

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

Identifikace změn v krajině s využitím družicových dat

Bc. Martin Pátek

**Diplomová práce
2022**

Univerzita Pardubice
Fakulta ekonomicko-správní
Akademický rok: 2021/2022

ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Bc. Martin Pátek**
Osobní číslo: **E19965**
Studijní program: **N0688A140007 Informatika a systémové inženýrství**
Specializace: **Informatika ve veřejné správě**
Téma práce: **Identifikace změn v krajině s využitím družicových dat**
Zadávající katedra: **Ústav systémového inženýrství a informatiky**

Zásady pro vypracování

Cílem práce je navrhnout vhodný postup a na jeho základě identifikovat změny v krajině v zadaném zájmovém území a časovém horizontu. Postup bude založen na zpracování multispektrálních družicových dat různými metodami. Součástí práce bude i interpretace a vizualizace výsledků.

Osnova:

- Principy a metody dálkového průzkumu Země
- Charakteristika zájmového území a sběr dat
- Identifikace změn zájmového území
- Vizualizace a interpretace výsledků

Rozsah pracovní zprávy: **cca 55 str.**
Rozsah grafických prací:
Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam doporučené literatury:

HALOUNOVÁ, Lena a Karel PAVELKA. Dálkový průzkum Země. V Praze: Česká technika – nakladatelství ČVUT, 2005. ISBN 80-01-03124-1.
LILLESAND, Thomas M., Ralph W. KIEFER a Jonathan W. CHIPMAN. Remote sensing and image interpretation. 6th ed. Hoboken: Wiley, c2008. ISBN 978-0-470-05245-7.
TSO, Brandt a Paul M. MATHER. Classification Methods for Remotely Sensed Data. 2. Boca Raton: CRC Press, 2009. ISBN 978-1-4200-9072-7.
WENG, Qihao. Remote sensing and GIS integration: theories, methods, and applications. New York: McGraw-Hill, c2010. ISBN 978-0-07-160653-0.

Vedoucí diplomové práce: **doc. Ing. Jitka Komárková, Ph.D.**
Ústav systémového inženýrství a informatiky

Datum zadání diplomové práce: **1. září 2021**
Termín odevzdání diplomové práce: **30. dubna 2022**

prof. Ing. Jan Stejskal, Ph.D. v.r.
děkan

L.S.

RNDr. Ing. Oldřich Horák, Ph.D. v.r.
vedoucí ústavu

V Pardubicích dne 1. září 2021

PROHLÁŠENÍ AUTORA

Prohlašuji:

Práci s názvem *Identifikace změn v krajině s využitím družicových dat* jsem vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

Byl jsem seznámen s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, 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. 7/2019 Pravidla pro odevzdávání, zveřejňování a formální úpravu závěrečných prací, ve znění pozdějších dodatků, bude práce zveřejněna prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 30. 4. 2022

Martin Pátek v.r.

PODĚKOVÁNÍ:

Tímto bych rád poděkoval především své vedoucí práce prof. doc. Ing. Jitce Komárkové, Ph. D. za její cenné rady a poskytnutou odbornou pomoc, která mi pomohla při zpracování této diplomové práce. Dále bych také rád poděkovali svojí rodině a kamarádům, kteří mě podporovali po celou dobu mého studia.

ANOTACE

Tato diplomová práce se zabývá identifikací změn v krajině na základě družicových dat. V první části práce je popsána základní problematika dálkového průzkumu Země, krajiny včetně detekce změn. Dále pak možnosti digitálního zpracování dat dálkového průzkumu Země, jednotlivé techniky klasifikace a jejich následné hodnocení. Posledním bodem první části je shrnutí vybraných studií, věnujících se tomuto tématu. Ve druhé části práce je proveden sběr dat a identifikace změn v rámci zájmového území včetně hodnocení přesnosti použité klasifikace.

KLÍČOVÁ SLOVA

Dálkový průzkum Země, klasifikace, spektrální indexy, Sentinel, Landsat, NDVI, NDWI

TITLE

Identification of landscape changes based on satellite data

ANNOTATION

This thesis deals with the identification of Land Cover changes based on satellite data. The first part of the thesis describes the basic issues of remote sensing and landscape change detection. Furthermore, the possibilities of digital processing of remote sensed data, classification techniques and their evaluation. The last topic of the first part is a summary of some studies dealing with this topic. The second part of the thesis is based on data collection and identification of changes within the area of interest including evaluation of the accuracy of the classification method used.

