍD V RÁMCI METODY SVM (LIN) ZA SLEDOVANÉ OBDOBÍ V ROCE 2016.....	55
TABULKA 27: CHYBOVÁ MATICE V RÁMCI METODY SVM (RBF) ZA SLEDOVANÉ OBDOBÍ V ROCE 2016	55
TABULKA 28: PLOCHY JEDNOTLIVÝCH TŘÍD V RÁMCI METODY SVM (RBF) ZA SLEDOVANÉ OBDOBÍ V ROCE 2016.....	56
TABULKA 29: CHYBOVÁ MATICE V RÁMCI METODY MLC ZA SLEDOVANÉ OBDOBÍ V ROCE 2016.....	57
TABULKA 30: PLOCHY JEDNOTLIVÝCH TŘÍD V RÁMCI METODY MLC ZA SLEDOVANÉ OBDOBÍ V ROCE 2016.....	58
TABULKA 31: PŘEHLED KLASIFIKAČNÍCH METOD ZA SLEDOVANÉ OBDOBÍ V ROCE 2018.....	60
TABULKA 32: CHYBOVÁ MATICE V RÁMCI METODY SVM (LIN) ZA SLEDOVANÉ OBDOBÍ V ROCE 2018	61
TABULKA 33: PLOCHY JEDNOTLIVÝCH TŘÍD V RÁMCI METODY SVM (LIN) ZA SLEDOVANÉ OBDOBÍ V ROCE 2018.....	62
TABULKA 34: CHYBOVÁ MATICE V RÁMCI METODY SVM (RBF) ZA SLEDOVANÉ OBDOBÍ V ROCE 2018	63
TABULKA 35: PLOCHY JEDNOTLIVÝCH TŘÍD V RÁMCI METODY SVM (RBF) ZA SLEDOVANÉ OBDOBÍ V ROCE 2016.....	64
TABULKA 36: CHYBOVÁ MATICE V RÁMCI METODY MLC ZA SLEDOVANÉ OBDOBÍ V ROCE 2018.....	65
TABULKA 37: PLOCHY JEDNOTLIVÝCH TŘÍD V RÁMCI METODY MLC ZA SLEDOVANÉ OBDOBÍ V ROCE 2018.....	66
TABULKA 38: PŘEHLED POROVNÁNÍ PLOCH JEDNOTLIVÝCH TŘÍD V ZÁJMOVÉM ÚZEMÍ ZA ROKY 2013, 2016 A 2018.....	68
TABULKA 39: POROVNÁNÍ ZMĚN VODNÍCH PLOCH V PRŮBĚHU LET 2013, 2016 A 2018	71

SEZNAM OBRÁZKŮ

OBRÁZEK 1: ELEKTROMAGNETICKÉ SPEKTRUM	13
OBRÁZEK 2: KLASIFIKACE OBĚŽNÝCH DRAH DLE NADMOŘSKÉ VÝŠKY	14
OBRÁZEK 3: CHYBOVÁ KLASIFIKAČNÍ MATICE	16
OBRÁZEK 4: SPEKTRÁLNÍ TŘÍDY	17
OBRÁZEK 5: PŘEVOD SPEKTRÁLNÍCH TŘÍD NA TŘÍDY	18
OBRÁZEK 6: ZÁJMOVÁ OBLAST	35
OBRÁZEK 7: PROSTŘEDÍ HTTPS://EARTHEXPLORER.USGS.GOV/	36
OBRÁZEK 8: VÝSLEDEK HLEDÁNÍ SNÍMKŮ	38
OBRÁZEK 9: NABÍDKA STAŽENÍ PRODUKTOVÝCH SAD	38
OBRÁZEK 10: ZDROJOVÉ SNÍMKY PRO KLASIFIKACI	39
OBRÁZEK 11: NÁSTROJ BAND MATH V PROGRAMU ENVI	40
OBRÁZEK 12: SPEKTRÁLNÍ INDEX NDBI	41
OBRÁZEK 13: SPEKTRÁLNÍ INDEX UI	42
OBRÁZEK 14: SPEKTRÁLNÍ INDEX EBBI	43
OBRÁZEK 15: SPEKTRÁLNÍ INDEX NDWI	44
OBRÁZEK 16: SPEKTRÁLNÍ INDEX NDVI	45
OBRÁZEK 17: ZDROJOVÉ SNÍMKY PRO KLASIFIKACI	46
OBRÁZEK 18: MAPOVÝ VÝSTUP KLASIFIKACE SVM (LIN) ZA SLEDOVANÉ OBDOBÍ V ROCE 2013	49
OBRÁZEK 19: MAPOVÝ VÝSTUP KLASIFIKACE SVM (RBF) ZA SLEDOVANÉ OBDOBÍ V ROCE 2013	50
OBRÁZEK 20: MAPOVÝ VÝSTUP KLASIFIKACE MLC ZA SLEDOVANÉ OBDOBÍ V ROCE 2013	52
OBRÁZEK 21: MAPOVÝ VÝSTUP KLASIFIKACE SVM (LIN) ZA SLEDOVANÉ OBDOBÍ V ROCE 2016	54
OBRÁZEK 22: MAPOVÝ VÝSTUP KLASIFIKACE SVM (RBF) ZA SLEDOVANÉ OBDOBÍ V ROCE 2016	56
OBRÁZEK 23: MAPOVÝ VÝSTUP KLASIFIKACE MLC ZA SLEDOVANÉ OBDOBÍ V ROCE 2016	58
OBRÁZEK 24: MAPOVÝ VÝSTUP SPEKTRÁLNÍHO INDEXU NDVI ZA SLEDOVANÉ OBDOBÍ V ROCE 2016	59
OBRÁZEK 25: MAPOVÝ VÝSTUP SPEKTRÁLNÍHO INDEXU ZA SLEDOVANÉ OBDOBÍ V ROCE 2016	60
OBRÁZEK 26: MAPOVÝ VÝSTUP KLASIFIKACE SVM (LIN) ZA SLEDOVANÉ OBDOBÍ V ROCE 2018	62
OBRÁZEK 27: MAPOVÝ VÝSTUP KLASIFIKACE SVM (RBF) ZA SLEDOVANÉ OBDOBÍ V ROCE 2018	64
OBRÁZEK 28: MAPOVÝ VÝSTUP KLASIFIKACE MLC ZA SLEDOVANÉ OBDOBÍ V ROCE 2018	66
OBRÁZEK 29: MAPOVÝ VÝSTUP SPEKTRÁLNÍHO INDEXU NDVI ZA SLEDOVANÉ OBDOBÍ V ROCE 2018	67
OBRÁZEK 30: MAPOVÝ VÝSTUP SPEKTRÁLNÍHO INDEXU NDVI ZA SLEDOVANÉ OBDOBÍ V ROCE 2018	68
OBRÁZEK 31: POROVNÁNÍ SATELITNÍCH SNÍMKŮ V ROCE 2013 A 2018	69
OBRÁZEK 32: PRACHOVICKÝ LOM A VÝSTUP SPEKTRÁLNÍHO INDEXU NDWI ZA SLEDOVANÉ OBDOBÍ V ROCE 2018	71
OBRÁZEK 33: INTENZITA SUCHA V TÝDNU PŘI 8. ZÁŘÍ 2013	79
OBRÁZEK 34: INTENZITA SUCHA V TÝDNU PŘI 18. LISTOPADU 2018	79

SEZNAM GRAFŮ

GRAF 1: PŘEHLED POROVNÁNÍ PLOCH JEDNOTLIVÝCH TŘÍD V ZÁJMOVÉM ÚZEMÍ ZA ROKY 2013, 2016 A 2018	70
--	----

SEZNAM ZKRATEK

ANN	Artificial neural networks
ArcGIS	Aeronautical Reconnaissance Coverage Geographic Information System
CHKO	Chráněné krajinná oblast
ČÚZK	Český úřad zeměměřický a katastrální
CVA	Change Vector Analysis
DN	Digital number
DPZ	Dálkový průzkum Země
EBBI	Enhanced Built-Up and Bareness Index
ENVI	Environment for Visualizing Images
EROS	Earth Resources Observation and Science
ET	Endorsement Theory
ETM	The Enhanced Thematic Mapper
ETM+	The Enhanced Thematic Mapper Plus
GeoTIFF	Georeferenced Tagged Image File Format
HRV	High Resolution Visible
IRS	Indian Remote Sensing
ISODATA	Iterative Self-Organizing Data Analysis Technique Algorithm
km	kilometr
LANDSAT	Land Remote-Sensing Satellite
LIN	Linear
LISS	Linear Imaging Self-Scanning System
MAHADP	Mahalanobis distance classification
METEOSAT	Meteorological Satellite
MINDP	Minimum Distance classification
MLC	Maximum Likelihood

MODIS	Moderate Resolution Imaging Spectroradiometer
MS	Multispectral
MSS	MultiSpectral Scanner
NDBI	Normalised Difference Built-Up Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
NIR	Near Infrared
NLAPS	National Land Archive Production System
NLCD	National Land Cover Database
nm	Nanometr
NOAA	National Oceanic and Atmospheric Administration
OLI	Operational Land Imager
PAN	Panchromatic
RBF	Radial basis function
SAR	Synthetic aperture radar
SPOT	Satellite Pour l'Observation de la Terre
SPOT XS	Satellite Pour l'Observation de la Terre Multi-spectral
SVM	Support vector machine
SWIR	Short-wave infrared
TIRS	Thermal Infrared Sensor
TM	Thematic Mapper
UI	Urban Index
USA	The United States of America
USGS	United States Geological Survey
WGS	The World Geodetic System
WoS	Web of Science

ÚVOD

Diplomová práce se zabývá identifikací změn v krajině ve vybraném území Železných hor pomocí metod řízené klasifikace a klasifikace spektrálními indexy nad získanými satelitními, též družicovými, snímky.

Dálkový průzkum Země získává informace o objektech a jevech na zemském povrchu a využívá se v mnoha oborech, jako je třeba meteorologie, geografie, vojenství, zemědělství a ekologie. Pro zvýraznění dílčích jevů na satelitních snímcích, které nemusí být zprvu viditelné, slouží spektrální indexy.

S analýzou změn ve vybraném území se nejběžněji setkáme právě v ekologii či meteorologii. V rámci meteorologie se používají snímky družic NOAA či METEOSAT. V rámci ekologie jde například o sledování globální změn při úbytku ledovců, ropných havárií či kácení deštných pralesů.

Cílem práce je identifikovat změny ve vybraném území Železných hor. Součástí práce bude výběr vhodných družicových dat. Využity budou metody spektrálního zvýraznění obrazu a automatické klasifikace.


1. DÁLKOVÝ PRŮZKUM ZEMĚ

Dálkovým průzkumem Země (DPZ) se označuje zkoumání zemského povrchu s cílem identifikovat požadované objekty a jevy bez přímého kontaktu. Tyto objekty a jevy se mohou vyskytovat nejenom na zemském povrchu či pod ním, ale i v dolních vrstvách atmosféry. Zjištění informací probíhá na základě snímání povrchu pomocí intervalů vlnových délek. Tyto informace jsou dále zpracovány a promítnuty do výsledného obrázku, který je charakterizován jednotlivými pixely. Každý pixel charakterizuje určitou část snímaného prostoru, který odpovídá prostorovému rozlišení snímače umístěného na jeho nosiči. [10]

1.1. Podstata DPZ

Princip je založen na tom, že objekty a jevy na povrchu mají specifické vlastnosti a ty mohou být sledovány pomocí jejich elektromagnetického záření. Toto záření je charakterizováno frekvencí a vlnovou délkou. [20]

Elektromagnetické záření se vyskytuje ve spojitém spektru a její části jsou vymezeny intervaly vlnových délek, jak je zobrazeno na obrázku 1: [20]



Obrázek 1: Elektromagnetické spektrum

Zdroj: [13]

Na obrázku 1 lze vidět, že viditelné záření je v celém spektru pouze malým intervalem vlnové délky, zhruba 400 až 700 nm. Viditelné se nazývá proto, že je takové záření možné zpozorovat lidským okem. Pokrok v technice umožňuje již také registrovat ostatní intervaly vlnových délek, které dříve byly samotnému oku „utajené“. [10]

1.2. Družicové systémy

Jako družicový systém se označuje jedna nebo více družic, které pořizující snímky pomocí snímačů, které jsou si vzájemně podobné včetně příslušných technických parametrů. Tyto parametry jsou mimo jiné dány oběžnou dráhou družice. Na obrázku 2 jsou uvedeny základní oběžné dráhy: [10]



Obrázek 2: Klasifikace oběžných drah dle nadmořské výšky

Zdroj: [6]

Vysoká oběžná dráha

Nejvzdálenější drahou od Země je vysoká oběžná dráha, která je vzdálena od zemského povrchu přibližně 35 780 kilometrů. Satelity na této oběžné dráze jsou využívány především pro monitorování klimatických jevů a umožňují pořizovat snímky stejného místa velmi často (jednotky minut), ovšem za cenu malého prostorového rozlišení. [6]

Střední oběžná dráha

Střední oběžná dráha je od Země vzdálena přibližně od 2 000 do 35 780 kilometrů. Satelity obíhají tuto dráhu již rychleji, doba oběhu je 12 hodin. [6]

Nízká oběžná dráha

Nízká oběžná dráha je od Země vzdálena přibližně od 180 do 2 000 kilometrů. Satelity obíhají tuto dráhu velmi rychle, doba oběhu je přibližně 99 minut. Tato oběžná dráha je nejvíce využívanou oběžnou drahou. [6]

Dělení družicových systémů dle zaměření: [10]

- Meteorologický družice (METEOSAT, NOAA)
- Výzkumné družice (Landsat, SPOT a IRS)

1.3.Klasifikace obrazu

Klasifikace obrazu může být zaměněna s pojmem segmentace obrazu, proto je vhodné si tyto pojmy vysvětlit.

Segmentace obrazu není klasifikačním algoritmem, ale jedná se o možný předběžný krok před klasifikací, který seskupuje sousední pixely do segmentů, které se poté nazývají entity nikoliv pixely, a výsledkem je segment charakterizovaný průměrnou barvou. [41] [38]

Klasifikace obrazu je proces transformace spektrálního vyjádření obrazu, tedy jednotlivých pixelů, které obsahují hodnoty intenzity odrazivosti, na informační třídy, které jednoznačně rozdělují obraz na jednotlivé typy povrchu. Základní dělení klasifikace je na řízenou a neřízenou.

Základní rozdíl mezi řízenou a neřízenou klasifikací je, že u řízené klasifikace se informační třídy (dále bude uváděno pouze „třída“) neboli typ pokryvu země uvádějí na začátku klasifikace. [24]

1.3.1. Řízená klasifikace

Proces řízení klasifikace je rozdělen na následující fáze: [10] [24]

- Definování trénovacích ploch
- Výpočet spektrálních příznaků pro trénovací plochy jednotlivých tříd, jejich editace a výběr pásem pro klasifikaci
- Zvolení klasifikátoru pro zařazení prvků obrazu do jednotlivých tříd
- Zařazení obrazových prvků do vymezených tříd
- Úprava, hodnocení a prezentace výsledků klasifikace

Definování trénovacích ploch

V rámci tohoto bodu je potřeba definovat veškeré třídy, které se na snímku vyskytují. Do těchto tříd se v dalších částech klasifikace budou zařazovat jednotlivé pixely na základně podobnosti DN hodnot, které je obsaženy v každém pixelu. DN (Digital number) hodnota charakterizuje hodnotu odrazivosti v rámci určitého intervalu, který je dán charakteristikou snímku.

Protože DN hodnoty ve snímku mohou nabývat od několika stovek až tisíců hodnot, tak je nutné vytvořit dostatečně velkou trénovací plochu, alespoň o rozměru 100 pixelů pro každou

třidu. Zároveň je nutné vytvořit ideální rozptyl DN hodnot pro každou třídu, čím větší rozptyl, tím bude daná třída méně homogenní, a naopak čím menší rozptyl DN hodnot, tím je větší šance, že nebudou některé pixely zařazeny do správné třídy. [10] [5]

Výpočet spektrálních příznaků pro trénovací plochy jednotlivých tříd, jejich editace a výběr pásem pro klasifikaci

V této části se provádějí statistické charakteristiky na pixelech, které byly zařazeny do tzv. trénovací plochy všech zvolených tříd. Jedná se například o kovarianční matici, směrodatnou odchylku či průměrový vektor. Tyto charakteristiky se provádí nad několika pásmy pořízeného snímku. [10]

Přesnost klasifikace této části lze konstruovat pomocí chybové matice správně zařazených pixelů. Na obrázku 3 je uveden příklad takové matice [24]:

		Truth					
		Asphalt	Concrete	Grass	Tree	Building	Total
Predicted	Asphalt	2385	4	0	1	4	2394
	Concrete	0	332	0	0	1	333
	Grass	0	1	908	8	0	917
	Tree	0	0	0	1084	9	1093
	Building	12	0	0	6	2053	2071
	Total	2397	337	908	1099	2067	6808

Obrázek 3: Chybová klasifikační matice

Zdroj: [4]

Na obrázku 3 lze vidět na zvýrazněné diagonále matice správně zařazené pixely a ve všech ostatních polích tříd jsou uvedeny počty špatně zařazených pixelů.

Zvolení klasifikátoru pro zařazení prvků obrazu do jednotlivých tříd

Cílem této části je zařazení pixelů do tříd, které byly zvoleny na začátku klasifikace. Vychází se z trénovacích dat zvolených na začátku klasifikace. Tato data jsou promítnuta do n-rozměrného pole v závislosti na počtu pásem, kde je určen centroid pro každou třídu. Jednou z metod zařazení pixelů do tříd je metoda, kdy se jednotlivé pixely zařazují do tříd na základě mezní vzdálenosti od centroidu, tedy pokud se mezní vzdálenost rovná nebo je menší než vzdálenost pixelu k danému centroidu, tak se k němu připojí. [10]

Mezi příklady metod patří [10]:


- Klasifikátor minimální vzdálenosti středů shluků

- Klasifikátor pravoúhelníků
- Klasifikátor „K“ nejbližších sousedů
- Klasifikátor maximální pravděpodobnosti
- Bayesovský klasifikátor

1.3.2. Neřízená klasifikace

U neřízené klasifikace na rozdíl od té řízené na začátku zadává přibližný počet tříd, do kterých se pixely budou klasifikovat, ale algoritmus třídy vytvoří sám. Základní premisou je, že pixely, které se vyskytují vedle sebe zpravidla patří do stejné třídy, zatímco pixely od sebe vzdálené se vyskytují v odlišných třídách. [10]

Na obrázku 4 je příklad klasifikace:




Obrázek 4: Spektrální třídy

Zdroj: [24]

Neřízená klasifikace umožňuje sledovat velmi jemné rozdíly v odrazivosti povrchu. Na obrázku 4 je možné vidět tři spektrální třídy lesů: listnaté, usychající a jehličnaté. Tento postup byl vytvořen pomocí základního algoritmu neřízené klasifikace K-Means. Jedná se o iterační proces, kdy jsou nejdříve vytvořeny centroidy pro každou třídu a pak se opakovaně pixely zařazují do třídy dle spektrální odrazivosti. Tento postup probíhá do doby, než se pixely v třídách ustálí a zůstanou neměnné. [24]

Další fází je převod spektrálních tříd na třídy. V této fázi na určení uživatele, které třídy jsou relevantní pro další zpracování. Příklad převodu je na dalším obrázku 5 [24]:



Obrázek 5: Převod spektrálních tříd na třídy

Zdroj: zpracováno dle [24]

Na obrázku 5 lze vidět, že se uživatel rozhodl vytvořit tři relevantní třídy z pěti spektrálních tříd. Rozhodl, že zakalené a čisté vody transformuje na jednotnou třídu voda a horské opadavé a nížinné opadavé lesy transformuje na třídu opadavé lesy. Spektrální třídu obilné pole zachoval nezměněnou.

Mezi základní algoritmy neřízené klasifikace patří [10]: K-Means, ISODATA, NARENDRA, GOLDBERG a AMOEBA.

1.4. Korekce

Při ošetření satelitních snímků (nebo „družicových snímků“ či pouze „snímků“) se můžeme setkat se třemi následujícími korekcemi.

Radiometrické korekce

Radiometrické korekce ošetřují vlivy nedokonalé odrazivosti paprsku od povrchu země způsobené různými okolnostmi, například denní dobou nebo nedostatečným slunečním zářením. [9]

Geometrické korekce

Geometrické korekce ošetřují například nedokonalosti při pořizování leteckých snímků, například důsledky kolísání letové výšky nebo problémy vznikající při zakřivení země. [9]

Atmosférické korekce

Atmosférické korekce ošetřují například vlivy rozptylu v atmosféře, jedná se třeba o kouřmo nebo zákal. [10]

2. SHRUTÍ STÁVAJÍCÍHO STAVU

V následující kapitole je zpracována rešerše odborných článků pro roky 2000-2018 dle vyhledávání podle klíčových slov v tabulce 1. Zdrojem pro rešerši je Web of Science (WoS).