KEYWORDS

Remote sensing, classification, spectral indices, Sentinel, Landsat, NDVI, NDWI

OBSAH

ÚVOD.....	11
1 DÁLKOVÝ PRŮZKUM ZEMĚ	12
1.1 PRINCIP DPZ.....	12
1.2 METODY DPZ.....	13
1.3 DATA DPZ.....	14
1.4 DRUŽICOVÉ SYSTÉMY.....	16
2 IDENTIFIKACE ZMĚN V KRAJINĚ.....	18
2.1 KRAJINA	18
2.1.1 Struktura krajiny.....	18
2.1.2 Spektrální projevy a vlastnosti krajiny	19
2.1.3 Detekce změn krajiny	20
2.2 DIGITÁLNÍ ZPRACOVÁNÍ DAT DPZ.....	20
2.2.1 Rektifikace a restaurace.....	21
2.2.2 Zvýraznění obrazu.....	23
2.2.3 Klasifikace.....	26
2.2.4 Postklasifikační úpravy a hodnocení přesnosti.....	32
2.3 SHRNUTÍ STÁVAJÍCÍHO STAVU	33
3 CHARAKTERISTIKA ZÁJMOVÉHO ÚZEMÍ, POUŽITÉ METODY, DATA A SOFTWARE.....	38
3.1 CHARAKTERISTIKA ZÁJMOVÉHO ÚZEMÍ.....	38
3.2 POUŽITÁ DATA.....	39
3.3 POUŽITÉ METODY A SOFTWARE	41
4 IDENTIFIKACE ZMĚN ZÁJMOVÉHO ÚZEMÍ.....	43
4.1 PŘÍPRAVA DAT	43
4.2 KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ.....	47
4.2.1 Vegetační indexy.....	47
4.2.2 Řízená klasifikace.....	49
4.2.3 Neřízená klasifikace	52
4.3 HODNOCENÍ PŘESNOSTI KLASIFIKACE.....	54
5 VIZUALIZACE A INTERPRETACE VÝSLEDKŮ	58
5.1 NDVI.....	58
5.2 NDWI.....	60
5.3 ŘÍZENÁ KLASIFIKACE.....	62
5.4 NEŘÍZENÁ KLASIFIKACE	65
5.5 HODNOCENÍ PŘESNOSTI KLASIFIKACE.....	68
ZÁVĚR.....	70
POUŽITÁ LITERATURA	71
SEZNAM PŘÍLOH.....	76