Tabulka 1: Přehled vyhledávaných klíčových slov a nalezených výsledků ve WoS

Hledaná fráze	Počet studií
("Spatio-temporal") AND ("Land use change")	1
(Land use/Cover change)	1
("Change detection") AND ("Land cover")	1
("Change detection")	1
(Sentinel) AND ("Multi temporal") AND (Kappa)	1
(Spot) AND ("Change detection")	2
(Irs) AND ("Land use")	2
(Modis) AND ("Land use")	1
(Landsat) AND ("Land use")	1
(Landsat) AND ("Change detection")	1
(Landsat) AND (Change detection) AND (Kappa) AND (Temporal)	3

Zdroj: vlastní

Pro potřeby sledování změn v krajině je třeba si ještě vymezit tyto dva pojmy:

Land cover

Jedná se o pozemní kryt povrchu země neboli půdní kryt, který je běžně rozdělen na třídu vegetační a uměle vytvořenou stavbu. Třída vegetační může být například: Voda, led nebo písek. [37]

Land use

Jedná se o činnost člověka, která je prováděna na pozemním krytu, s cílem získat produkt ze zdroje, který půda obsahuje. [37]

2.1.Odborné studie

Vývoj změny využívání půdy a krajiny v reakci na rychlou urbanizaci

Studie se zabývá analýzou změn využití půdy v čase pro hodnocení ekologického důsledku urbanizace. Tato analýza se zabývá územím města Hangzhou, hlavním městem v provincii Zhejiang v Číně. [7]

Zkoumané satelitní snímky byly pořízeny v letech 1996–2006 pomocí družic SPOT, konkrétně pomocí SPOT-3 (PAN) v dubnu 1996, SPOT-2 (XS) v březnu 2000, SPOT-5 (XS) v březnu 2003 a SPOT-5 (XS) v prosinci 2006. Snímky prošly geometrickými korekcemi. [7]

Pro klasifikaci satelitních snímků byly zvoleny metody ISODATA a MLC. Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu. Hodnoty jsou v tabulce 2 [7]:

Tabulka 2: Přehled přesnosti klasifikačních metod ve studii č. 1

Interval	Metoda	Celková přesnost (%)	Kappa koeficient
1996–2000	ISODATA	88,39	0,87
	MLC	86,56	0,85
2000–2003	ISODATA	90,43	0,89
	MLC	87,1	0,86
2003–2006	ISODATA	92,58	0,92
	MLC	90,11	0,89

Zdroj: zpracováno dle [7]

Detekce a sledování změn využití půdy a změn půdního krytu v Dhaka Metropolitan of Bangladesh v letech 1960-2005

Studie se zabývá využitím a pokrytím půdy v Dhaka Metropolitan v Bangladéši. Změny byly sledovány pomocí satelitních snímků od roku 1960 do 2005.

Snímky byly pořízeny pomocí Landsatu 1,4,5,7 a IRS-1D. Konkrétně, Landsat 1 MSS pro březen 1975, Landsat 4 TM pro únor 1988 a Landsat 5 TM pro únor 1999, Landsat 7 ETM+ pro leden 2003 a IRS-1D LISS III pro prosinec 2005.

Topografické snímky z roku 1960 prošly geometrickou korekcí obrazu pomocí softwaru ArcGIS. Korekce všech snímků probíhala pomocí obrazu Landsat TM z roku 1997. Všechny satelitní snímky byly převzorkovány na prostorové rozlišení 30 metrů metodou nejbližšího souseda.

Byla použita metoda řízené klasifikace obrazu MLC a satelitní snímky byly rozděleny do pěti tříd. Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu. Hodnoty jsou v tabulce 3 [8]:

Tabulka 3: Přehled přesnosti klasifikačních metod ve studii č. 2

Rok	Celková přesnost (%)	Kappa koeficient
1975	85,6	0,827
1988	86,4	0,837
1999	90,4	0,885
2003	90	0,879
2005	88,2	0,856

Zdroj: zpracováno dle [8]

Aktualizace národní databáze půdního krytu (NLCD) 2001-2006 pomocí detekce změn snímků Landsat

Studie se zabývá analýzou půdního krytu v pěti městech USA: Manchester, Jackson, Sioux Falls, Seattle a San Diego. Cílem je aktualizovat databázi National Land Cover Database (NLCD) z roku 2001 na rok 2006.

Satelitní snímky byly pořízeny pomocí Landsatu ETM+ (srpen 1999, červenec 2000, červen 2000, září 2000 a říjen 2001) a Landsatu TM (září 2005, 2x červen 2006, září 2006 a únor 2006). Snímky byly získány z USGS, EROS a terénní korekce aplikované prostřednictvím NLAPS.

Snímky byly dále ošetřeny atmosférickými, radiometrickými a geometrickými korekcemi. Klasifikace proběhla do šestnácti tříd pomocí rozhodovacích stromů. [43]

Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu. Hodnoty jsou v tabulce 4 [43]:

Tabulka 4: Přehled přesnosti klasifikačních metod ve studii č. 3

Město	Celková přesnost (%)	Kappa koeficient
Manchester	83,33	0,8179
Jackson	78,36	0,7635
Sioux Falls	88,57	0,872
Seattle	78,32	0,7614
San Diego	87,5	0,8592

Zdroj: zpracováno dle [43]

Studie potvrzuje, že je možné použít NLCD jako zdroj dat pro analýzu změn půdního krytu. Zvolená metoda k aktualizaci NLCD výrazně sníží náklady a čas pro další aktualizace verze NLCD. [43]

Klasifikace půdního krytu a analýza změn metropolitní oblasti Twin City (Minnesota) pomocí dálkového průzkumu družice Landsat

Studie se zabývá klasifikací půdního krytu a analýzou změny krytu v oblasti Twin Cities Metropolitní oblasti Minnesoty o rozloze 7 700 km².

Snímky byly pořízeny pro červen a srpen 1986, červen a září 1991, květen a září 1998, květen a červenec 2002 pomocí Landsat 5 TM a pouze snímek pro květen 2002 byl pořízen Landsatem ETM+.

Snímky byly klasifikovány do sedmi tříd pomocí klasifikace maximální pravděpodobnosti (MLC). Následná post-klasifikace byla použita pro snížení chyby klasifikace způsobené podobnostmi ve spektrálním chování určitých tříd, jako jsou holá pole, městské oblasti a mokřady. [44]

Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu. Hodnoty jsou v tabulce 5 [44]:

Tabulka 5: Přehled přesnosti klasifikačních metod ve studii č. 4

Rok	Celková přesnost (%)	Kappa koeficient
1986	95,5	0,944
1991	94,6	0,932
1998	92,6	0,909
2002	93,2	0,916

Zdroj: zpracováno dle [44]

Mapování rýžového pole pomocí snímků Sentinel-1A a fenologické metody

Cílem studie je monitorování rýžových polí na území jižního Vietnamu o rozloze 40 000 km². Snímky byly pořízeny pro období zima-jaro a léto-podzim od října 2014 do srpna 2015 pomocí satelitu Sentinel-1A SAR.

Klasifikace je založena na fenologické metrice a snímek byl klasifikován do dvou tříd. Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu [16]:

- Hodnota celkové přesnosti klasifikace byla 86,2 %
- Hodnota kappa koeficientu byla 0,72

Změna využívání půdy/půdního krytu v povodí Terkos v Istanbulu

Studie se zabývá analýzou změny využití půdy v oblasti sladkovodního jezera Terkos na severozápadě Istanbulu, v blízkosti Černého moře. Region zahrnuje zemědělské oblasti, vegetaci, sladkovodní jezero, smíšené lesy, mokřady a obytné oblasti.

Snímky pro červenec 2003 byly pořízeny pomocí SPOT 4 XS o prostorovém rozlišení 20 metrů, snímky pro srpen 2007 pomocí SPOT 5 MS (10 metrů) a pro posouzení přesnosti sloužily snímky od SPOT 5 Pan (2,5 metru). Snímky byly ošetřeny pomocí geometrické a atmosférické korekce.

Ve studii byla použita analýza CVA, což je spektrální diferenční technika, jejímž hlavním cílem je detekce změn ve vstupních multispektrálních datech. [3]

Byly použity 3 komponenty k určení dynamiky změn využití půdy:

- Jas
- Zeleň
- Mokro

Byla zvolena neřízená klasifikační metoda ISODATA, která rozdělila snímky na šest různých tříd:

- Vysoké hodnoty změny pro zeleň, jas a vlhkost
- Střední hodnoty změny pro zeleň, jas a vlhkost

Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu:

- Hodnota celkové přesnosti klasifikace byla 84,32 %
- Hodnota kappa koeficientu byla 0,81

Použití rozšířených polárních souřadnic v kombinaci s metodou CVA došlo k lepší schopnosti určit dynamiku změny v krajině ve vybraném území. [3]

ET Klasifikace pro detekci změn v krajině a půdního krytu

Studie se zabývá změnou pokryvu krajiny v oblasti města Dronninglund v Dánsku, studovaná oblast má přibližně 9 900 hektarů. Snímky byly pořízeny pomocí SPOT-4 v červenci 1998 a dubnu 2003.

Klasifikace založená na teorii schvalování (ET) pomocí sdružování důkazů klasifikovala snímky do sedmi tříd. Celková přesnost klasifikace byla 88,4 % a 84,6 %. [15]

Detekce změn v pobřežních zónách Goa v Indii pomocí dálkového snímání

Studie se zabývá změnou pokryvu krajiny v čase v pobřežní oblasti provincie Goa v Indii. Snímky byly pořízeny pomocí tří satelitů [26]:

- SPOT 1 (HRV) – listopad 1990 (prostorové rozlišení 20 metrů)
- IRS-1C (LISSIII) – leden 2001 (prostorové rozlišení 23,5 metru)
- IRS-1D (LISSIII) – leden 2003 (prostorové rozlišení 23,5 metru)

Snímky prošly radiometrickými a atmosférickými korekcemi.

Snímky byly klasifikovány pomocí řízené klasifikace maximální pravděpodobnosti (MLC) do šesti tříd. Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu. Hodnoty jsou v tabulce 6 [26]:

Tabulka 6: Přehled přesnosti klasifikačních metod ve studii č. 8

Rok	Celková přesnost (%)	Kappa koeficient
1990	90,93	0,89
2001	88,03	0,84
2003	88,69	0,86

Zdroj: zpracováno dle [26]

Kritické posouzení dynamiky půdního krytu využívání půdy pomocí satelitních snímků

Studie se zabývá změnou využití půdy ve studované oblasti povodí řeky Brahmaputra, která se rozpíná na ploše 413,94 km² ve státě Assam v Indii. Snímky byly pořízeny pomocí tří satelitů [30]:

- Landsat 5 TM – prosinec 1987 (prostorové rozlišení 30 metrů)
- IRS-1C LISS III – březen 1997 (prostorové rozlišení 23,5 metru)
- IRS-P6 LISS III – prosinec 2007 (prostorové rozlišení 23,5 metru)

Řízená klasifikace maximální pravděpodobnosti (MLC) proběhla do čtrnácti tříd. Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu. Hodnoty jsou v tabulce 7 [30]:

Tabulka 7: Přehled přesnosti klasifikačních metod ve studii č. 9

Rok	Celková přesnost (%)	Kappa koeficient
1987	84,77	0,8011
1997	85,55	0,811
2007	87,5	0,8363

Zdroj: zpracováno dle [30]

Studie je použitelná pro správce zdrojů na regionální či státní úrovni a pro územní plánování. [30]

Analýza dat v čase pomocí snímků MODIS NDVI spolu s doplňkovými údaji o mapování země/zemního krytu území Uttarakhand

Studie se zbývá analýzou využití krajiny v čase na území Uttarakhand v Indii o rozloze 53,483 km². Data satelitu MODIS zahrnují celkem 23 snímků pořízených od ledna do prosince 2010 a mají prostorové rozlišení 250 metrů.

Neřízená klasifikace ISODATA rozdělila snímky do devíti tříd. Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu [32]:

- Hodnota celkové přesnosti klasifikace byla 78,67 %
- Hodnota kappa koeficientu byla 0,76

Důsledky změn ve využívání půdy v povodí řeky Komerse z období 2000-2016

Studie se zabývá dopady změn ve využití půdy, které proběhly v průběhu let 2000 až 2016 na území povodí řeky Komering v Indonésii. Snímky byly ošetřeny atmosférickými a geometrickými korekcemi a byly pořízeny od července do září pomocí satelitu Landsat 7 ETM v roce 2000 a Landsat OLI 8 v roce 2016. Řízená klasifikace maximální pravděpodobnosti (MLC) proběhla v programu ENVI 5.1. do šesti tříd. [21]

Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu [21]:

- Hodnota celkové přesnosti klasifikace byla 82,96 %
- Hodnota hodnota kappa koeficientu byla 0,75

Zjištění změn v zemědělství v severovýchodním Íránu pomocí snímků Landsat

Studie se zabývá změnami ve využití půdy v oblasti nacházející se v severovýchodním Íránu a pokrývá plochu přibližně 21 400 km².

Snímky byly pořízeny pomocí Landsat 7 v červenci 2000 a Landsat 8 ETM+ v červenci 2013 s prostorovým rozlišením 30 metrů. Klasifikace proběhla do šesti tříd pomocí algoritmu podpůrných vektorů (SVM) a umělé neuronové sítě (ANN). Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu. Hodnoty jsou v tabulce 8 [39]:

Tabulka 8: Přehled přesnosti klasifikačních metod ve studii č. 12

	Celková přesnost (%)	Kappa koeficient
SVM	93,74	0,92
ANN	93,08	0,91

Zdroj: zpracováno dle [39]

Ze studie vyplývá, že vysoké přesnosti algoritmů SVM a ANN mohou být dosaženy pro rozsáhlé terénní oblasti s využitím údajů z různých kombinací pásem s vegetačními a půdními indexy. [39]

Postsocialistický růst v Rumunské Bukurešti a detekce změn pomocí snímků Landsat (1984-2010)

Studie se zabývá mapováním post-sovětského růstu města Bukurešť v letech 1984-2010. Všechny čtyři snímky byly pořízeny v srpnu v letech 1984, 1993, 2003 a 2010 pomocí Landsatu 5 TM s prostorovým rozlišením 30 metrů.

Řízená klasifikace pomocí neuronových sítí rozdělila snímky do čtyř tříd. Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu a tyto hodnoty jsou v tabulce 9 [28]:

Tabulka 9: Přehled přesnosti klasifikačních metod ve studii č. 13

Rok	Celková přesnost (%)	Kappa koeficient
1993	87,84	0,7
2003	93,86	0,892
2010	86,92	0,7

Zdroj: zpracováno dle [28]

Posouzení změn půdního krytí v Somálsku po občanské válce pomocí dálkového průzkumu Země

Cílem této studie je analyzovat využití půdy a pokryvu území pro sledovanou oblast v letech 1992-2015 a zejména vyhodnotit vliv občanské války. Studovaná oblast je Mogadišo, hlavní město Somálska, konkrétně pobřežní oblast Banaadir.

Snímky byly pořízeny v prosinci 1992 pomocí Landsat 4, v únoru 2000 pomocí Landsat 7 a v lednu 2015 pomocí Landsat 8. Prostorové rozlišení všech snímků je 30 metrů. Snímky prošly atmosférickou a geometrickou korekcí a byly klasifikovány do pěti tříd. Byly použity tři různé metody řízené klasifikace [18]:

- Klasifikátor minimálních vzdáleností (MINDP)
- Mahalanobiův klasifikátor minimálních vzdáleností (MAHADP)
- Algoritmus podpůrných vektorů (SVM)

Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu. Hodnoty jsou uvedeny v tabulce 10 [18]:

Tabulka 10: Přehled přesnosti klasifikačních metod ve studii č. 14

	1992		2000		2015	
	Celková přesnost (%)	Kappa koeficient	Celková přesnost (%)	Kappa koeficient	Celková přesnost (%)	Kappa koeficient
MINDP	93	0,9053	92,4	0,8957	95,4	0,9378
MAHADP	91,6	0,8868	94,5	0,9254	96,9	0,9583
SVM	97,2	0,9625	98,5	0,9798	98,5	0,9803

Zdroj: zpracováno dle [18]

Klasifikace využívání půdy a detekce změn pomocí multi-temporálních snímků v přírodní rezervaci Chunati

Studie se zabývá vývojem zničené přírodní rezervace Chunati v Bagladéši a zachycuje její vývoj od roku 2005 do roku 2015.

Snímky byly pořízeny v listopadu 2005 a v únoru 2010 pomocí Landsat 5 TM, v březnu 2015 pomocí Landsat 8 OLI/TIRS. Všechny snímky mají prostorové rozlišení 30 metrů. Snímky prošly atmosférickými korekcemi.

Řízená klasifikace maximální pravděpodobnosti (MLC) probíhala v programu ERDAS 14 a rozdělila snímky do šestnácti tříd. Přesnost byla určena pomocí celkové přesnosti klasifikace a kappa koeficientu. Tyto hodnoty jsou v tabulce 11 [19]:

Tabulka 11: Přehled přesnosti klasifikačních metod ve studii č. 15

Rok	Celková přesnost (%)	Kappa koeficient
2005	83,96	0,81
2010	86,15	0,82
2015	92,16	0,89

Zdroj: zpracováno dle [19]

Výsledky této studie mohou pomoci při plánování a realizacích rozhodnutí pro zachování chráněné krajinné oblasti Chunati. Celková přesnost klasifikace se může vylepšit použitím snímků ze stejného období a za stejných atmosférických podmínek. Tyto problémy mohly způsobit nesoulad tříd. [19]

2.2. Celkové shrnutí klasifikačních tříd

Shrnující tabulka všech klasifikovaných tříd pro všechny studie je zobrazena v tabulce 12:

Tabulka 12: Celkové shrnutí klasifikačních tříd a jejich četnosti

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	Počet
Městské plochy		13
Lesy	7
Voda		7
Byliny / tráva			7
Vodní plochy		6
Holá půda / skládka					6
Mokřady / nížiny											5
Zemědělství				5
Plodiny			4

Křovina			4
Seno / pastvina			4
Vegetace		.				.						.			3
Jas					...										3
Osídlení									.	.				.	3
Ovocný sad	.													.	2
Pěstovaná půda		.	.												2
Sníh / led			.							.					2
Opadavý les			.							.					2
Stále zelený les			.							.					2
Smíšený les			.											.	2
Písečné pláže						.	.								2
Degradovaný les						.								.	2
Nedefinovaná oblast												.	.		2
Mokřady			.												1
Bylinné mokřady			.												1
Rýžová půda				.											1
Zem bez rýže				.											1
Dopravní cesty a ostatní oblasti						.									1
Jarní plodiny						.									1
Letní plodiny						.									1
Zimní plodiny						.									1
Mangrovy						.									1
Plantáže							.								1
Hustý les							.								1
Bažiny							.								1
Řeka							.								1
Vodní vegetace							.								1
Listnatý les							.								1
Plantáž								.							1
Poušť												.			1
Chov ryb / rybník														.	1
Pepřovník betelový														.	1
Přírodní regenerační plocha														.	1
Společenská lesní plocha														.	1
Lesní plantáž														.	1

Zdroj: zpracováno dle [7] [8] [43] [44] [16] [3] [15] [26] [30] [32] [21] [39] [28] [18] [19]

2.3. Celkové shrnutí klasifikačních metod a zdrojů snímků

Shrnující tabulka všech použitých zdrojů satelitních snímků, klasifikačních metod a hodnocení přesnosti pro všechny studie je zobrazena v tabulce 13:

Tabulka 13: Celkové shrnutí klasifikačních metod a jejich přesnosti

Studie	Satelit	Metoda	Nejnižší přesnost	Nejvyšší přesnost	Nejlepší metoda
1	SPOT-2 (XS)	ISODATA, MLC	86,56 % a 0,85	92,58 % a 0,92	ISODATA
	SPOT-3 (PAN)				
	SPOT-5 (XS)				
2	Landsat 1 MSS	MLC	85,6 % a 0,827	90,4 % a 0,885	MLC
	Landsat 4 TM				
	Landsat 5 TM				
	Landsat 7 ETM+				
	IRS-1D LISS II				
3	Landsat ETM+	Rozhodovací stromy	78,32 % a 0,7614	88,57 % a 0,872	Rozhodovací stromy
	Landsat TM				
4	Landsat 5 TM	MLC	92,6 % a 0,909	95,5 % a 0,944	MLC
	Landsat ETM+				
5	Sentinel-1A SAR	Fenologická metrika	86,2 % a 0,72	86,2 % a 0,72	Fenologická metrika
6	SPOT 4 XS	ISODATA	84,32 % a 0,81	84,32 % a 0,81	ISODATA
	SPOT 5 MS				
	SPOT 5 Pan				
7	SPOT-4	ET	84,60 %	88,40 %	ET
8	SPOT 1 (HRV)	MLC	88,03 % a 0,84	90,93 % a 0,89	MLC
	IRS-1C (LISSIII)				
	IRS-1D (LISSIII)				
9	Landsat 5 TM	MLC	84,77 % a 0,8011	87,5 % a 0,8363	MLC
	IRS-1C LISS III				
	IRS-P6 LISS III				
10	MODIS	ISODATA	78,67 % a 0,76	78,67 % a 0,76	ISODATA
11	Landsat 7 ETM	MLC	82,96 % a 0,75	82,96 % a 0,75	MLC
	Landsat OLI 8				
12	Landsat 7	SVM, ANN	93,08 % a 0,91	93,74 % a 0,92	SVM
	Landsat 8 ETM+				
13	Landsat 5 TM	Neuronová síť	86,92 % a 0,7	93,86 % a 0,892	Neuronová síť
14	Landsat 4	MINDP, MAHADP, SVM	91,6 % a 0,8868	98,5 % a 0,9803	SVM
	Landsat 7				
	Landsat 8				
15	Landsat 5 TM	MLC	83,96 % a 0,81	92,16 % a 0,89	MLC
	Landsat 8 OLI/TIRS				

Zdroj: zpracováno dle [7] [8] [43] [44] [16] [3] [15] [26] [30] [32] [21] [39] [28] [18] [19]

3. VÝBĚR METOD A PROGRAMOVÉ PROSTŘEDÍ

V této kapitole budou uvedeny metody a programové prostředí, ve kterém budou uvedené metody použity pro identifikaci změn v krajině na základě družicových dat. Jedná se o tři základní metody:

- Klasifikace pomocí spektrálních indexů
- Řízená klasifikace
- Hodnocení přesnosti řízené klasifikace

3.1. Klasifikace pomocí spektrálních indexů

Spektrální index je matematický aparát, který pracuje s různými pásmy družicového snímku tak, aby zvýraznil požadovaný pokryv země.

Pro zvýraznění městských ploch byly vybrány následující spektrální indexy [35]:

- NDBI (Normalised Difference Built-Up Index) =
$$\frac{SWIR1 - NIR}{SWIR1 + NIR}, \quad (1)$$

- UI (Urban Index) =
$$\frac{SWIR2 - NIR}{SWIR2 + NIR}, \quad (2)$$

- EBBI (Enhanced Built-Up and Bareness Index) =
$$\frac{SWIR1 - NIR}{10 + \sqrt{SWIR1 + TIRS1}}, \quad (3)$$

Ač jsou indexy NDBI, UI a EBBI původně navrženy pro snímky Landsat TM a ETM+, tak ve studii (SEKERTEKIN a MARANGOZ, 41) je upravili a aplikovali na snímky Landsat 8 a ze závěru jejich studie je patrné, že jsou vhodné pro snímky Landsat 8 a dokáží dobře identifikovat změny v zastavěných plochách.

Pro zvýraznění vodních ploch byly vybrány následující spektrální indexy [42]:

- NDVI (Normalized Difference Vegetation Index) =
$$\frac{NIR - RED}{NIR + RED}, \quad (4)$$

- NDWI (Normalized Difference Water Index) =
$$\frac{GREEN - NIR}{GREEN + NIR}, \quad (5)$$

Ač je index NDVI zaměřen zejména na vegetaci, tak dobře identifikuje vodní plochy a v diplomové práci bude použit v porovnání s indexem NDWI, který je primárně zaměřen právě na vodní plochy.

3.2. Metody řízené klasifikace

Na základě tabulky 12 a analýze hodnocení přesnosti všech rešerší odborných článků v kapitole 2.1 byly zvoleny následující klasifikační metody:

- Algoritmus podpůrných vektorů (SVM LIN a SVM RBF)
- Klasifikátor maximální pravděpodobnosti (MLC)
- Klasifikátor minimálních vzdáleností (MINDP)
- Mahalanobiův klasifikátor minimálních vzdáleností (MAHADP)

3.2.1. Algoritmus podpůrných vektorů (SVM)

Jedná se o řízenou klasifikaci, která čerpá z teorie statistického učení pro oddělení jednotlivých tříd povrchu. Povrch se zde nazývá optimální nadrovina a nejbližší body snímku k dané nadrovině se nazývají podpůrné vektory.

Při aplikaci metody byly použity dvě matematické reprezentace jádra:

- Lineární - $K(x_i, x_j) = x_i x_j$, (6)

- Radiální bázová funkce - $K(x_i, x_j) = \exp(-g\|x_i - x_j\|^2)$, $g > 0$, (7)

Tyto jádra (6) a (7) určují váhy jednotlivých bodů snímku při zařazení do cílových tříd. Znak g reprezentuje gamma parametr, který určuje šířku rozhodovací oblasti. Čím je hodnota g nižší, tím je rozhodovací oblast rozdělena na větší plochy a body snímku mají větší pravděpodobnost být zařazeny do nesprávné třídy, naopak, čím je hodnota vyšší, tak se plochy zmenšují a pixely jsou zařazovány do správné třídy vlivem menších a „inteligentnějších“ ploch. Znaky x_i a x_j jsou jednotlivé body snímku. [36] [1] [40]

Při klasifikaci byly nastaveny tyto parametry:

- Gamma = 0,143
- Chybový parametr = 100 (maximální hodnota), určuje nejvyšší přesnost modelu
- Prahová hodnota = 0, vyjadřuje nejistotu, zda blízké segmenty spadají do stejné třídy

3.2.2. Klasifikátor maximální pravděpodobnosti (MLC)

Klasifikace maximální pravděpodobnosti zařazuje pixely do dané třídy na základě vypočtené pravděpodobnosti. Bod snímku se zařadí do té třídy, která má nejvyšší pravděpodobnost.

V případě zvolení prahové hodnoty dojde k nezařazení pixelů, u kterých je práh větší než pravděpodobnost.

Každý bod snímku je vypočten na základě matematického vzorce:

$$g_i(x) = \ln p(\omega_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (x-m_i)^T \Sigma_i^{-1} (x-m_i), \quad (8)$$

Kde: i je třída, x jsou n -dimenzionální data (n je počet pásem), $p(\omega_i)$ je pravděpodobnost vytvoření ω_i třídy, $|\Sigma_i|$ je determinant kovarianční matice dat ve třídě ω_i , Σ_i^{-1} je inverzní matice, m_i je průměrový vektor. [27]

Při aplikaci klasifikace byly nastavena hodnota prahu na 1, aby se zařadily všechny body snímku do nějaké třídy.

3.2.3. Klasifikátor minimálních vzdáleností (MINDP)

Klasifikátor minimálních vzdáleností zařadí pixel do dané třídy na základě nejbližší euklidovské vzdálenosti středního vektoru každé třídy k danému bodu snímku, pokud není nastavena prahová hodnota či odchylka, v takovém případě by došlo k nezařazení některých pixelů. [29]

3.2.4. Mahalanobiův klasifikátor minimálních vzdáleností (MAHADP)

Mahalanobiova klasifikace minimálních vzdáleností je příbuzná klasifikaci MLC, ale předpokládá, že všechny kovariance tříd jsou stejné. Body snímku jsou zařazeny do nejbližší třídy. V případě zadání prahové hodnoty některé pixely nemusí být zařazeny do některé třídy. [25]

3.3. Hodnocení přesnosti klasifikace

Hodnocení přesnosti klasifikace je matematický aparát, který slouží ke zjištění, jak se správně klasifikovala data z trénovacích dat do výsledného klasifikovaného obrazu. Určuje se dle celkové přesnosti klasifikace a kappa koeficientu. [34]

3.3.1. Celková přesnost klasifikace

Celková přesnost klasifikace určuje přesnost klasifikace na základě součtu správně zařazených pixelů dělených součtem všech trénovacích pixelů.

Tabulka 14: Příklad chybové matice

	Les	Voda	Součet
Les	96	4	100
Voda	0	100	100
Součet	100	100	200

Zdroj: vlastní

V tabulce 14 je uvedeno, že trénovací plocha obsahuje celkem 100 pixelů pro lesy a 100 pixelů pro vodu. Správně klasifikovaných pixelů pro les je 96 a 4 pixely byly klasifikovány ve výsledném obrazu jako voda. Správně klasifikovaných pixelů pro vodu je 100 a žádný pixel nebyl klasifikován ve výsledném obrazu jako les. [34]

Celková přesnost klasifikace je v tomto případě: $C = \frac{96+100}{200} = 98 \%$

3.3.2. Kappa koeficient

Kappa koeficient nabývá hodnot od 0 do 1 a vyjadřuje stupeň přesnosti klasifikace. Čím větší je hodnota, tím je klasifikace lepší než náhodné zařazení pixelů. Koeficient se vypočítá na základě následujícího vzorce [4]:

$$K = \frac{N \sum_{i=1}^n m_{i,i} - \sum_{i=1}^n (G_i C_i)}{N^2 - \sum_{i=1}^n (G_i C_i)}, \quad (9)$$

Kde: i je číslo třídy, N je celkový počet klasifikovaných hodnot ve srovnání se správně zařazenými pixely, $m_{i,i}$ jsou hodnoty na diagonále klasifikační matice (správně zařazené pixely), C_i je celkový počet předpokládaných hodnot patřících do třídy i , G_i je celkový počet správně zařazených hodnot do třídy i . [4]

3.4. Zvolené programové prostředí

Na základě kapitol 3.2., 3.3., 3.4. a potažmo kapitoly 2 bylo vybráno programové prostředí softwaru ENVI 5.5 jako nejvhodnější pro práci s družicovými snímky, následnou klasifikací a ověření přesnosti klasifikace zejména proto, že nejpresnější metody, zmíněné v kapitole 3.2., jsou součástí softwaru ENVI. Další výhodou ENVI je poměrně jednoduchá a přehledná práce s klasifikačními metodami, včetně spektrálních indexů, a následným ověřením přesnosti řízené klasifikace. Při porovnání těchto výhod například se softwarem ArcGIS, nedosahuje ArcGIS takové široké škály klasifikačních metod a zejména jednoduchosti při ověření přesnosti klasifikace. Mezi výhodou ArcGISu lze považovat větší množství možností při tvorbě mapového

výstupu a celkově možnost lepší vizuální interpretace. I přes tuto výhodu ArcGISu bude práce se snímky probíhat v softwaru ENVI 5.5.

Mezi viditelné nedostatky tvorby mapového výstupu v programu ENVI patří nemožnost popsat legendu s háčky a čárkami, v takovém případě jsou zobrazeny jiné znaky a textový popis je nejednoznačný. V mapových výstupech řízené klasifikace v diplomové práci bude tedy legenda s popisky bez háček a také čárek. Zajímavostí je, že háčky a čárky v nadpisu mapového výstupu se zobrazují bez chyb. Mapové výstupy spektrálních indexů neumožňují pracovat z vygenerovanými třídami a tedy legendou, takže u některých byly vytvořeny dodatečně pomocí jiného programu. Dalším nedostatkem je nemožnost ovládat posunutí mapového podkladu což může způsobit problém při delších názvech jednotlivých tříd v legendě a tím překrytí mapového výstupu právě legendou.

Další nevýhodou program ENVI je nemožnost ověřit celkovou přesnost a kappa koeficient spektrálních indexů. Při použití snímku s aplikovaným spektrálním indexem pro ověření přesnosti klasifikace se objeví hláška, že tento typ souboru nelze použít. Zároveň jakékoliv zásahy do typu souboru, třeba jen barevné zvýraznění určité třídy znemožní použít snímek pro vytvoření mapového výstupu. Spektrální indexy budou tedy v diplomové práci použity zejména pro vizuální analýzu a nebudou pro ně vytvořeny přesnosti klasifikace a kappa koeficienty.

4. ANALÝZA VYBRANÉHO ÚZEMÍ

4.1. Charakteristika zájmové území

Identifikace změn v krajině je provedena na vybraném území Železných hor o rozměru 29,1 x 37,02 km. Vybrané zájmové území zahrnuje zejména oblast CHKO Železné hory. Na obrázku 6 je vyznačena zájmová oblast:



Obrázek 6: Zájmová oblast

Zdroj: [25]

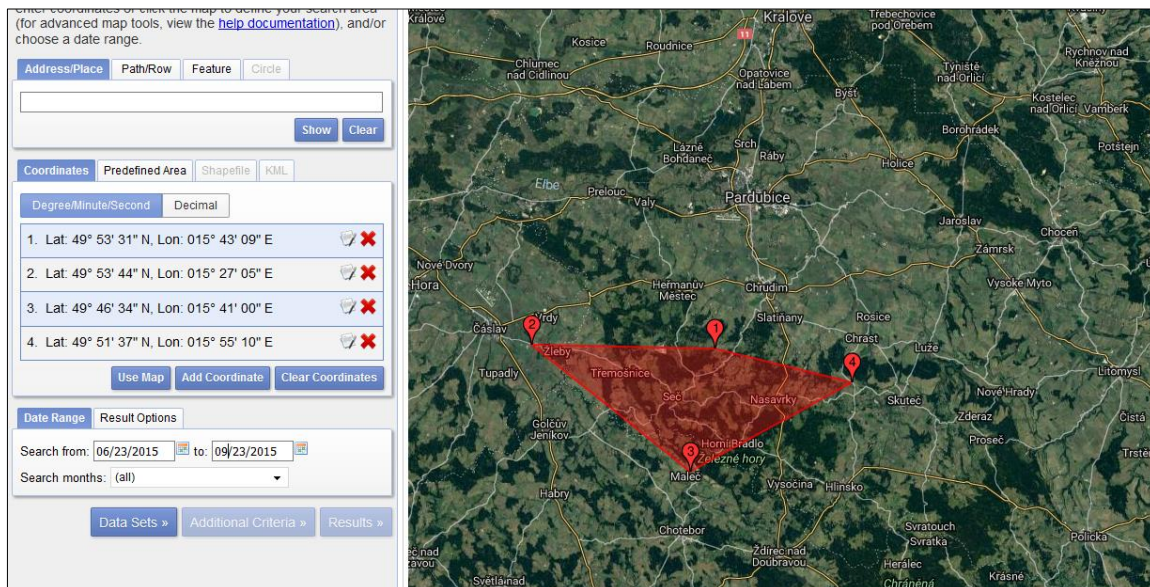
CHKO Železné hory je částí pohoří Železné hory a zaujímá plochu o velikosti 284 km². CHKO Železné hory zahrnuje z velké části rozsáhlé lesní plochy. Součástí CHKO Železné hory jsou například Národní přírodní rezervace Lichnice, Národní přírodní památka Kaňkovy hory a dalších 25 přírodních rezervací a památek. [14]

Mezi největší města v zájmové oblasti patří Hlinsko, Chotěboř, Nasavrky, Třemošnice a hojně navštěvované turistické místo Seč. Okrajově do zájmové oblasti zasahují Heřmanův Městec, Ždírec nad Doubravou a Chrudim.

Nejvýznamnější vodní plochou v zájmové oblasti je Sečská přehrada, dále jsou zde malé rybníky jako Rohozenský rybník, Horní a Dolní Peklo. Nejvýznamnější řekou je zde Chrudimka.

4.2. Výběr a stažení dat

Vybraná oblast zájmového území byla přibližně ohraničena v databázi satelitních snímků <https://earthexplorer.usgs.gov/>, ze které budou čerpány satelitní snímky. Na obrázku 7 je prostředí zmíněného webu s vyznačenými hranicemi pro vyhledávání:



Obrázek 7: Prostředí <https://earthexplorer.usgs.gov/>

Zdroj: [12]

Kromě hranic území, bylo nastaveno několik dalších parametrů pro nalezení optimálních satelitních snímků.

Hledané snímky by měly být pořízeny v období jara, léta až maximálně začínajícího podzimu, aby se na základě sledovaných tříd pokryvu země dalo dobře tyto třídy identifikovat pomocí klasifikace. Zimní období by velmi významně znemožnilo analýzu změn v krajině. Seběmenší sněhová pokrývka zamezí klasifikaci hledaných tříd pokryvu země.

Pro co nejpřesnější porovnání změn v krajině je důležité pracovat se snímky, které se pořídily v co možná nejbližším termínu v průběhu let a za co nejlepších atmosférických podmínek (žádná oblačnost, žádný stín) a za denního světla. Oblačnost má negativní vliv na klasifikaci dat, obvykle se vyskytuje ve formě bílé až šedé barvy, které by mohlo být v zimním čase zaměněné se sněhovou pokrývkou a v jiném období by mohlo být zaměněno s městskými plochami. Stín oblačnosti se vyskytuje ve formě tmavě modré barvy, která může být zaměněná s vodní plochou.

Na základě bezplatné dostupnosti a kvalité poskytnutých snímků byl vybrán satelit Landsat 8 OLI/TIRS C1 Level-1 jako zdroj satelitních snímků. V úvahu připadaly snímky satelitu

Sentinel 2, které poskytují lepší prostorové rozlišení (až 10 metrů), ovšem start družice byl v roce 2015 a nepokryl by celé analyzované období (2013, 2016 až 2018). Aby podmínky sledování změn a technické parametry pro pořízení snímků byly v průběhu let co nejpodobnější a vzájemně porovnatelné, bylo využito tedy pouze snímků Landsat 8, které jsou dostačující. V tabulce 15 je popis použití jednotlivých pásem, intervalů vlnových délek a prostorové rozlišení pro snímky satelitu Landsat 8:

Tabulka 15: Landsat 8 přehled pásem a využití

Pásmo	Vlnové délky (nm)	Použití pásma	Prostorové rozlišení (m)
Pásmo 1 - Aerosol	0.435 - 0.451	Studie aerosoli	30
Pásmo 2 - Modré	0.452 - 0.512	Rozlišení půdy od vegetace	30
Pásmo 3 - Zelené	0.533 - 0.590	Rozlišení vitality rostlin	30
Pásmo 4 - Červené	0.636 - 0.673	Potlačení vegetačních svahů	30
Pásmo 5 - Blízké infračervené (NIR)	0.851 - 0.879	Zaměření na břehy	30
Pásmo 6 - Krátkovlnné infračervené (SWIR 1)	1.566 - 1.651	Potlačení vlhkosti půdy a vegetace	30
Pásmo 7 - Krátkovlnné infračervené (SWIR 2)	2.107 - 2.294	Zaměření na zvýšenou vlhkost půdy a vegetace	30
Pásmo 8 - Panchromatické	0.503 - 0.676	Rozlišení 15 metrů	15
Pásmo 9 - Oblačné	1.363 - 1.384	Zlepšená detekce oblačnosti	30
Pásmo 10 - Termální infračervené (TIRS 1)	10.60 - 11.19	Tepelné mapování a vlhkost půdy	100
Pásmo 11 - Termální infračervené (TIRS 2)	11.50 - 12.51	Tepelné mapování a vlhkost půdy	100

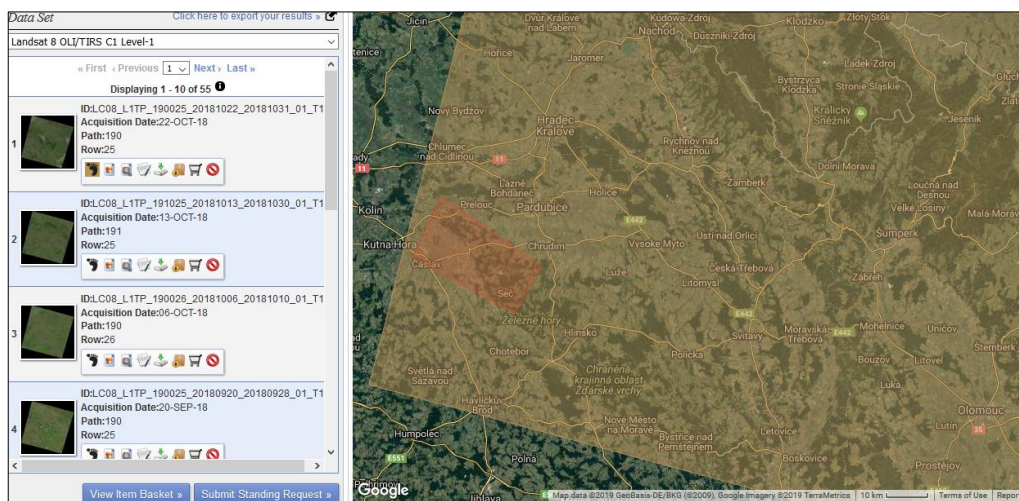
Zdroj: zpracováno dle [2] [22] [33]

OLI/TIRS v popisu Landsatu 8 znamená pozemní operační snímač (OLI) a tepelný infračervený snímač (TIRS). Level-1 značí, že snímky nejsou ošetřeny od atmosférických korekcí. Snímky Landsatu 8 jsou nabízeny i na Levelu-2, která ošetřuje atmosférické korekce, ale tato možnost není bezplatně k dispozici v rámci <https://earthexplorer.usgs.gov/>. [11]

Při přihlédnutí k výše uvedeným parametrům byly použity pro vyhledávání satelitních snímků následující parametry:

- Období: Červenec-říjen v letech 2013, 2016, 2018
- Satelit: Landsat 8 OLI/TIRS C1 Level-1
- Pokrytí oblačností snímků: do 20 %

Na obrázku 8 je příklad výstupu snímků na základě zadaných kritérií:

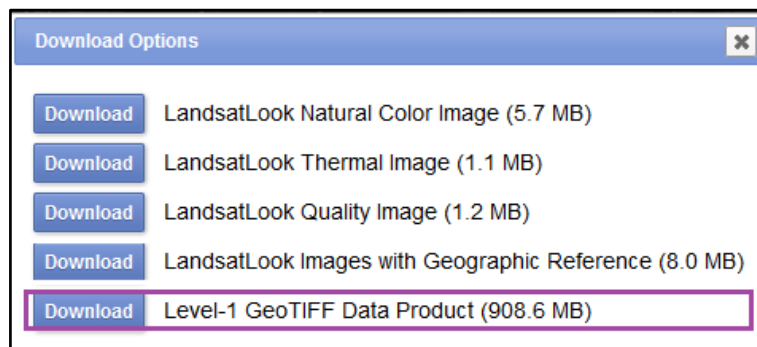


Obrázek 8: Výsledek hledání snímků

Zdroj: [12]

V levé části obrázku 8 je seznam výsledků na základě splnění zadaných kritérií, v pravé části obrázku 8 je žlutě vyznačena oblast, která je v daném snímku zaznamenána.