SEZNAM OBRÁZKŮ A TABULEK A GRAFŮ

Obrázek 1: Elektromagnetické spektrum	13
Obrázek 2: Aktivní a pasivní snímání	14
Obrázek 3: Prostorové rozlišení	15
Obrázek 4: Oběžné dráhy	17
Obrázek 5: Spektrální křivky vegetace, půdy a vody	19
Obrázek 6: Třídy klasifikace studie 6.....	36
Obrázek 7: Zájmová oblast.....	39
Obrázek 8: Úvodní obrazovka webu Earth Explorer.....	40
Obrázek 9: Tvorba polygonu pro ořez dat.....	43
Obrázek 10: Tvorba bodů polygonu.....	44
Obrázek 11: Výsledný polygon	44
Obrázek 12: Nástroj Extract by Mask (Batch)	45
Obrázek 13: Oříznutá data Landsat – červenec	45
Obrázek 14: Ukázka nastavení nástroje Composite Bands	46
Obrázek 15: Nastavení Image Analysis	47
Obrázek 16: Index NDVI na snímku z družice Sentinel	48
Obrázek 17: Výpočet indexu NDWI pomocí nástroje Raster Calculator.....	49
Obrázek 18: Index NDWI nad daty družice Landsat	49
Obrázek 19: Výběr trénovacích dat	50
Obrázek 20: Nastavení klasifikátoru Maximum Likelihood	51
Obrázek 21: Výsledek řízené klasifikace v červenci nad daty Sentinelu	51
Obrázek 22: Nastavení klasifikátoru ISO Cluster	52
Obrázek 23: Nastavení nástroje Reclassify	53
Obrázek 24: Výsledek reklasifikace – srpen	54
Obrázek 25: Nastavení nástroje Create Accuracy Assesment Points.....	55
Obrázek 26: Nastavení nástroje Compute Confusion Matrix.....	56
Obrázek 27: Výsledek výpočtu matice chyb a kappa koeficientu.....	56
Obrázek 28: Vegetační index NDVI na snímcích družice Sentinel-2	58
Obrázek 29: Vegetační index NDVI na snímku Landsat	59
Obrázek 30: Vegetační index NDWI na snímcích družice Sentinel-2	60
Obrázek 31: Vegetační index NDWI na snímku družice Landsat.....	61
Obrázek 32: Výsledek klasifikace MLC – květen.....	62
Obrázek 33: Výsledek klasifikace MLC – červenec	63
Obrázek 34: Výsledek klasifikace MLC – červen (Landsat)	64
Obrázek 35: Výsledek klasifikace ISO – květen	65
Obrázek 36: Výsledek klasifikace ISO – červenec	66
Obrázek 37: Výsledek klasifikace ISO – červen (Landsat).....	68
Obrázek 38: Výsledek klasifikace MLC – červen.....	I
Obrázek 39: Výsledek klasifikace MLC – srpen.....	I
Obrázek 40: Výsledek klasifikace ISO – červen	II
Obrázek 41: Výsledek klasifikace ISO – srpen	II
Tabulka 1: Vegetační indexy	25
Tabulka 2: Porovnání klasifikátorů řízené klasifikace	29
Tabulka 3: Hodnocení přesnosti studie 1	33
Tabulka 4: Hodnocení přesnosti studie 2	34
Tabulka 5: Hodnocení přesnosti studie 3	34
Tabulka 6: Hodnocení přesnosti studie 4	35
Tabulka 7: Hodnocení přesnosti studie 5	35
Tabulka 8: Hodnocení přesnosti studie 6	36

Tabulka 9: Výsledky studie 8	37
Tabulka 10: Spektrální pásma družice Landsat-8	39
Tabulka 11: Procentuální pokrytí snímku mraky	41
Tabulka 12: Rozloha tříd MLC – Sentinel-2 v květnu	63
Tabulka 13: Porovnání ploch tříd MLC mezi družicemi.....	65
Tabulka 14: Výsledky hodnocení přesnosti klasifikace – Sentinel	68
Tabulka 15: Matice chyb klasifikace ISO – květen.....	69
Tabulka 16: Matice chyb MLC – květen.....	III
Tabulka 17: Matice chyb MLC – červen.....	III
Tabulka 18: Matice chyb MLC – červenec	III
Tabulka 19: Matice chyb MLC – srpen.....	IV
Tabulka 20: Matice chyb ISO – červen	V
Tabulka 21: Matice chyb ISO – červenec	V
Tabulka 22: Matice chyb ISO – srpen	V
Tabulka 23: Matice chyb MLC – Landsat.....	VI
Tabulka 24: Matice chyb ISO – Landsat	VI
Graf 1: Rozloha vodních ploch – Sentinel.....	61
Graf 2: Rozloha tříd MLC – Sentinel	64
Graf 3: Rozloha tříd ISO – Sentinel	67

SEZNAM ZKRATEK

ArcGIS	Aeronautical Reconnaissance Coverage Geographic Information System
DN	Digital Number
DPZ	Dálkový průzkum Země
EVI	Enhanced Vegetation Index
GIS	Geographic information system / Geografický informační systém
LiDAR	Light Detection and Ranging
LSWI	Land Surface Water Index
LULC	Land use/Land Cover
NBR	Normalized Burn Ratio
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
NIR	Near Infrared
OLI	Operational Land Imager
RVI	Ratio Vegetation Index
SAVI	Soil-Adjusted Vegetation Index
SVI	Simple Vegetation Index
SVM	Support Vector Machine
SW	Software
TIRS	Thermal Infrared Sensor
TM	Thematic Mapper
USGS	United States Geological Survey
UTM	Universal Transverse Mercator
VIgreen	Vegetation Index Green
WGS 84	World Geodetic System 1984

ÚVOD

Dálkový průzkum Země (DPZ) je v dnešní době nedílnou součástí různých odvětví. Vzhledem ke stále se měnícím typům a rozloze jednotlivých typů zemského pokryvu je důležité sledovat tento vývoj a predikovat vývoj budoucí. DPZ se nejčastěji využívá například v zemědělství, archeologii, ekologii, geologii a meteorologii. V dnešní době jsou také družicové snímky často zmiňovaným tématem, a to z důvodu jejich možného využití pro vojenské účely.