Po zkontrolování snímků mohlo být postoupeno ke stažení těch relevantních a vložení do programu ENVI. U všech snímků bylo zkontrolováno, jestli zájmové území nepřekrývá nějaká výrazná oblačnost. Vybrané snímky byly staženy ve formátu „GeoTIFF Data Product“, který obsahuje snímky v 11 pásmech, tyto pásma jsou uvedeny v tabulce 15. Na obrázku 9 je možné vidět možné varianty stažení datových sad (snímků):



Obrázek 9: Nabídka stažení produktových sad


Zdroj: [12]

Na obrázku 9 je možné vidět dále příklad datové sady „LandsatLook Images with Geographic References“, který obsahuje snímek v přirozených barvách, termální podobě a v osmi bitové kvalitě. Pro potřeby klasifikace obrazu a použití spektrálních indexů je tato sada nedostatečná. [23]

5. ZDROJOVÁ DATA A VÝBĚR RELEVANTNÍCH SPEKTRÁLNÍCH INDEXŮ

5.1. Zdrojová data

Pro analýzu změn v krajině v čase byly nakonec použity snímky Landsat 8 složené ze sedmi pásem č.1 až č.7 dle tabulky 15. Při detailní analýze těchto snímků bylo viditelné, že všechny zkoumané třídy jsou dobře od sebe spektrálně odlišitelné, což je základ pro přesnou klasifikaci. Na obrázku 10 jsou všechny zdrojové snímky použité k analýze:



Obrázek 10: Zdrojové snímky pro klasifikaci

Zdroj: vlastní zpracování dle dat [12]

Na obrázku 10 je v části A vidět snímek ze dne 6. září 2013, v části B je snímek ze 4. srpna 2016 a snímek v části C je z 13. listopadu 2018.

Na základě tabulky 12 a vizuální analýzy zdrojových dat na obrázku 10 bylo vybráno pět sledovaných tříd:

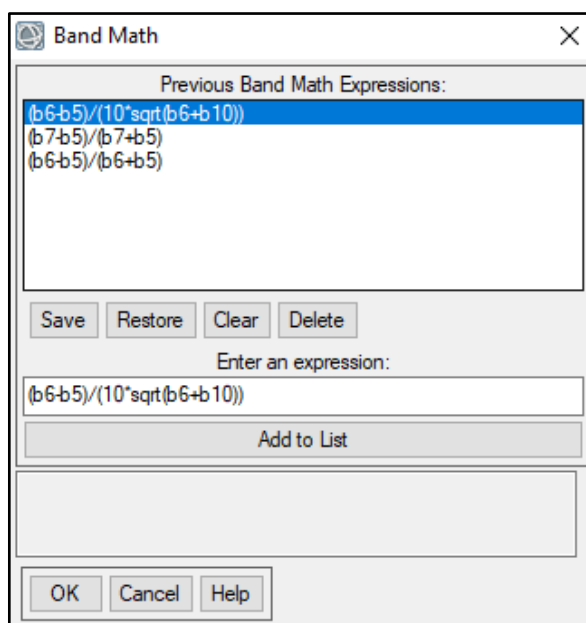
- Městské plochy – zahrnuje zejména domy, infrastrukturu a průmysl

- Lesy – zahrnuje veškeré lesní plochy
- Zeleň – zahrnuje veškeré zelené rostliny
- Pole – zahrnuje zejména holé zemědělskou půdu, obilniny a spálené travnaté plochy
- Vodní plochy – zahrnuje zejména vodní plochy a řeky

5.2. Výběr relevantních spektrálních indexů

Všechny spektrální indexy z kapitoly 3.1 budou aplikovány na snímek z roku 2013 a v případě, že daný spektrální index bude poskytovat požadovaný výstup, tak budou dále aplikovány na snímky z roku 2016 a 2018.

Aplikace spektrálních snímků v programu ENVI probíhá v nástroji Band Math, do kterého se zapíše příslušný matematický aparát. Na obrázku 11 je příklad matematického aparátu:




Obrázek 11: Nástroj Band Math v programu ENVI

Zdroj: vlastní zpracování

Nejdříve bude pracováno se spektrálními indexy pro zvýraznění městských ploch, mezi které patří NDBI, UI a EBBI, jejichž matematický aparát je popsán v kapitole 3.1. Legendy v mapových výstupech pro NDBI, UI a EBBI nebudou vytvářeny kvůli velké heterogenitě jednotlivých tříd.

Jako první byl vytvořen spektrální index NDBI, který je na obrázku 12:

KLASIFIKACE NDBI ZÁJMOVÉHO ÚZEMÍ v roce 2013



Jiri KOPRIVA
Pardubice 2019
Zdroj: <https://earthexplorer.usgs.gov/>

Obrázek 12: Spektrální index NDBI


Zdroj: vlastní zpracování dle dat [12]

Spektrální index NDBI na obrázku 12 nezvýraznil požadovanou třídu městských ploch tak, aby byla odlišená od ostatních tříd. Městské plochy jsou rozděleny na dvě třídy, jedna třída městských ploch je zařazena včetně některých lesních ploch a druhá třída městských ploch zahrnuje městské plochy a zeleň. Spektrální index NDBI velmi dobře zvýrazňuje vodní plochy.

Vzhledem k tomu, že městské plochy nejsou dobře zvýrazněny, tak tento index nebude dále užíván ve snímcích v roce 2016 a 2018.

Na obrázku 13 je mapový výstup pro UI:

KLASIFIKACE UI ZÁJMOVÉHO ÚZEMÍ v roce 2013



Jiri KOPRIVA
Pardubice 2019
Zdroj: <https://earthexplorer.usgs.gov/>

Obrázek 13: Spektrální index UI


Zdroj: vlastní zpracování dle dat [12]

Spektrální index UI na obrázku 13 nezvýraznil požadovanou třídu městských ploch tak, aby byla odlišená od ostatních tříd. Městské plochy jsou zařazeny ve stejné třídě jako převážný část lesních ploch a veškeré vodní plochy.

Vzhledem k tomu, že městské plochy nejsou dobře zvýrazněny, tak tento index nebude dále užíván ve snímcích v roce 2016 a 2018.

Na následujícím obrázku 14 je mapový výstup pro EBBI:

KLASIFIKACE EBBI ZÁJMOVÉHO ÚZEMÍ v roce 2013



Jiri KOPRIVA
Pardubice 2019
Zdroj: <https://earthexplorer.usgs.gov/>

Obrázek 14: Spektrální index EBBI

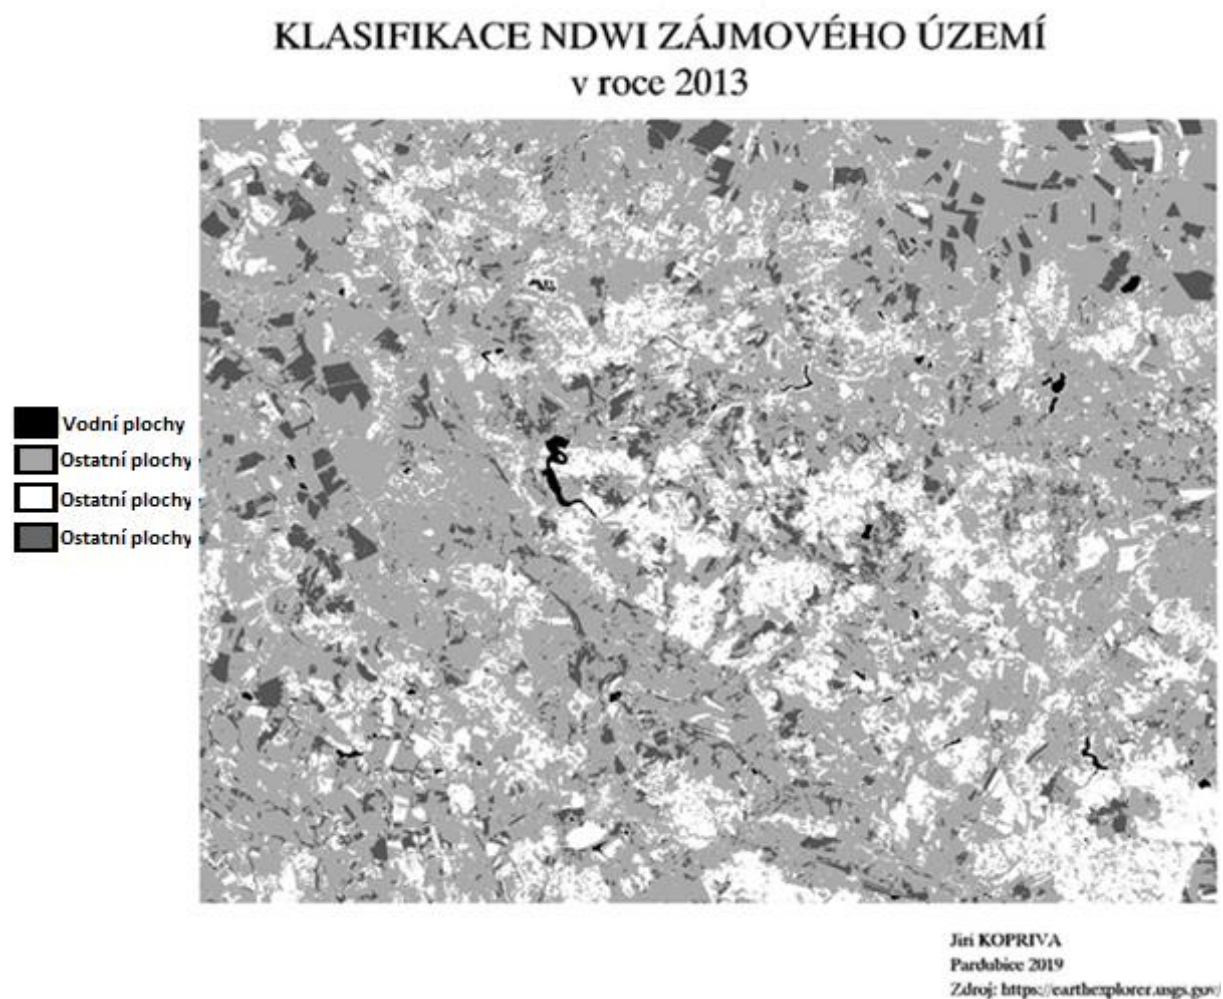
Zdroj: vlastní zpracování dle dat [12]

Spektrální index EBBI na obrázku 14 nezvýraznil požadovanou třídu městských ploch tak, aby byla odlišená od ostatních tříd. Městské plochy jsou rozděleny na několik tříd, jedna třída městských ploch zahrnuje pole a další třídy městských ploch jsou zařazeny s lesními plochami, vodními plochami a zelení.

Vzhledem k tomu, že městské plochy nejsou dobře zvýrazněny, tak tento index nebude dále užíván ve snímcích v roce 2016 a 2018.

Ani jeden ze sledovaných spektrálních indexů zaměřených na městské plochy nezvýrazňuje požadovanou třídu správně, žádný tedy nebude dále užíván. V další fázi budou použity spektrální indexy zaměřené na vodní plochy (NDVI, NDWI).

Na obrázku 15 je aplikován index NDWI:



Obrázek 15: Spektrální index NDWI

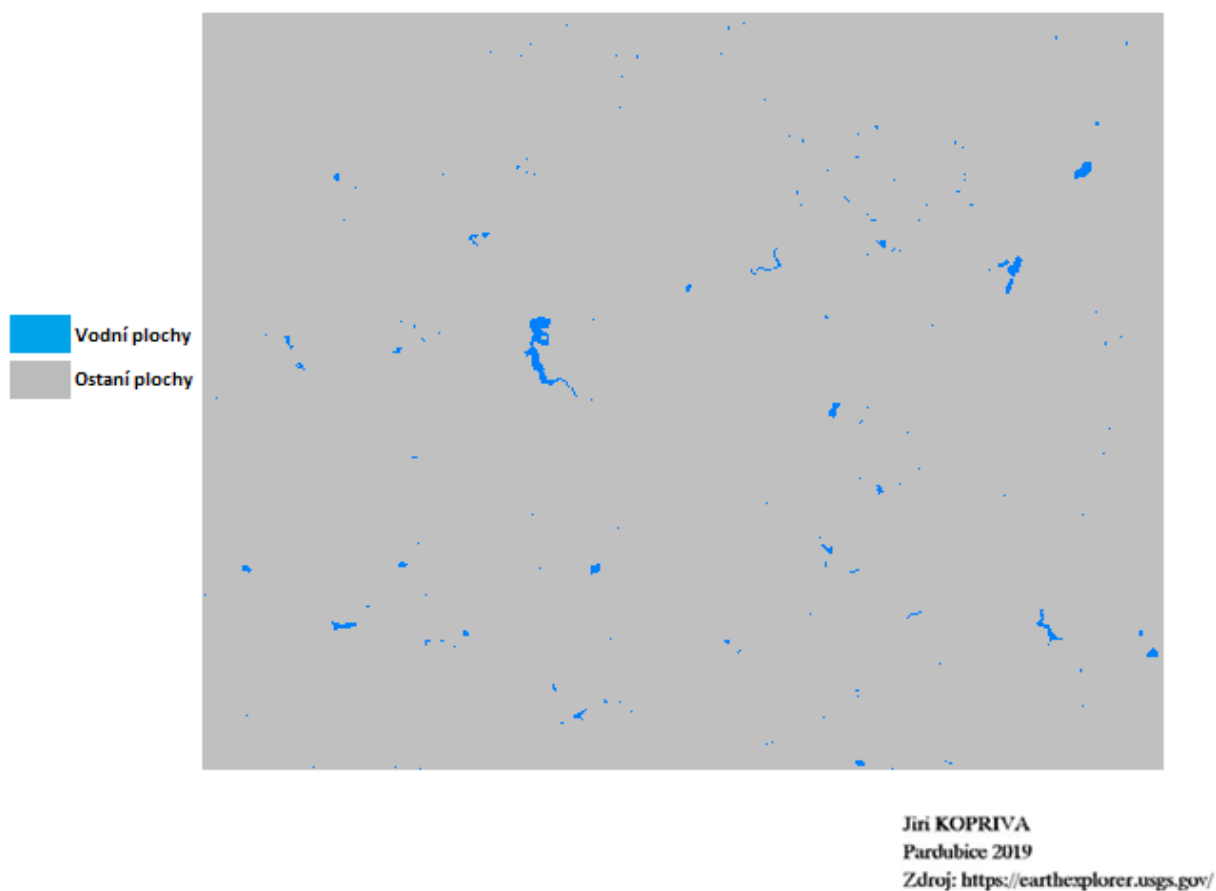
Zdroj: vlastní zpracování dle dat [12]

NDWI velmi dobře zvýrazňuje vodní plochy, které jsou vyznačeny černou barvou na obrázku 15. Celková plocha vodních ploch v zájmovém území podle NDWI je 6,857 km².

Vzhledem k tomu, že vodní plochy jsou dobře zvýrazněny, tak tento index bude dále užíván ve snímcích v roce 2016 a 2018.

Na obrázku 16 je mapový výstup pro NDVI:

KLASIFIKACE NDVI ZÁJMOVÉHO ÚZEMÍ v roce 2013



Obrázek 16: Spektrální index NDVI

Zdroj: vlastní zpracování dle dat [12]

NDVI se zpravidla používá pro zvýraznění vegetace, ale také velmi dobře zvýrazňuje vodní plochy, které jsou vyznačeny modrou barvou na obrázku 16. Celková plocha vodních ploch v zájmovém území podle NDVI je 4,811 km².

Vzhledem k tomu, že vodní plochy jsou dobře zvýrazněny, tak tento index bude dále užíván ve snímcích v roce 2016 a 2018.

V této kapitole byly aplikovány všechny vybrané spektrální indexy z kapitoly 3.1. a jako relevantní byly vybrány oba spektrální indexy zaměřené na vodní plochy (NDWI a NDVI), s kterými se bude pracovat dále pro snímky z let 2016 a 2018. Všechny spektrální indexy zaměřené na městské plochy (NDBI, UI a EBBI) nezobrazovaly správně požadovanou třídu, takže dále již nebudou používány.


6. KLASIFIKACE DAT A OVĚŘENÍ PŘESNOSTI KLASIFIKACE

Postup při klasifikaci bude následující:

- Vytvoření trénovacích ploch pro každou třídu v rámci všech období (2013, 2016 a 2018)
- Aplikace spektrálních indexů zaměřených na vodní plochy (NDWI a NDVI) na všech snímcích za všechna období
- Aplikace pěti druhů klasifikačních metod na všech snímcích na základě trénovacích dat za všechna období
- Vytvoření tabulek přesnosti klasifikace a hodnot celkové přesnosti klasifikace a kappu koeficientu všech metod řízené klasifikace
- Vytvoření tabulek pro velikost pokryvu země jednotlivých tříd, kde bude plocha jednotlivých tříd pokryvu země zaokrouhlena na tři desetinná místa a procentuální vyjádření na dvě desetinná místa
- Vytvoření mapových výstupů pro tři nejlepší klasifikační metody a spektrální indexy NDWI a NDVI v rámci každého období.
- Porovnání pokryvu země mezi jednotlivými obdobími

Vytvoření trénovacích ploch

Trénovací plochy byly vytvořeny na základě vizuální analýzy satelitního snímku a v případě dostupnosti, ortofotomap ČÚZK. Velikost trénovacích ploch poměrově přibližně odpovídala celkovému rozložení jednotlivých tříd pokryvu země na snímcích.



Obrázek 17: Zdrojové snímky pro klasifikaci

Zdroj: vlastní zpracování dle dat [31] a [12]

Na obrázku 17 lze v levé části vidět výřez snímku, ve kterém se zrovna vytvářely trénovací plochy v rámci programu ENVI, a v pravé části obrázku je příklad ortofotomapy na webu ČÚZK. V tabulce 16 je uveden příklad množství trénovacích bodů pro jednotlivé třídy pro snímek z roku 2013:

Tabulka 16: Množství trénovacích bodů pro jednotlivé třídy za rok 2013

Třída	Počet pixelů
Městské plochy	3318
Lesy	5876
Zeleň	5233
Vodní plochy	489
Pole	9034

Zdroj: vlastní

6.1. Klasifikace dat za období roku 2013

V tabulce 17 jsou výsledky přesnosti přesností jednotlivých metod řízené klasifikace pro období roku 2013:

Tabulka 17: Přehled přesností klasifikačních metod za sledované období v roce 2013

Metoda	Celková přesnost	Kappa koeficient
SVM (RBF)	96,22 %	0,9483
SVM (LIN)	96,29 %	0,9493
MLC	95,77 %	0,9423
MINDP	85,51 %	0,806
MAHADP	90,17 %	0,8661

Zdroj: vlastní

V tabulce 17 je vidět, že nejlepší metodou je SVM (LIN) s přesností 96,29 % správně zařazených bodů do dané třídy, velmi podobně dopadla SVM (RBF) s přesností 96,22 % správně zařazených bodů do dané třídy a třetí nejlepší metodou je MLC s přesností 95,77 %. Pro tyto tři nejlepší metody tedy bude vytvořen mapový podklad.

Klasifikace SVM (LIN) za období roku 2013

Podrobnější pohled na přesnost klasifikace SVM (LIN) za rok 2013 je v tabulce 18:

Tabulka 18: Chybová matice v rámci metody SVM (LIN) za sledované období v roce 2013

	Městské plochy	Lesy	Zeleň	Vodní plochy	Pole	Součet
Městské plochy	3005	12	265	0	36	3318
Lesy	77	5799	0	0	0	5876


Zeleň	293	16	4911	0	13	5233
Vodní plochy	1	0	0	488	0	489
Pole	146	8	22	0	8858	9034
Součet	3522	5835	5198	488	8907	23950

Zdroj: vlastní

Z tabulky 18 je patrné, že z celkového součtu 3318 pixelů, které byly v trénovacích datech označeny jako městské plochy, bylo správně klasifikovaných 3005 (ve výsledku klasifikace byly v třídě městské plochy), 12 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako lesy, 265 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako zeleň a 36 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako pole. Z tabulky 18 je dále patrné, že z celkového součtu 489 pixelů, které byly v trénovacích datech označeny jako vodní plochy, bylo 488 správně klasifikovaných jako vodních plochy a 1 pixel byl špatně zařazen jako městské plochy. Všechny další třídy v tabulce jsou správně či špatně zařazené podle stejné principu.

Na obrázku 18 je mapový výstup klasifikace SVM (LIN) pro snímky Landsat 8 v roce 2013:

KLASIFIKACE SVM (LIN) ZÁJMOVÉHO ÚZEMÍ v roce 2013



■ Městské plochy
 ■ Lesy
 ■ Zelen
 ■ Vodní plochy
 ■ Pole

0 5 10 km

Jiri KOPRIVA
Pardubice 2019
Zdroj: <https://earthexplorer.usgs.gov/>

Obrázek 18: Mapový výstup klasifikace SVM (LIN) za sledované období v roce 2013

Zdroj: vlastní zpracování dle dat [12]

V tabulce 19 je znázorněna plocha jednotlivých tříd v rámci metody SVM (LIN) za sledované období v roce 2013:

Tabulka 19: Plochy jednotlivých tříd v rámci metody SVM (LIN) za sledované období v roce 2013

Třída	Plocha [km ²]	Plocha [%]
Městské plochy	81,296	7,55
Lesy	376,410	34,94
Zeleň	367,601	34,12
Vodní plochy	6,064	0,56
Pole	245,912	22,83

Zdroj: vlastní

Z tabulky 19 je patrné, že největší plochu zaujímají lesy s 34,94 %, dále je významnou plochou zeleň s 34,12 %, méně již je polí s 22,83 %, městských ploch je 7,55 % a nejméně území zaujímají vodní plochy s 0,56 %.

Klasifikace SVM (RBF) za období roku 2013

Podrobnější pohled na přesnost klasifikace SVM (RBF) za rok 2013 je v tabulce 20:

Tabulka 20: Chybová matice v rámci metody SVM (RBF) za sledované období v roce 2013

	Městské plochy	Lesy	Zeleň	Vodní plochy	Pole	Součet
Městské plochy	2952	16	218	0	46	3232
Lesy	82	5792	0	0	0	5874
Zeleň	319	18	4967	0	16	5320
Vodní plochy	2	0	0	488	0	490
Pole	167	9	13	0	8845	9034
Součet	3522	5835	5198	488	8907	23950


Zdroj: vlastní

Z tabulky 20 je patrné, že z celkového součtu 3232 pixelů, které byly v trénovacích datech označeny jako městské plochy, bylo správně klasifikovaných 2952 (ve výsledku klasifikace byly v třídě městské plochy), 16 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako lesy, 218 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako zeleň a 46 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako pole. Žádný pixel městských ploch z trénovacích dat nebyl klasifikován jako vodní plocha.

Z tabulky 20 je dále patrné, že z celkového součtu 490 pixelů, které byly v trénovacích datech označeny jako vodní plochy, bylo 488 správně klasifikovaných jako vodních plochy a 2 pixely byly špatně zařazeny jako městské plochy. Žádný pixel vodních ploch z trénovacích dat nebyl klasifikován jako les, zeleň či pole.

Všechny další třídy v tabulce jsou správně či špatně zařazené podle stejné principu. Na obrázku 19 je mapový výstup klasifikace SVM (RBF) pro snímky Landsat 8 v roce 2013:

KLASIFIKACE SVM (RBF) ZÁJMOVÉHO ÚZEMÍ v roce 2013



Obrázek 19: Mapový výstup klasifikace SVM (RBF) za sledované období v roce 2013

Zdroj: vlastní zpracování dle dat [12]

V tabulce 21 je znázorněna plocha jednotlivých tříd v rámci metody SVM (RBF) za sledované období v roce 2013:

Tabulka 21: Plochy jednotlivých tříd v rámci metody SVM (RBF) za sledované období v roce 2013

Třída	Plocha [km ²]	Plocha [%]
Městské plochy	81,824	7,60
Lesy	373,132	34,64
Zeleň	371,751	34,51
Vodní plochy	5,970	0,55
Pole	244,605	22,71

Zdroj: vlastní

Z tabulky 21 je patrné, že největší plochu zaujímají lesy s 34,64 %, dále je významnou plochou zeleň s 34,51 %, o mnoho méně již je polí s 22,71 %, městských ploch je 7,6 % a nejméně území zaujímají vodní plochy s 0,55 %.

Klasifikace MLC za období roku 2013

Podrobnější pohled na přesnost klasifikace MLC za rok 2013 je v tabulce 22:

Tabulka 22: Chybová matice v rámci metody MLC za sledované období v roce 2013

	Městské plochy	Lesy	Zeleň	Vodní plochy	Pole	Součet
Městské plochy	3115	41	208	1	67	3432
Lesy	19	5618	11	0	0	5648
Zeleň	339	167	4932	0	56	5494
Vodní plochy	0	0	0	487	0	487
Pole	49	9	47	0	8784	8889
Součet	3522	5835	5198	488	8907	23950


Zdroj: vlastní

Z tabulky 22 je patrné například, že z celkového součtu 3432 pixelů, které byly v trénovacích datech označeny jako městské plochy bylo správně klasifikovaných 3115 (ve výsledku klasifikace byly v třídě městské plochy), 41 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako lesy, 208 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako zeleň, 1 pixel městských ploch z trénovacích dat byl špatně klasifikován jako vodní plocha a 67 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako pole.

Z tabulky 22 je dále patrné, že z celkového součtu 487 pixelů, které byly v trénovacích datech označeny jako vodní plochy, byly všechny správně klasifikovaných jako vodní plochy. Všechny další třídy v tabulce jsou správně či špatně zařazené podle stejné principu.

Na obrázku 20 je mapový výstup klasifikace MLC pro snímky Landsat 8 v roce 2013:

KLASIFIKACE MLC ÚZEMÍ ZÁJMOVÉHO ÚZEMÍ v roce 2013



Obrázek 20: Mapový výstup klasifikace MLC za sledované období v roce 2013

Zdroj: vlastní zpracování dle dat [12]

V tabulce 23 je znázorněna plocha jednotlivých tříd v rámci metody MLC za sledované období v roce 2013:

Tabulka 23: Plochy jednotlivých tříd v rámci metody MLC za sledované období v roce 2013

Třída	Plocha [km ²]	Plocha [%]
Městské plochy	147,580	13,70
Lesy	308,579	28,64
Zeleň	380,608	35,33
Vodní plochy	3,266	0,30
Pole	237,248	22,02

Zdroj: vlastní

Z tabulky 23 je patrné, že největší plochu zaujímá zeleň s 35,33 %, dále jsou významnou plochou lesy s 28,64 %, o něco méně již je pole s 22,02 %, městských ploch je 13,7 % a nejméně území zaujímají vodní plochy s 0,3 %.

6.2. Klasifikace dat za období roku 2016

V následující tabulce jsou výsledky přesnosti klasifikace pro období roku 2016:

Tabulka 24: Přehled klasifikačních metod za sledované období v roce 2016

Metoda	Celková přesnost	Kappa koeficient
SVM (RBF)	97.38 %	0.9646
SVM (LIN)	97.73 %	0.9693
MLC	97.30 %	0.9635
MINDP	82.01 %	0.7617
MAHADP	93.31 %	0.9099

Zdroj: vlastní

Nejlepší metodou je SVM (LIN) s přesností 97,73 % správně zařazených bodů do dané třídy, velmi podobně dopadla SVM (RBF) s přesností 97,38 % správně zařazených bodů do dané třídy a třetí nejlepší metodou je MLC s přesností 97,30 %. Pro tyto tři nejlepší metody tedy bude vytvořen mapový podklad.

Klasifikace SVM (LIN) za období roku 2016

Podrobnější pohled na přesnost klasifikace SVM (LIN) za rok 2016 je v tabulce 25:

Tabulka 25: Chybová matice v rámci metody SVM (LIN) za sledované období v roce 2016

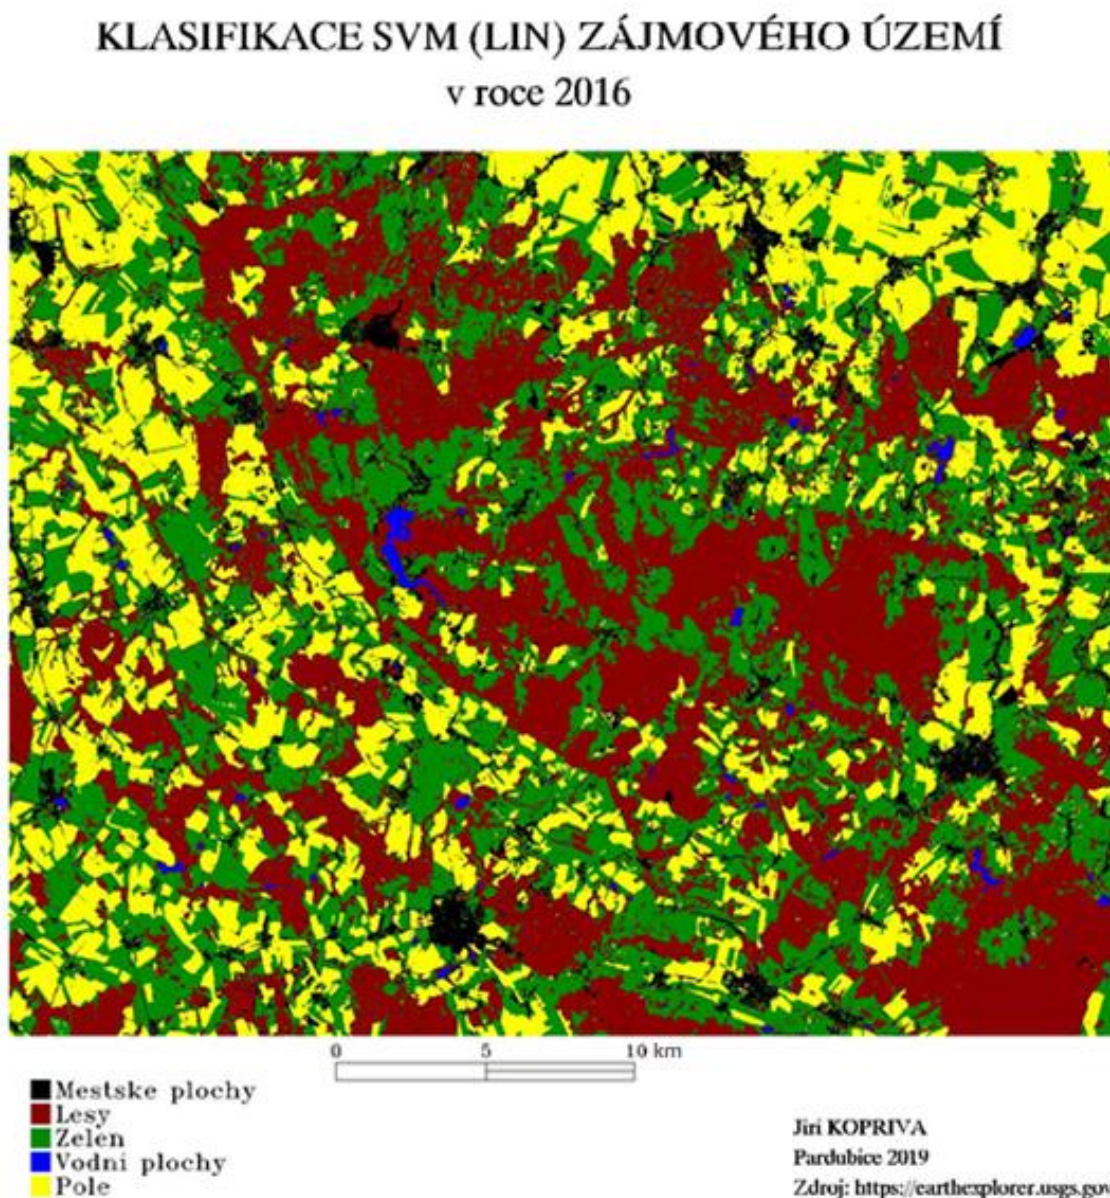
	Městské plochy	Lesy	Zeleň	Vodní plochy	Pole	Součet
Městské plochy	3274	42	24	0	36	3376
Lesy	59	5762	27	0	0	5848
Zeleň	128	31	2948	0	7	3114
Vodní plochy	0	0	0	488	0	488
Pole	61	0	16	0	6069	6146
Součet	3522	5835	3015	488	6112	18972

Zdroj: vlastní

Z tabulky 25 je patrné, že z celkového součtu 5848 pixelů, které byly v trénovacích datech označeny jako lesy, bylo správně klasifikovaných 5762 (ve výsledku klasifikace byly v třídě lesy), 59 pixelů lesů z trénovacích dat bylo špatně klasifikováno jako městské plochy, 27 pixelů lesů z trénovacích dat bylo špatně klasifikováno jako zeleň. Žádný pixel lesů z trénovacích dat nebyl klasifikován jako vodní plocha či pole.

Z tabulky 25 je patrné, že z celkového součtu 6146 pixelů, které byly v trénovacích datech označeny jako pole, bylo 6069 správně klasifikovaných jako pole, 61 pixelů bylo špatně zařazeno jako městské plochy a 16 pixelů bylo špatně zařazeno jako zeleň. Žádný pixel polí z trénovacích dat nebyl klasifikován jako vodní plocha či les. Všechny další třídy v tabulce jsou správně či špatně zařazené podle stejné principu.

Na následujícím obrázku je mapový výstup klasifikace SVM (LIN) pro snímky Landsat 8 v roce 2016:



Obrázek 21: Mapový výstup klasifikace SVM (LIN) za sledované období v roce 2016

Zdroj: vlastní zpracování dle dat [12]

V tabulce 26 je znázorněna plocha jednotlivých tříd v rámci metody SVM (LIN) za sledované období v roce 2016:

Tabulka 26: Plochy jednotlivých tříd v rámci metody SVM (LIN) za sledované období v roce 2016

Třída	Plocha [km ²]	Plocha [%]
Městské plochy	79,769	7,40
Lesy	367,022	34,07
Zeleň	364,508	33,84
Vodní plochy	6,107	0,57
Pole	259,877	24,12

Zdroj: vlastní

Z tabulky 26 je patrné, že největší plochu zaujímají lesy s 34,07 %, dále je významnou plochou zeleň s 33,84 %, o mnoho méně již je polí s 24,12 %, městských ploch je 7,4 % a nejméně území zaujímají vodní plochy s 0,57 %.

Klasifikace SVM (RBF) za období roku 2016

Podrobnější pohled na přesnost klasifikace SVM (RBF) za rok 2016 je v tabulce 27:

Tabulka 27: Chybová matice v rámci metody SVM (RBF) za sledované období v roce 2016

	Městské plochy	Lesy	Zeleň	Vodní plochy	Pole	Součet
Městské plochy	3250	35	45	0	41	3371
Lesy	58	5763	42	0	0	5863
Zeleň	140	37	2910	0	8	3095
Vodní plochy	1	0	0	488	0	489
Pole	73	0	18	0	6063	6154
Součet	3522	5835	3015	488	6112	18972

Zdroj: vlastní


Z tabulky 27 je patrné, že z celkového součtu 5863 pixelů, které byly v trénovacích datech označeny jako lesy, bylo správně klasifikovaných 5763 (ve výsledku klasifikace byly v třídě lesy), 58 pixelů lesů z trénovacích dat bylo špatně klasifikováno jako městské plochy, 42 pixelů lesů z trénovacích dat bylo špatně klasifikováno jako zeleň. Žádný pixel lesů z trénovacích dat nebyl klasifikován jako vodní plocha či pole.

Z tabulky 27 je patrné, že z celkového součtu 6154 pixelů, které byly v trénovacích datech označeny jako pole, bylo 6063 správně klasifikovaných jako pole, 73 pixelů bylo špatně zařazeno jako městské plochy a 18 pixelů bylo špatně zařazeno jako zeleň. Žádný pixel polí z trénovacích dat nebyl klasifikován jako vodní plocha či les.

Všechny další třídy v tabulce jsou správně či špatně zařazené podle stejného principu.

Na následujícím obrázku je mapový výstup klasifikace SVM (RBF) pro snímky Landsat 8 v roce 2016:

KLASIFIKACE SVM (RBF) ZÁJMOVÉHO ÚZEMÍ v roce 2016



Obrázek 22: Mapový výstup klasifikace SVM (RBF) za sledované období v roce 2016

Zdroj: vlastní zpracování dle dat [12]

V tabulce 28 je znázorněna plocha jednotlivých tříd v rámci metody SVM (RBF) za sledované období v roce 2016:

Tabulka 28: Plochy jednotlivých tříd v rámci metody SVM (RBF) za sledované období v roce 2016

Třída	Plocha [km ²]	Plocha [%]
Městské plochy	80,034	7,43
Lesy	367,057	34,07
Zeleň	364,799	33,86
Vodní plochy	6,195	0,58
Pole	259,197	24,06

Zdroj: vlastní

Z tabulky 28 je patrné, že největší plochu zaujímají lesy s 34,07 %, dále je významnou plochou zeleň s 33,86 %, o něco méně již je polí s 24,06 %, městských ploch je 7,43 % a nejméně území zaujímají vodní plochy s 0,58 %.

Klasifikace MLC za období roku 2016

Podrobnější pohled na přesnost klasifikace MLC za rok 2013 je v tabulce 29:

Tabulka 29: Chybová matice v rámci metody MLC za sledované období v roce 2016

	Městské plochy	Lesy	Zeleň	Vodní plochy	Pole	Součet
Městské plochy	3337	119	52	3	55	3566
Lesy	20	5680	55	0	0	5755
Zeleň	112	32	2906	0	6	3056
Vodní plochy	0	0	0	485	0	485
Pole	53	4	2	0	6051	6110
Součet	3522	5835	3015	488	6112	18972

Zdroj: vlastní


Z tabulky 29 je patrné, že z celkového součtu 5755 pixelů, které byly v trénovacích datech označeny jako lesy, bylo správně klasifikovaných 5680 (ve výsledku klasifikace byly v třídě lesy), 20 pixelů lesů z trénovacích dat bylo špatně klasifikováno jako městské plochy, 55 pixelů lesů z trénovacích dat bylo špatně klasifikováno jako zeleň. Žádný pixel lesů z trénovacích dat nebyl klasifikován jako vodní plocha či pole.

Z tabulky 29 je dále patrné, že z celkového součtu 6110 pixelů, které byly v trénovacích datech označeny jako pole, bylo 6051 správně klasifikovaných jako pole, 53 pixelů bylo špatně zařazeno jako městské plochy, 2 pixely bylo špatně zařazeno jako zeleň, 4 pixely byly špatně zařazeny jako lesy. Žádný pixel polí z trénovacích dat nebyl klasifikován jako vodní plocha.

Z tabulky 29 je dále patrné, že z celkového součtu 3056 pixelů, které byly v trénovacích datech označeny jako zeleň, bylo 2906 správně klasifikovaných jako zeleň, 112 pixelů bylo špatně zařazeno jako městské plochy, 32 pixelů bylo špatně zařazeno jako lesy a 6 pixelů bylo špatně zařazeno jako pole. Žádný pixel zeleň z trénovacích dat nebyl klasifikován jako vodní plocha. Všechny další třídy v tabulce jsou správně či špatně zařazené podle stejného principu.

Na obrázku 23 je mapový výstup klasifikace MLC pro snímky Landsat 8 v roce 2016:

KLASIFIKACE MLC ZÁJMOVÉHO ÚZEMÍ v roce 2016



Obrázek 23: Mapový výstup klasifikace MLC za sledované období v roce 2016

Zdroj: vlastní zpracování dle dat [12]

V tabulce 30 je znázorněna plocha jednotlivých tříd v rámci metody MLC za sledované období v roce 2016:

Tabulka 30: Plochy jednotlivých tříd v rámci metody MLC za sledované období v roce 2016

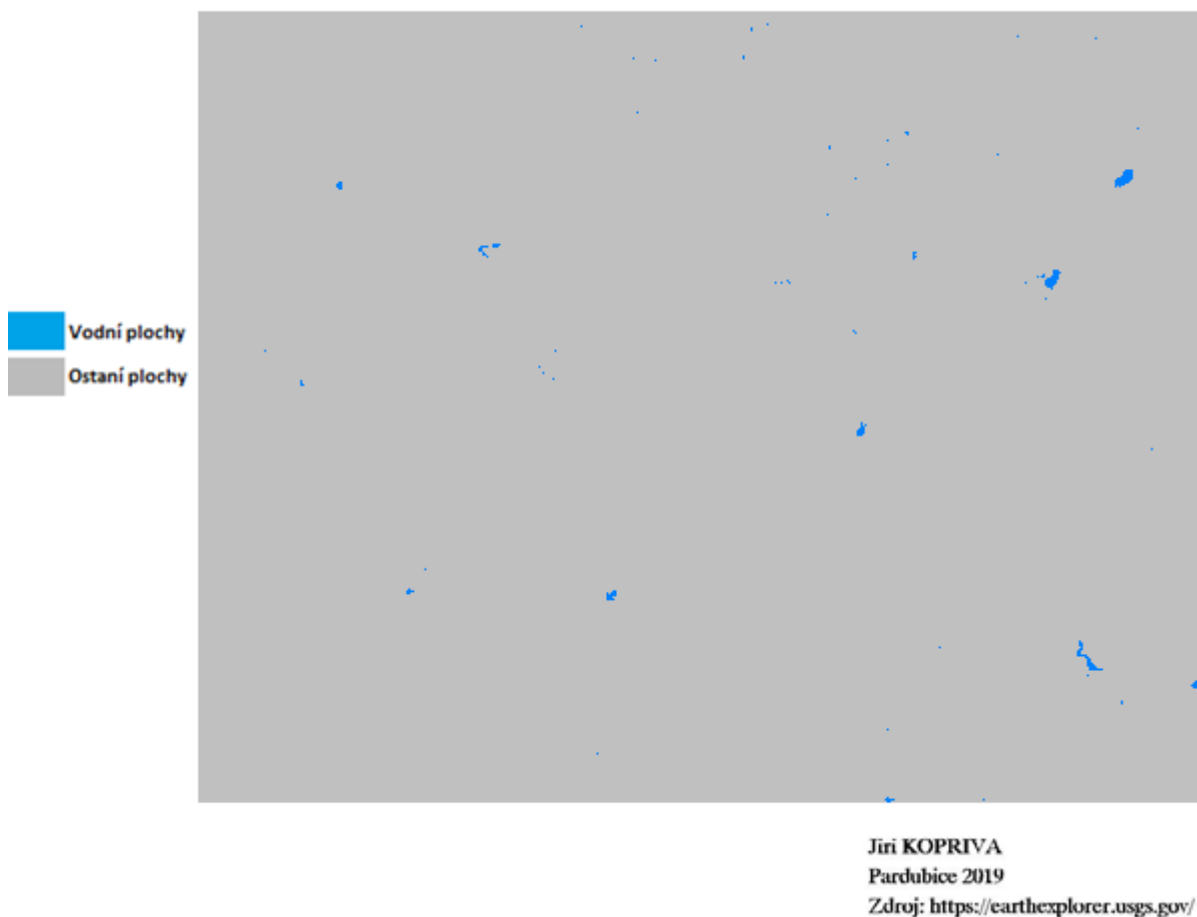
Třída	Plocha [km ²]	Plocha [%]
Městské plochy	163,016	15,13
Lesy	327,257	30,38
Zeleň	337,587	31,34
Vodní plochy	3,646	0,34
Pole	245,776	22,81

Zdroj: vlastní

Z tabulky 30 je patrné, že největší plochu zaujímá zeleň s 31,34 %, dále jsou významnou plochou lesy s 30,38 %, méně již je polí s 22,81 %, městských ploch je 15,13 % a nejméně území zaujímají vodní plochy s 0,34 %.

Na obrázku 24 je klasifikace pomocí spektrálního indexu NDVI pro rok 2016

KLASIFIKACE NDVI ZÁJMOVÉHO ÚZEMÍ v roce 2016




Obrázek 24: Mapový výstup spektrálního indexu NDVI za sledované období v roce 2016

Zdroj: vlastní zpracování dle dat [12]

Klasifikace pomocí spektrálního indexu NDVI v roce 2016 neukázala očekávaný výstup. Některé vodní plochy nebyly klasifikovány, i když se na satelitním snímku vyskytují. Tento mapový výstup tedy nebude brán při vyhodnocení jako relevantní. Celková plocha vodních ploch v zájmovém území v roce 2016 podle NDVI je 1,543 km².

KLASIFIKACE NDWI ZÁJMOVÉHO ÚZEMÍ v roce 2016



Jiri KOPRIVA
Pardubice 2019
Zdroj: <https://earthexplorer.usgs.gov/>

Obrázek 25: Mapový výstup spektrálního indexu za sledované období v roce 2016

Zdroj: vlastní zpracování dle dat [12]

Celková plocha vodních ploch v zájmové území v roce 2016 podle NDWI je 4,806 km².

6.3. Klasifikace dat za období roku 2018

V tabulce 31 jsou výsledky přesnosti klasifikace pro období roku 2018:

Tabulka 31: Přehled klasifikačních metod za sledované období v roce 2018

Metoda	Celková přesnost	Kappa koeficient
SVM (RBF)	96.21 %	0.9471
SVM (LIN)	96.51 %	0.9512
MLC	95.93 %	0.9436
MINDP	86.29 %	0.8127
MAHADP	86.79 %	0.8201

Zdroj: vlastní

Nejlepší metodou je SVM (LIN) s přesností 96,51 % správně zařazených bodů do dané třídy, velmi podobně dopadla SVM (RBF) s přesností 96,21 % správně zařazených bodů do dané třídy a třetí nejlepší metodou je MLC s přesností 95,93 %. Pro tyto tři nejlepší metody tedy bude vytvořen mapový podklad.

Klasifikace SVM (LIN) za období roku 2018

Podrobnější pohled na přesnost klasifikace SVM (LIN) za rok 2018 je v tabulce:

Tabulka 32: Chybová matice v rámci metody SVM (LIN) za sledované období v roce 2018

	Městské plochy	Lesy	Zeleň	Vodní plochy	Pole	Součet
Městské plochy	2924	24	40	2	187	3177
Lesy	51	7956	2	0	0	8009
Zeleň	141	19	4405	0	38	4603
Vodní plochy	0	0	0	342	0	342
Pole	406	0	7	0	9666	10079
Součet	3522	7999	4454	342	9891	26208

Zdroj: vlastní

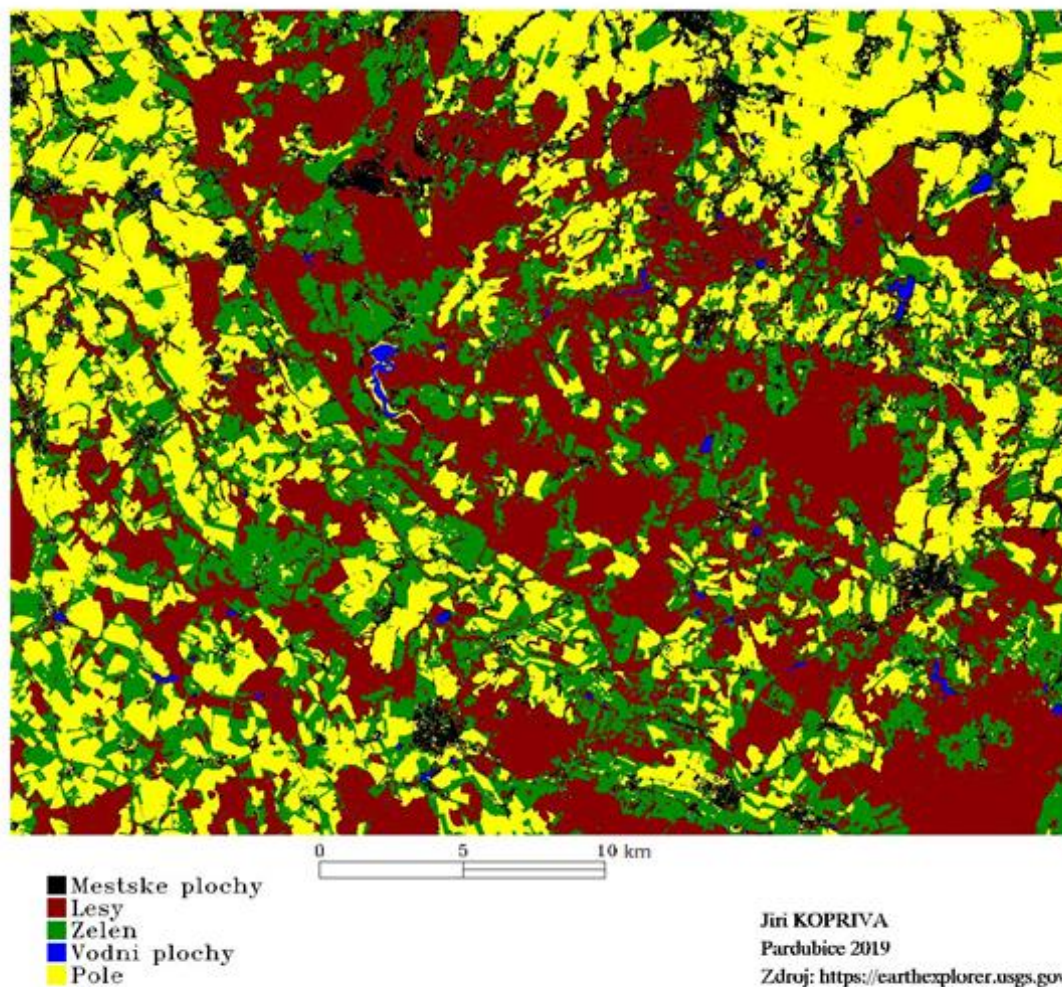
Z tabulky 32 je patrné, že z celkového součtu 4603 pixelů, které byly v trénovacích datech označeny jako zeleň, bylo správně klasifikovaných 4405 (ve výsledku klasifikace byly v třídě městské plochy), 19 pixelů zeleně z trénovacích dat bylo špatně klasifikováno jako lesy, 141 pixelů zeleně z trénovacích dat bylo špatně klasifikováno jako městské plochy a 38 pixelů zeleně z trénovacích dat bylo špatně klasifikováno jako pole. Žádný pixel zeleně z trénovacích dat nebyl klasifikován jako vodní plocha.

Z tabulky 32 je dále patrné, že z celkového součtu 342 pixelů, které byly v trénovacích datech označeny jako vodní plochy, bylo všech 342 správně klasifikovaných jako vodní plochy.

Z tabulky 32 je patrné, že z celkového součtu 8009 pixelů, které byly v trénovacích datech označeny jako lesy, bylo správně klasifikovaných 7956 (ve výsledku klasifikace byly v třídě lesy), 51 pixelů lesů z trénovacích dat bylo špatně klasifikováno jako městské plochy, 2 pixely lesů z trénovacích dat byly špatně klasifikovány jako zeleň. Žádný pixel lesů z trénovacích dat nebyl klasifikován jako vodní plocha nebo pole. Všechny další třídy v tabulce jsou správně či špatně zařazené podle stejného principu.

Na obrázku 26 je mapový výstup klasifikace SVM (LIN) pro snímky Landsat 8 v roce 2018:

KLASIFIKACE SVM (LIN) ZÁJMOVÉHO ÚZEMÍ v roce 2018



Obrázek 26: Mapový výstup klasifikace SVM (LIN) za sledované období v roce 2018

Zdroj: vlastní zpracování dle dat [12]

V tabulce 33 je znázorněna plocha jednotlivých tříd v rámci metody SVM (LIN) za sledované období v roce 2018:

Tabulka 33: Plochy jednotlivých tříd v rámci metody SVM (LIN) za sledované období v roce 2018

Třída	Plocha [km ²]	Plocha [%]
Městské plochy	91,398	8,48
Lesy	384,573	35,70
Zeleň	277,070	25,72
Vodní plochy	4,339	0,40
Pole	319,902	29,70

Zdroj: vlastní

Z tabulky 33 je patrné, že největší plochu zaujímají lesy s 35,7 %, dále je významnou plochou pole s 29,7 %, méně již je zeleně s 25,72 %, městských ploch je 8,48 % a nejméně území zaujímají vodní plochy s 0,4 %.

Klasifikace SVM (RBF) za období roku 2018

Podrobnější pohled na přesnost klasifikace SVM (RBF) za rok 2018 je v tabulce 34:

Tabulka 34: Chybová matice v rámci metody SVM (RBF) za sledované období v roce 2018

	Městské plochy	Lesy	Zeleň	Vodní plochy	Pole	Součet
Městské plochy	2911	34	43	0	240	3228
Lesy	51	7945	1	0	0	7997
Zeleň	135	20	4407	0	41	4603
Vodní plochy	0	0	0	342	0	342
Pole	425	0	3	0	9610	10038
Součet	3522	7999	4454	342	9891	26208

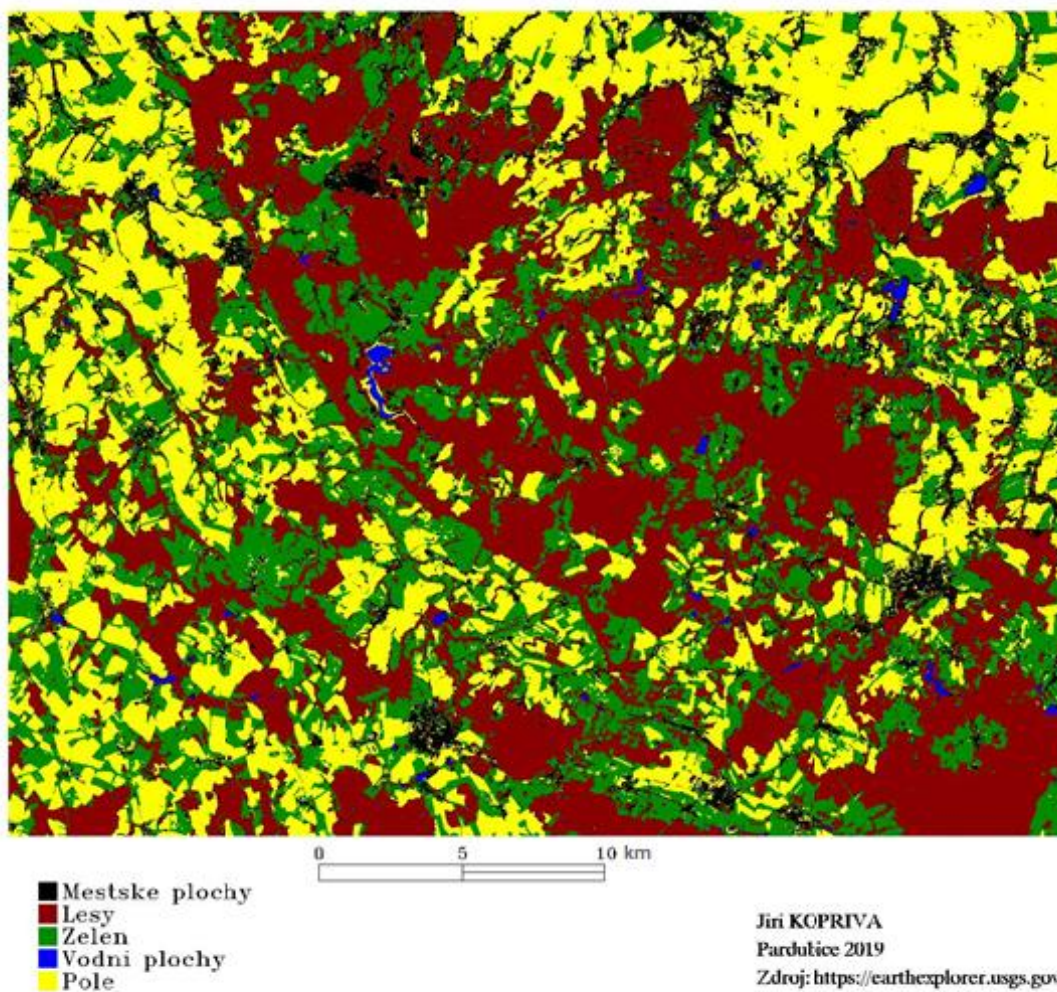
Zdroj: vlastní

Z tabulky 34 je patrné například, že z celkového součtu 3228 pixelů, které byly v trénovacích datech označeny jako městské plochy, bylo správně klasifikovaných 2911 (ve výsledku klasifikace byly v třídě městské plochy), 34 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako lesy, 43 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako zeleň a 240 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako pole. Žádný pixel městských ploch z trénovacích dat nebyl klasifikován jako vodní plocha.

Z tabulky 34 je dále patrné například, že z celkového součtu 10038 pixelů, které byly v trénovacích datech označeny jako pole, bylo 9610 správně klasifikovaných jako vodních plochy, 3 pixely byly špatně zařazeny jako zeleň a 425 pixelů byly špatně zařazeny jako městské plochy. Žádný pixel polí z trénovacích dat nebyl klasifikován jako vodní plocha či les. Všechny další třídy v tabulce jsou správně či špatně zařazené podle stejného principu.

Na obrázku 27 je mapový výstup klasifikace SVM (RBF) pro snímky Landsat 8 v roce 2018:

KLASIFIKACE SVM (RBF) ZÁJMOVÉHO ÚZEMÍ v roce 2018



Obrázek 27: Mapový výstup klasifikace SVM (RBF) za sledované období v roce 2018

Zdroj: vlastní zpracování dle dat [12]

V tabulce 35 je znázorněna plocha jednotlivých tříd v rámci metody SVM (RBF) za sledované období v roce 2018:

Tabulka 35: Plochy jednotlivých tříd v rámci metody SVM (RBF) za sledované období v roce 2016

Metoda	Plocha [km ²]	Plocha [%]
Městské plochy	93,556	8,68
Lesy	381,248	35,39
Zezeň	278,764	25,88
Vodní plochy	4,271	0,40
Pole	319,443	29,65

Zdroj: vlastní

Z tabulky 35 je patrné, že největší plochu zaujímají lesy s 35,39 %, dále je významnou plochou pole s 29,65 %, zeleň zahrnuje 25,88 % území, městských ploch je 8,68 % a nejméně území zaujímají vodní plochy s 0,4 %.

Klasifikace MLC za období roku 2018

Podrobnější pohled na přesnost klasifikace MLC za rok 2018 je v tabulce 36:

Tabulka 36: Chybová matice v rámci metody MLC za sledované období v roce 2018

	Městské plochy	Lesy	Zeleň	Vodní plochy	Pole	Součet
Městské plochy	3185	207	14	2	300	3708
Lesy	14	7779	0	0	0	7793
Zeleň	233	10	4436	0	190	4869
Vodní plochy	0	0	0	340	0	340
Pole	90	3	4	0	9401	9498
Součet	3522	7999	4454	342	9891	26208

Zdroj: vlastní

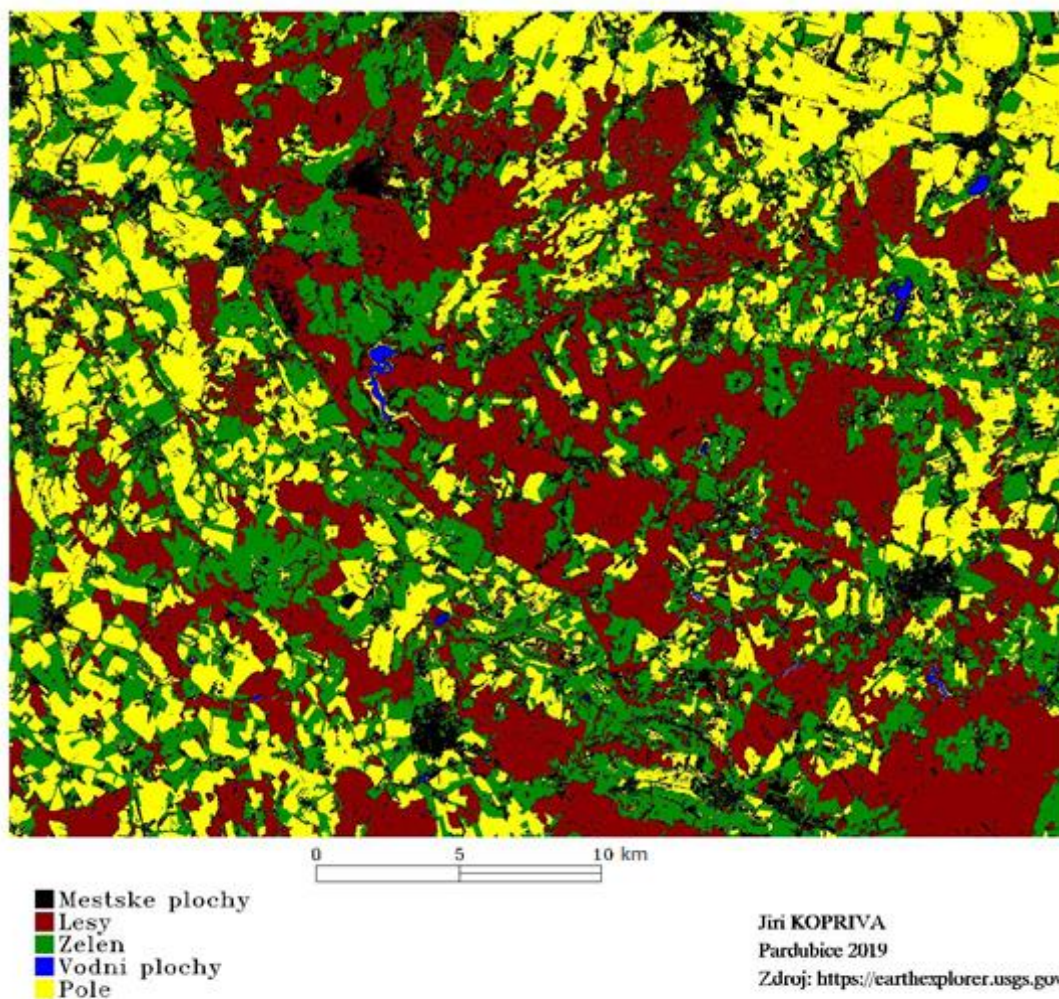
Z tabulky 36 je patrné, že z celkového součtu 3708 pixelů, které byly v trénovacích datech označeny jako městské plochy, bylo správně klasifikovaných 3185 (ve výsledku klasifikace byly v třídě městské plochy), 207 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako lesy, 14 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako zeleň, 300 pixelů městských ploch z trénovacích dat bylo špatně klasifikováno jako pole a 2 pixely byly klasifikovány jako vodní plochy.

Z tabulky 36 je dále patrné, že z celkového součtu 340 pixelů, které byly v trénovacích datech označeny jako vodní plochy, bylo všech 340 správně klasifikovaných jako vodních plochy. Všechny další třídy v tabulce jsou správně či špatně zařazené podle stejného principu.

Z tabulky 36 je patrné, že z celkového součtu 7793 pixelů, které byly v trénovacích datech označeny jako lesy, bylo správně klasifikovaných 7779 (ve výsledku klasifikace byly v třídě lesy), 14 pixelů lesů z trénovacích dat bylo špatně klasifikováno jako městské plochy. Žádný pixel zeleně z trénovacích dat nebyl klasifikován jako vodní plocha, zeleň nebo pole.

Na obrázku 28 je mapový výstup klasifikace MLC pro snímky Landsat 8 v roce 2018:

KLASIFIKACE MLC ZÁJMOVÉHO ÚZEMÍ v roce 2018



Obrázek 28: Mapový výstup klasifikace MLC za sledované období v roce 2018

Zdroj: vlastní zpracování dle dat [12]

V tabulce 37 je znázorněna plocha jednotlivých tříd v rámci metody MLC za sledované období v roce 2018:

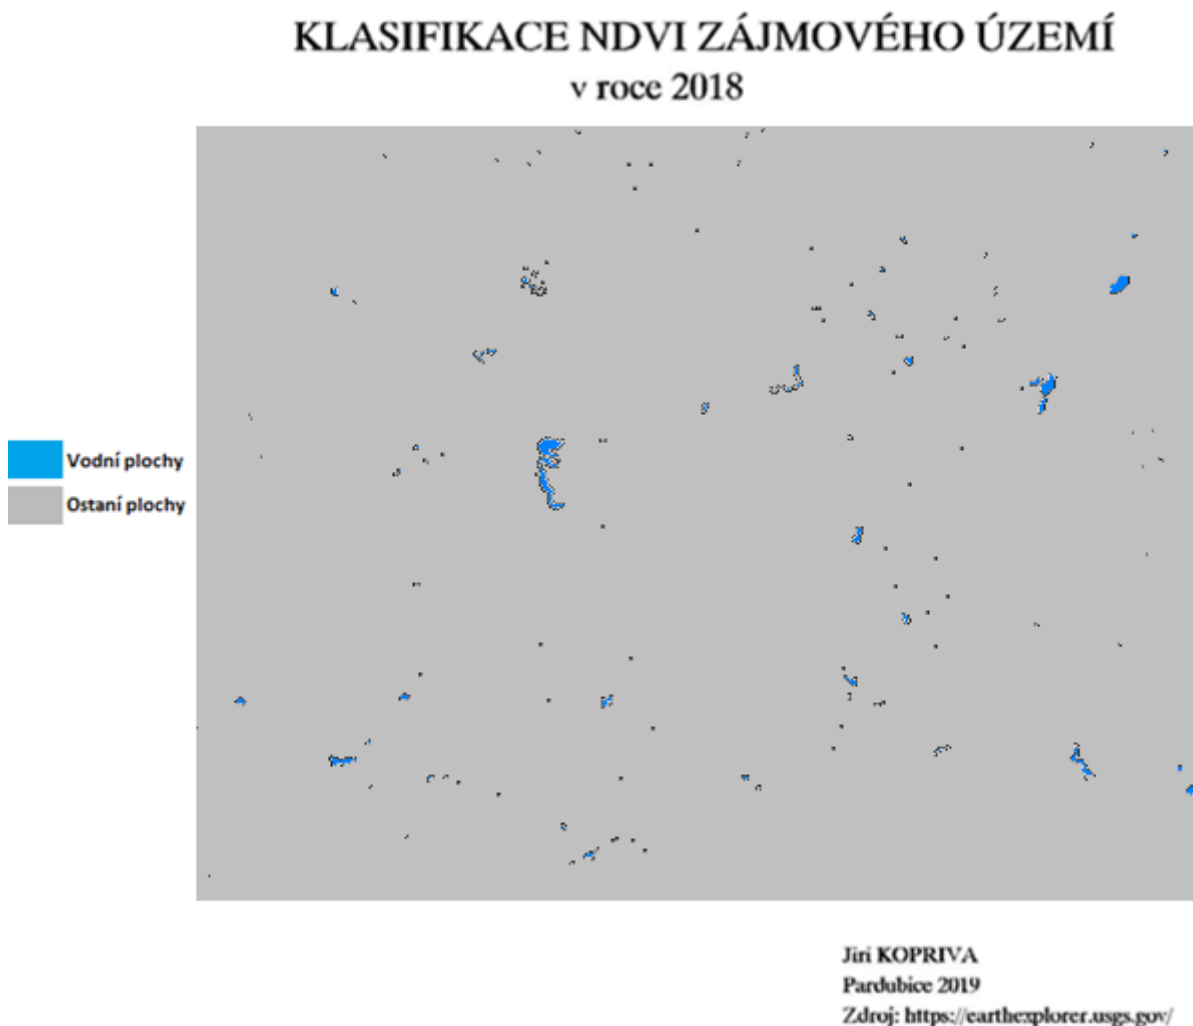
Tabulka 37: Plochy jednotlivých tříd v rámci metody MLC za sledované období v roce 2018

Metoda	Plocha [km ²]	Plocha [%]
Městské plochy	179,011	16,62
Lesy	323,543	30,03
Zeleň	290,871	27,00
Vodní plochy	2,132	0,20
Pole	281,725	26,15

Zdroj: vlastní

Z tabulky 37 je patrné, že největší plochu zaujímají lesy s 30,03 %, dále je významnou plochou zeleň s 27 %, méně již je polí s 26,15 %, městských ploch je 16,62 % a nejméně území zaujímají vodní plochy s 0,2 %.

Na obrázku 29 je mapový výstup klasifikace pomocí spektrálního indexu NDVI pro snímky Landsat 8 v roce 2018:



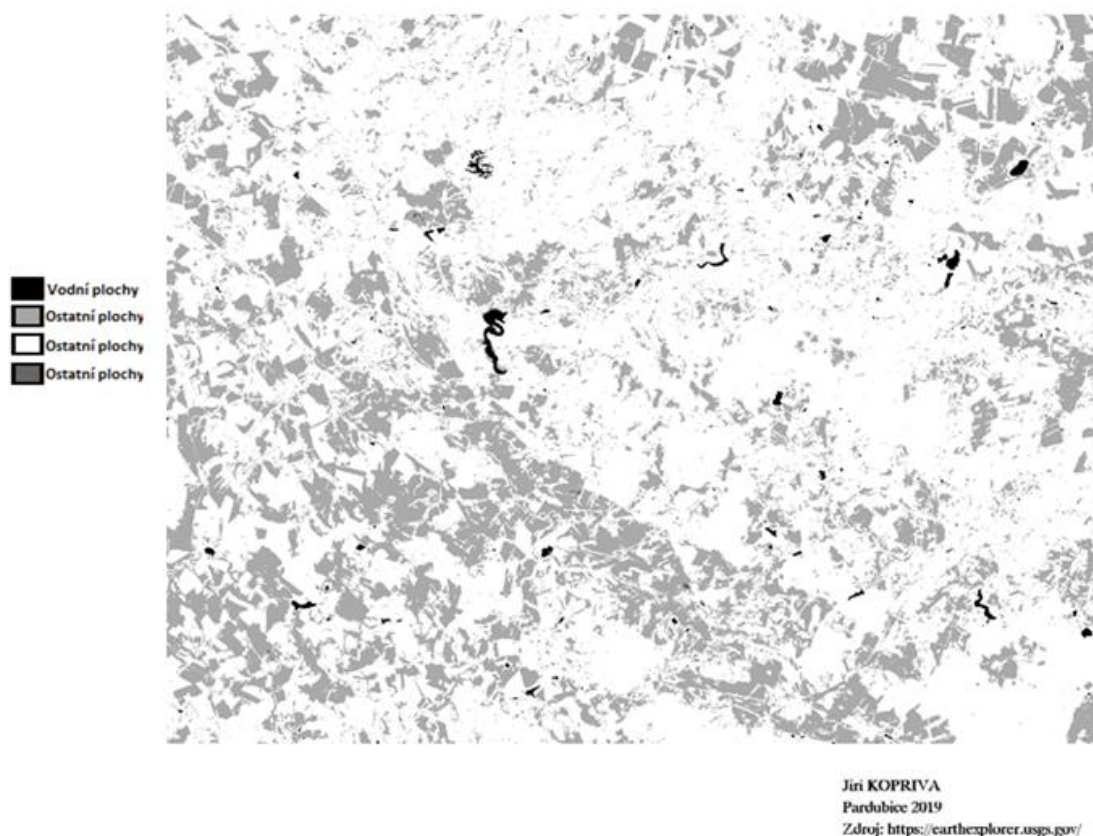
Obrázek 29: Mapový výstup spektrálního indexu NDVI za sledované období v roce 2018

Zdroj: vlastní zpracování dle dat [12]

NDVI na snímku z roku 2018 velmi dobře zvýrazňuje vodní plochy, které jsou vyznačeny modrou barvou na obrázku 29. Celková plocha vodních ploch v zájmovém území podle NDVI je 4,365 km².

Na obrázku 30 je mapový výstup klasifikace pomocí spektrálního indexu NDWI pro snímky Landsat 8 v roce 2018:

KLASIFIKACE NDWI ZÁJMOVÉHO ÚZEMÍ v roce 2018



Obrázek 30: Mapový výstup spektrálního indexu NDVI za sledované období v roce 2018

Zdroj: vlastní zpracování dle dat [12]

Celková plocha vodních ploch v zájmovém území v roce 2018 podle NDWI je 5,846 km².

6.4. Vyhodnocení změn v zájmovém území

Jak je patrné z tabulek 17, 24 a 31, ve všech obdobích let 2013, 2016 a 2018 je nejpřesnější metodou SVM (LIN) a při vyhodnocení změn budou brány plochy jednotlivých tříd právě z hodnot metody SVM (LIN). V tabulce 38 je porovnání ploch jednotlivých tříd za roky 2013, 2016 a 2018:

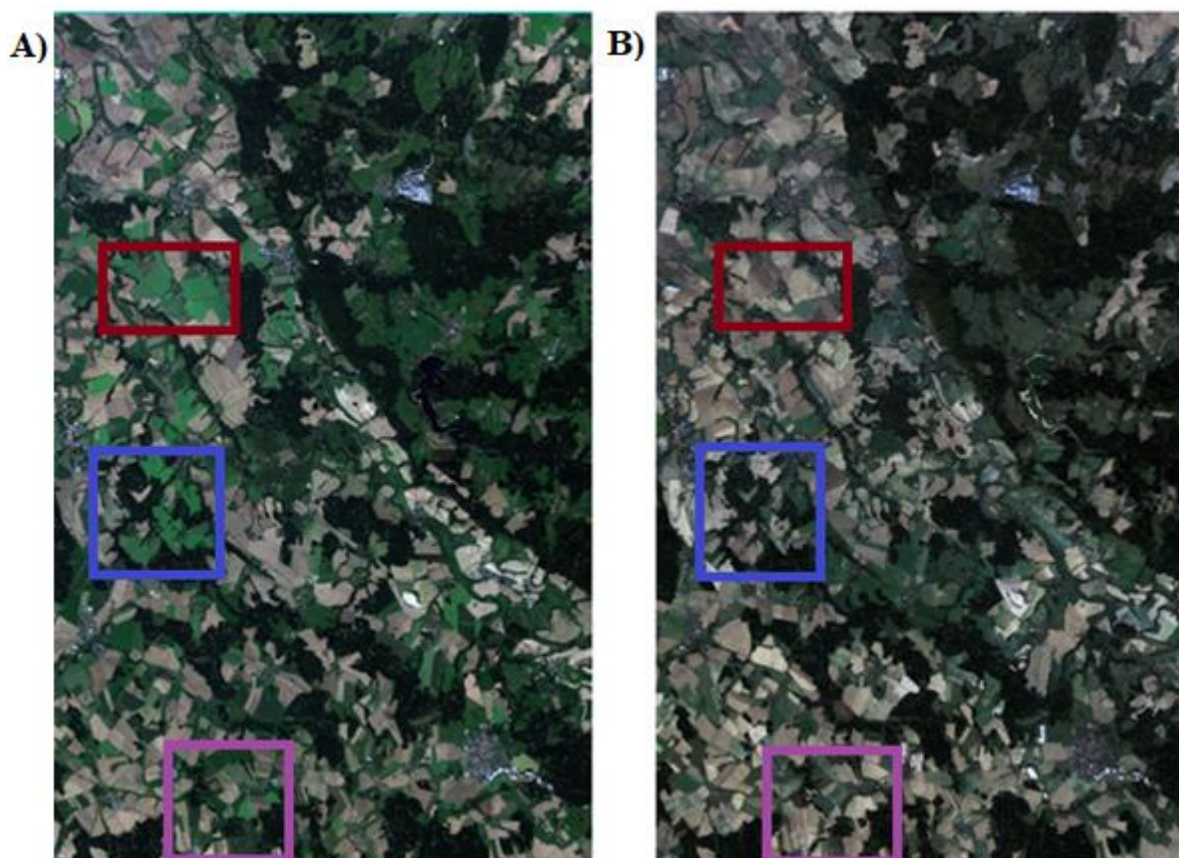
Tabulka 38: Přehled porovnání ploch jednotlivých tříd v zájmovém území za roky 2013, 2016 a 2018

	Plocha 2013 [km ²]	Plocha 2016 [km ²]	Plocha 2018 [km ²]	2013-2016	2016-2018	2013-2018
Městské plochy	81,296	79,769	91,398	-1,91 %	12,72 %	11,05 %
Lesy	376,410	367,022	384,573	-2,56 %	4,56 %	2,12 %
Zeleň	367,601	364,508	277,070	-0,85 %	-31,56 %	-32,67 %
Vodní plochy	6,064	6,107	4,339	0,69 %	-40,74 %	-39,76 %
Pole	245,912	259,877	319,902	5,37 %	18,76 %	23,13 %

Zdroj: vlastní

Z tabulky 38 je patrné, že nejdůležitější procentní změna nastala u vodních ploch, která dosáhla mezi roky 2013 až 2018 téměř -40 %. Tento jev se dá vysvětlit teplým počasím a suchem, které se nakumulovalo v posledních letech. Potvrzení této hypotézy znázorňuje Příloha A, která ukazuje stav sucha v týdnu při 6. září 2013 a Příloha B, která ukazuje stav sucha v týdnu při 13. listopadu 2018.

Dále je z tabulky 38 patrné, že významná změna nastala také u třídy pole a zeleně. Třída pole pokrývala v roce 2018 o 23,13 % více zájmového území než v roce 2013, zatímco třída zeleně pokrývala o zhruba 32 % méně zájmového území v roce 2018 než v roce 2013. Na základě vizuální analýzy se dá předpokládat závislost mezi klesajícím podílem třídy zeleně a stoupajícím podílem třídy pole. Je třeba brát v potaz, že snímek z roku 2013 je pořízen 6. září a snímek z roku 2018 je pořízen 13. listopadu, tzn. půda je již v tomto pozdním podzimním období částečně připravena na přezimování a převážná část zelených plodin byla již sklizena. Dále se na zvýšeném podílu třídy pole v zájmovém území mohlo odrazit velmi teplé počasí a sucho, které bylo objasněno v Příloze A a Příloze B, a které mohlo některé travnaté plochy spálit do žluta. Na obrázku 31 je vidět výřez ze satelitních snímků z roku 2013 a 2018, kde je nejvíce viditelná změna třídy zeleně a třídy pole:



Obrázek 31: Porovnání satelitních snímků v roce 2013 a 2018

Zdroj: vlastní zpracování dle dat [12]

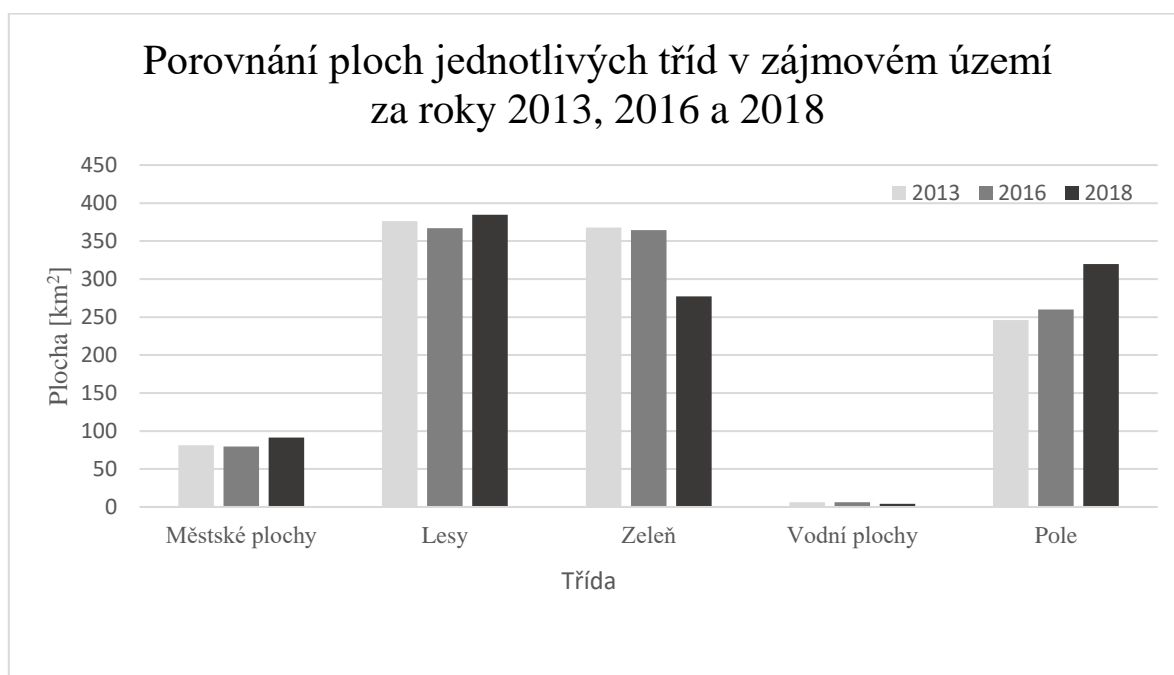
V části A obrázku 31 lze vidět výřez snímku ze 6. září 2013 a v části B obrázku 31 lze vidět výřez snímku z 13. listopadu 2018.

Dále je z tabulky 38 patrné, že mírná změna nastala u třídy městské plochy, a to zvýšení podílu o 11 % v zájmové oblasti mezi roky 2013 až 2018. Tato změna při detailním zkoumání mapovým výstupů ukázala spíše než rozšíření městských ploch o 11 %, že došlo ke kolísání v klasifikaci. Některé oblasti, kde se nacházely městské plochy byly klasifikovány hustěji v roce 2018 než v roce 2013 a naopak. Ve výsledku ale došlo k nárůstu podílu městských ploch v klasifikaci. K tomuto nárůstu ještě přispělo pár špatně klasifikovaných oblastí, které měly být ve skutečnosti ve třídě pole.

Dále je z tabulky 38 patrné, že drobná změna nastala u lesních ploch, které zvýšily svůj podíl v zájmové oblasti o zhruba 2 %. Největší viditelná změna u lesních ploch nastala na pár drobných územích, kde spolu sousedí zeleň a lesní plochy, tato území se klasifikovala převážně na lesní plochy díky drobné změně ve spektrální vyjádření pokryvu země.

Na grafu 1 je vidět ještě grafické znázornění ploch jednotlivých tříd v zájmovém území za roky 2013, 2016 a 2018:

Graf 1: Přehled porovnání ploch jednotlivých tříd v zájmovém území za roky 2013, 2016 a 2018



Zdroj: vlastní


Tabulka 39 se zabývá podrobněji změnou vodních ploch v průběhu let 2013, 2016 až 2018 klasifikované pomocí spektrálních indexů NDVI a NDWI a pomocí řízené klasifikace SVM (LIN).

Tabulka 39: Porovnání změn vodních ploch v průběhu let 2013, 2016 a 2018

	Plocha 2013 [km ²]	Plocha 2016 [km ²]	Plocha 2018 [km ²]	2013-2016	2016-2018	2013-2018
NDVI	4,811	1,543	4,365	-67,93 %	182,89 %	-9,27 %
NDWI	6,857	4,806	5,846	-29,91 %	21,64 %	-14,74 %
SVM (LIN)	6,064	6,107	4,339	0,7 %	-40,75 %	-39,76 %

Zdroj: vlastní

Jak ukázala Příloha A a Příloha B, trendem mezi roky 2013 až 2018 bylo kumulované sucho, a tak se dá předpokládat klesající podíl vodních ploch v zájmovém území. V tabulce 39 je spektrální index NDVI v roce 2016 klasifikován špatně a nebude k němu dále přihlíženo. Trendem u NDVI, NDWI a SVM (LIN) mezi roky 2013 až 2018 je pokles podílu vodních ploch v zájmovém území. Ovšem u NDWI došlo k nárůstu tohoto podílu mezi roky 2016 a 2018 o 21,64 % což je způsobeno převážně oblastí Prachovického lomu, kde významná část této oblasti je klasifikovaná jako vodní plochy, i když se o vodní plochy nejedná. Na obrázku 32 je uvedena oblast Prachovického lomu a výsledku NDWI:



Obrázek 32: Prachovický lom a výstup spektrálního indexu NDWI za sledované období v roce 2018

Zdroj: vlastní zpracování dle dat [12] a [31]

Na obrázku 32 v levé části je nejnovější dostupný snímek Prachovického lomu z ČÚZK (30. září. 2017) a v pravé části obrázku 32 výsledek spektrálního indexu NDWI dne 13. listopadu 2018. Nelze s určitostí říci, že stejná situace v této oblasti byla i o rok později, než byl pořízen letecký snímek, ale pravděpodobně došlo ke špatné klasifikaci NDWI. Ač se při detailním zkoumání leteckého snímku nalézají v oblasti drobné vodní plochy, tak ne v takovém rozsahu, jak jsou vyobrazeny v klasifikovaném snímku v pravé části obrázku 32.

ZÁVĚR

Cílem práce bylo identifikovat změny ve vybraném území Železných hor. K identifikaci změn došlo pomocí metod řízené klasifikace a spektrálních indexů v programu ENVI.

V úvodní části byly zmíněny základní pojmy, které souvisí s dálkovým průzkumem Země a identifikací změn v krajině. Nejdříve byla vysvětlena samotná podstata dálkového průzkumu Země a dále byly uvedeny základní oběžné dráhy. Dále již byla vysvětlena podstata řízené a neřízené klasifikace, která je stěžejní pro identifikaci změn v krajině v čase.

Ve druhé části bylo zpracováno celkem 15 odborných článků z databáze WoS, které souvisejí s problematikou identifikace změn v krajině v čase. Rešerše byla zaměřena zejména na zjištění, jakým nosičem byly pořízeny satelitní snímky, jaké byly použité metody klasifikace, jaké byly použity korekce, na kolik tříd byly klasifikovány snímky, a nakonec, jaké byly přesnosti klasifikace. Z následně sestavených přehledových tabulek bylo vybráno 5 klasifikačních metod, 5 tříd, do kterých se bude klasifikovat zájmová oblast Železných hor, a nosič, který satelitní snímky poskytl.

V třetí kapitole byly uvedeny metody, které budou sloužit k identifikaci změn v krajině v čase a programovém prostředí ENVI 5.5, ve kterém došlo k aplikování metod. Podrobně je popsán aparát pěti použitých metod řízené klasifikace (SVM LIN, SVM RBF, MLC, MINDP a MAHADP), pěti použitých spektrálních indexů (NDBI, EBBI, UI, NDWI a NDVI) a následně ověření přesnosti klasifikace pomocí celkové přesnosti klasifikace a kappa koeficientu.

Ve čtvrté kapitole byl popsán postup při stažení satelitních snímků a analyzována zájmová oblast. U snímků Landsat 8 bylo popsáno použití jednotlivých pásem a prostorové rozlišení.

V páté a šesté kapitole byla provedena samotná klasifikace zájmové oblasti, aby mohla být provedena identifikace změn. Nejprve byly aplikovány všechny spektrální indexy na snímku z roku 2013, a ty, které dokázaly dobře klasifikovat hledanou třídu, byla použity pro snímky v dalších letech. V této části se ukázaly jako relevantní pouze dva spektrální indexy zaměřené na vodní plochy (NDVI a NDWI). NDVI je běžně používán pro identifikaci vegetace, ale zde byl použit pro zvýraznění vodních ploch. V další fázi bylo provedeno všech 5 metod řízené klasifikace pro všechna analyzovaná období, z toho byl vytvořen mapový výstup pro tři nejlepší metody v každém analyzovaném období. Nakonec šesté kapitoly byly shrnuty výsledky v tabulkách a grafu pro nepřesnější metodu řízené klasifikace SVM (LIN) a spektrální indexy NDVI a NDWI a byly znázorněny změny jednotlivých tříd povrchu země v průběhu let. Tyto změny byly vysvětleny a jejich možné příčiny byly popsány a zdůvodněny.

POUŽITÁ LITERATURA

- [1] ALBON, Chris. SVC Parameters When Using RBF Kernel. Technical Notes On Using Data Science & Artificial Intelligence To Fight For Something That Matters [online]. [cit. 2019-02-28]. Dostupné z: https://chrisalbon.com/machine_learning/support_vector_machines/svc_parameters_using_rbf_kernel/
- [2] BARSI, Julia, Kenton LEE, Geir KVARAN, Brian MARKHAM a Jeffrey PEDELTY. The Spectral Response of the Landsat-8 Operational Land Imager. Remote Sensing [online]. 2014, 6(10), 10232-10251 [cit. 2019-02-28]. DOI: 10.3390/rs61010232. ISSN 2072-4292. Dostupné z: <http://www.mdpi.com/2072-4292/6/10/10232>
- [3] BEKTAS BALCIK, F. a C. GOKSEL. DETERMINATION OF MAGNITUDE AND DIRECTION OF LAND USE/ LAND COVER CHANGES IN TERKOS WATER BASIN, ISTANBUL. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences [online]. 2012, XXXIX-B7, 275-279 [cit. 2019-02-27]. DOI: 10.5194/isprsarchives-XXXIX-B7-275-2012. ISSN 1682-1777. Dostupné z: <http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XXXIX-B7/275/2012/>
- [4] Calculate Confusion Matrices. Harris Geospatial Solutions: Geospatial Data and Analytics [online]. [cit. 2019-02-28]. Dostupné z: <https://www.harrisgeospatial.com/docs/CalculatingConfusionMatrices.html>
- [5] CAMPBELL, James B. a Randolph H. WYNNE. Introduction to remote sensing. 5th ed. New York: Guilford Press, c2011. ISBN 978-1609181765.
- [6] Catalog of Earth Satellite Orbits. NASA Earth Observatory [online]. [cit. 2019-02-27]. Dostupné z: <https://earthobservatory.nasa.gov/features/OrbitsCatalog>
- [7] DENG, Jin S., Ke WANG, Yang HONG a Jia G. QI. Spatio-temporal dynamics and evolution of land use change and landscape pattern in response to rapid urbanization: Lecture Notes from the 2nd ERCOFTAC Summerschool held in Stockholm, 10-16 June, 1998. Landscape and Urban Planning [online]. 2009, 1999, 92(3-4), 187-198 [cit. 2019-02-27]. DOI: 10.1016/j.landurbplan.2009.05.001. ISSN 01692046. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0169204609000814>
- [8] DEWAN, Ashraf M. a Yasushi YAMAGUCHI. Using remote sensing and GIS to detect and monitor land use and land cover change in Dhaka Metropolitan of Bangladesh during

- 1960–2005. Environmental Monitoring and Assessment [online]. 2009, 150(1-4), 237-249 [cit. 2019-02-27]. DOI: 10.1007/s10661-008-0226-5. ISSN 0167-6369. Dostupné z: <http://link.springer.com/10.1007/s10661-008-0226-5>
- [9] DIXON, Barnali a Venkatesh UDDAMERI. GIS and geocomputation for water resource science and engineering. Chichester, West Sussex, UK: AGU, Wiley, 2016. ISBN 978-1-118-35413-1.
- [10] DOBROVOLNÝ, Petr. Dálkový průzkum Země: digitální zpracování obrazu. Brno: Masarykova univerzita, 1998. ISBN 80-210-1812-7.
- [11] Does Landsat Level-1 data processing include atmospheric correction?. USGS [online]. [cit. 2019-02-28]. Dostupné z: <https://landsat.usgs.gov/does-landsat-level-1-data-processing-include-atmospheric-correction>
- [12] EarthExplorer - Home. EarthExplorer - USGS [online]. [cit. 2019-02-28]. Dostupné z: <https://earthexplorer.usgs.gov/>
- [13] Elektromagnetické spektrum. Pion [online]. [cit. 2019-02-27]. Dostupné z: <http://www.pion.cz/cs/clanek/elektromagneticke-spektrum>
- [14] Charakteristika oblasti. Agentura ochrany přírody a krajiny ČR [online]. [cit. 2019-02-28]. Dostupné z: <http://zeleznehory.ochranaprirody.cz/charakteristika-oblasti/>
- [15] CHELLASAMY, M., T. P. A. FERRÉ, M. HUMLEKROG GREVE, R. LARSEN a U. CHINNASAMY. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences [online]. 2014, XL-8, 695-701 [cit. 2019-02-27]. DOI: 10.5194/isprsarchives-XL-8-695-2014. ISSN 2194-9034. Dostupné z: <http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XL-8/695/2014/>
- [16] CHEN, C. F., N. T. SON, C. R. CHEN, L. Y. CHANG a S. H. CHIANG. RICE CROP MAPPING USING SENTINEL-1A PHENOLOGICAL METRICS. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences [online]. 2016, XLI-B8, 863-865 [cit. 2019-02-27]. DOI: 10.5194/isprsarchives-XLI-B8-863-2016. ISSN 2194-9034. Dostupné z: <http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLI-B8/863/2016/isprs-archives-XLI-B8-863-2016.pdf>
- [17] Intersucho. Intenzita sucha [online]. [cit. 2019-03-26]. Dostupné z: <https://www.intersucho.cz/>

- [18] IOP Conference Series: Earth and Environmental Science [online]. 2016, 37 [cit. 2019-02-28]. ISSN 1755-1307. Dostupné z: <http://stacks.iop.org/1755-1315/37/i=1/a=012063?key=crossref.d4aad672b5c2ecba36c928603cac3e4e>
- [19] ISLAM, Kamrul, Mohammed JASHIMUDDIN, Biswajit NATH a Tapan Kumar NATH. Land use classification and change detection by using multi-temporal remotely sensed imagery: The case of Chunati wildlife sanctuary, Bangladesh. The Egyptian Journal of Remote Sensing and Space Science [online]. 2018, 21(1), 37-47 [cit. 2019-02-28]. DOI: 10.1016/j.ejrs.2016.12.005. ISSN 11109823. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1110982316301594>
- [20] KONEČNÝ, Milan, ed. GIS frontiers in business and science and ICA MAP USE commission session. Brno: Masarykova univerzita, 1996. ISBN 80-210-1330-3.
- [21] KUSRATMOKO, E, S T DAYANTI a SUPRIATNA. The critical land in Komerling watershed as a result of land use changes from 2000-2016 period. IOP Conference Series: Earth and Environmental Science [online]. 2017, 54 [cit. 2019-02-28]. DOI: 10.1088/1755-1315/54/1/012020. ISSN 1755-1307. Dostupné z: <http://stacks.iop.org/1755-1315/54/i=1/a=012020?key=crossref.a6d3c81696c8e11c278c7bce81f01505>
- [22] Landsat 8 Operational Land Imager (OLI) and Thermal Infrared Sensor (TIRS). EarthExplorer - USGS [online]. [cit. 2019-02-28]. Dostupné z: <https://landsat.usgs.gov/what-are-best-spectral-bands-use-my-study>
- [23] LandsatLook images. EarthExplorer - USGS [online]. [cit. 2019-03-09]. Dostupné z: <https://landsat.usgs.gov/landsatlook-images>
- [24] LILLESAND, Thomas M. a Ralph W. KIEFER. Remote sensing and image interpretation. 3rd ed. New York: John Wiley, 1994. ISBN 04-715-7783-9.
- [25] Mahalanobis Distance. Harris Geospatial Solutions: Geospatial Data and Analytics [online]. [cit. 2019-02-28]. Dostupné z: <https://www.harrisgeospatial.com/docs/Mahalanobis.html>
- [26] Mani Murali R, Vethamony P, Saran A. K, et al. Change detection studies in coastal zone features of Goa, India by remote sensing. Current Science, 2006
- [27] Maximum Likelihood. Harris Geospatial Solutions: Geospatial Data and Analytics [online]. [cit. 2019-02-28]. Dostupné z: <https://www.harrisgeospatial.com/docs/MaximumLikelihood.html>

- [28] MIHAI, Bogdan, Constantin NISTOR a Gabriel SIMION. Post-socialist urban growth of Bucharest, Romania – a change detection analysis on Landsat imagery (1984–2010). *Acta geographica Slovenica* [online]. 2015, 55(2) [cit. 2019-02-28]. DOI: 10.3986/AGS.709. ISSN 1581-8314. Dostupné z: <http://ojs.zrc-sazu.si/ags/article/view/709>
- [29] Minimum Distance. Harris Geospatial Solutions: Geospatial Data and Analytics [online]. [cit. 2019-02-28]. Dostupné z: <https://www.harrisgeospatial.com/docs/MinimumDistance.html>
- [30] MONDAL, Md., Nayan SHARMA, Martin KAPPAS a P. GARG. Critical Assessment of Land Use Land Cover Dynamics Using Multi-Temporal Satellite Images. *Environments* [online]. 2015, 2(4), 61-90 [cit. 2019-02-28]. DOI: 10.3390/environments2010061. ISSN 2076-3298. Dostupné z: <http://www.mdpi.com/2076-3298/2/1/61>
- [31] Ortofoto ČR. Geoportál ČÚZK [online]. [cit. 2019-03-24]. Dostupné z: <https://geoportal.cuzk.cz/geoprohlizec/?wmcid=2012>
- [32] PATAKAMURIA, S. K., S. AGRAWAL a M. KRISHNAVENI. Time-Series analysis of MODIS NDVI data along with ancillary data for Land use/Land cover mapping of Uttarakhand. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* [online]. 2014, XL-8, 1491-1500 [cit. 2019-02-28]. DOI: 10.5194/isprsarchives-XL-8-1491-2014. ISSN 2194-9034. Dostupné z: <http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XL-8/1491/2014/>
- [33] PETERS, Joe. The Many Band Combinations of Landsat 8. *EarthExplorer - USGS* [online]. 2015 [cit. 2019-03-09]. Dostupné z: <https://www.harrisgeospatial.com/Learn/Blogs/Blog-Details/ArtMID/10198/ArticleID/15691/The-Many-Band-Combinations-of-Landsat-8>
- [34] RWANGA, Sophia S. a J. M. NDAMBUKI. Accuracy Assessment of Land Use/Land Cover Classification Using Remote Sensing and GIS. *International Journal of Geosciences* [online]. 2017, 08(04), 611-622 [cit. 2019-02-28]. DOI: 10.4236/ijg.2017.84033. ISSN 2156-8359. Dostupné z: <http://www.scirp.org/journal/doi.aspx?DOI=10.4236/ijg.2017.84033>
- [35] SEKERTEKIN, Aliihsan a Aycan Murat MARANGOZ. An Erdas Imagine Model To Extract Urban Indices Using Landsat 8 Satellite Imagery [online]. 2017, 2017(6) [cit. 2019-03-22]. ISSN 2277-8616.

- [36] Support Vector Machine Background. Harris Geospatial Solutions: Geospatial Data and Analytics [online]. [cit. 2019-02-28]. Dostupné z: <https://www.harrisgeospatial.com/docs/backgroundsvmgeneral.html>
- [37] The difference between “land use” and “land cover”. Michigan State University [online]. [cit. 2019-02-27]. Dostupné z: https://www.canr.msu.edu/news/the_difference_between_land_use_and_land_cover
- [38] Understanding Segmentation and Classification. ArcGis Desktop [online]. [cit. 2019-03-26]. Dostupné z: <http://desktop.arcgis.com/en/arcmap/10.3/tools/spatial-analyst-toolbox/understanding-segmentation-and-classification.htm>
- [39] VARAMESH, S. DETECTION OF LAND USE CHANGES IN NORTHEASTERN IRAN BY LANDSAT SATELLITE DATA. Applied Ecology and Environmental Research [online]. 2017, 15(3), 1443-1454 [cit. 2019-02-28]. DOI: 10.15666/aeer/1503_14431454. ISSN 15891623. Dostupné z: http://aloki.hu/pdf/1503_14431454.pdf
- [40] WANG, Jason T. L. Data mining in bioinformatics. London: Springer, c2005. ISBN 18-523-3671-4.
- [41] WEGMANN, Martin, Benjamin LEUTNER a Stefan DECH. Remote Sensing and GIS for Ecologists: Using Open Source Software [online]. Pelagic Publishing, ©2016 [cit. 2019-03-26]. ISBN 978-1-78427-022-3.
- [42] Why does NDVI, NDBI, NDWI Ranges From -1 to 1?. GIS Resources [online]. 6.března 2018 [cit. 2019-03-22]. Dostupné z: <http://www.gisresources.com/ndvi-ndbi-ndwi-ranges-1-1/>
- [43] XIAN, George, Collin HOMER a Joyce FRY. Updating the 2001 National Land Cover Database land cover classification to 2006 by using Landsat imagery change detection methods. Remote Sensing of Environment [online]. 2009, 113(6), 1133-1147 [cit. 2019-02-27]. DOI: 10.1016/j.rse.2009.02.004. ISSN 00344257. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0034425709000340>
- [44] YUAN, Fei, Kali E. SAWAYA, Brian C. LOEFFELHOLZ a Marvin E. BAUER. Land cover classification and change analysis of the Twin Cities (Minnesota) Metropolitan Area by multitemporal Landsat remote sensing. Remote Sensing of Environment [online]. 2005, 98(2-3), 317-328 [cit. 2019-02-27]. DOI: 10.1016/j.rse.2005.08.006. ISSN 00344257. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0034425705002646>

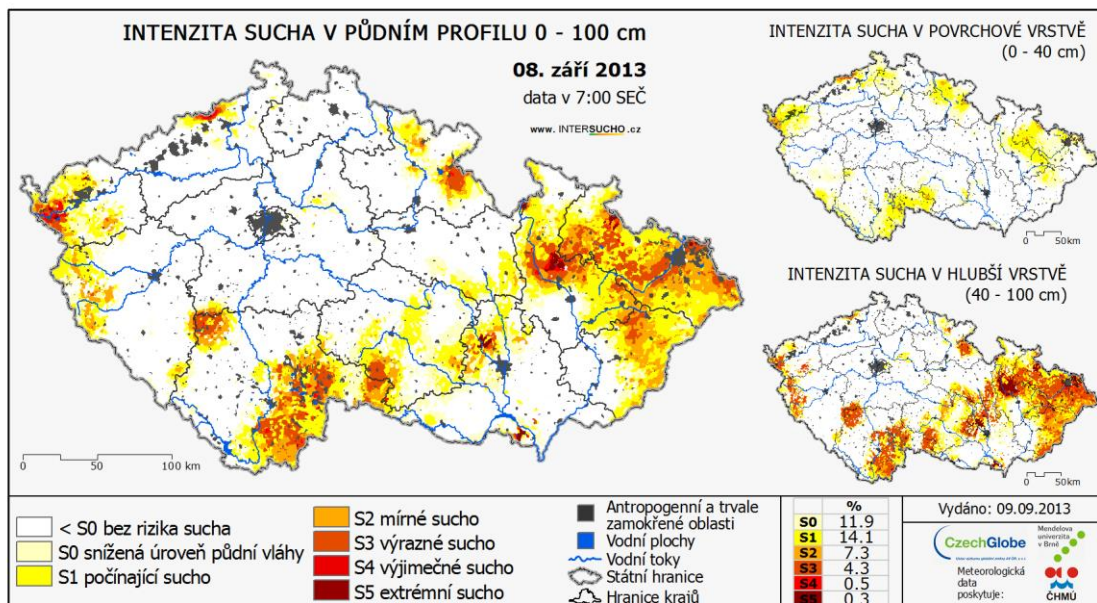
SEZNAM PŘÍLOH

Příloha A – Intenzita sucha v týdnu při 8. září 2013

Příloha B – Intenzita sucha v týdnu při 18. listopadu 2018

Příloha C – Zdrojová data (DVD)

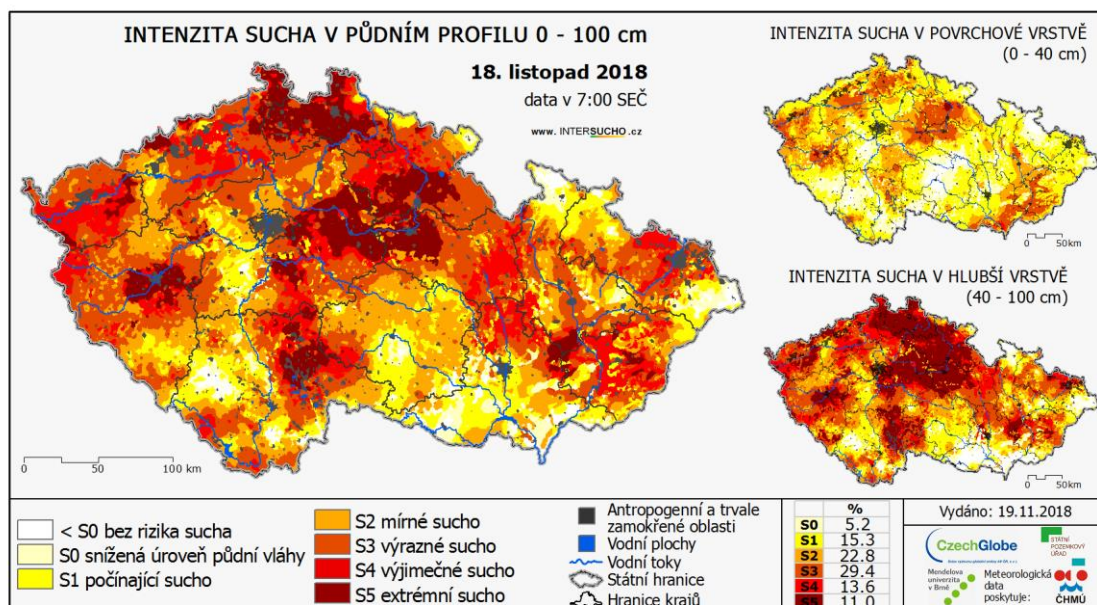
Příloha A – Intenzita sucha v týdnu při 8. září 2013



Obrázek 33: Intenzita sucha v týdnu při 8. září 2013

Zdroj: [17]

Příloha B – Intenzita sucha v týdnu při 18. listopadu 2018



Obrázek 34: Intenzita sucha v týdnu při 18. listopadu 2018

Zdroj: [17]