Tato diplomová práce se zabývá identifikací změn na základě družicových dat. V první části je popsán dálkový průzkum Země, jeho princip, jednotlivé metody, využívaná data a družicové systémy. Další část je zaměřena na možnosti identifikace změn v krajině a výsledky zahraničních studií zabývajících se touto problematikou.

V rámci praktické části je navržen postup zpracování družicových snímků, podle kterého jsou následně zpracovány jednotlivé metody, které byly vybrány na základě úspěšnosti a četnosti využití ve světových studiích. Tyto metody jsou následně popsány a vizualizovány pomocí mapových výstupů a dalších prostředků.

Cílem práce je navrhnout vhodný postup a na jeho základě identifikovat změny v krajině v zadaném zájmovém území a časovém horizontu. Postup bude založen na zpracování multispektrálních družicových dat různými metodami. Součástí práce bude i interpretace a vizualizace výsledků.

1 DÁLKOVÝ PRŮZKUM ZEMĚ

Dálkový průzkum je věda a umění získávání informací o objektech, plochách nebo jevech pomocí dat, která byla získána ze zařízení, jenž není v přímém kontaktu s právě pozorovaným objektem, plochou nebo jevem (Lillesand, 2008).

Historie dálkového průzkumu Země začala vynálezem fotografie v roce 1839. První snímky pořízené ze vzduchu se datují do šedesátých let 19. století. Z počátku byly k pořizování fotografií využívány balóny, draci nebo například holubi. První letecké snímky se pak objevily v roce 1908 a byly pořízeny W. Wrightem. S koncem druhé světové války je spojený další milník v oblasti snímání Země. Jednalo se především o vývoj letů do kosmu, využívání mikrovlnných vlnových délek a vynález radaru. První snímek povrchu země byl pořízen z družice Explorer. Následoval další vývoj lepších družic, které měly například meteorologické využití. V dnešní době se stále využívají již zmíněné metody snímání z družic, ale existují i novější možnosti pořizování snímků např. pomocí dronů (Halounová, 2008).

Weng (2010) v závislosti na elektromagnetickém spektru dělí dálkový průzkum na:

1. Satelitní dálkový průzkum – při využití satelitů(družic)
2. Fotografie a fotogrammetrie – pokud se fotografie používají k zachycení viditelného světla
3. Tepelné dálkové snímání – za předpokladu využití tepelné infračervené části spektra
4. Radarové dálkové snímání – při použití mikrovlnných vlnových délek
5. Dálkové snímání LiDar – pokud jsou laserové impulsy vysílány směrem k zemi a vzdálenost mezi senzorem a zemí je měřena na základě doby návratu každého impulsu


1.1 Princip DPZ

DPZ je založen na poznatku, že objekty či jevy, nacházející se na zemském povrchu určitým specifickým způsobem ovlivňují své okolí. Zmíněné ovlivnění je charakteristické jak pro typ objektu, kterým je například les, moře nebo střecha, tak i pro jejich jednotlivé vlastnosti (např. barva nebo teplota). Informace tohoto charakteru objekty vydávají pomocí tzv. silových polí. V oblasti dálkového průzkumu je k získávání informací o objektech na zemském povrchu využíváno elektromagnetické záření (Dobrovolný, 1998).

Elektromagnetické záření interaguje s atmosférou Země, přičemž stupeň interakce závisí na vlnové délce záření a místních charakteristikách atmosféry. Základní interakce jsou známé jako rozptyl a absorpce. K rozptylu dochází spíše v kratších vlnových délkách. Nejběžnější

rozptylové chování je známé jako Rayleighův rozptyl, který je hlavní příčinou zákalu na snímcích z dálkového snímání. Atmosféra má různé úrovně absorpce na různých vlnových délkách. Oblasti spektra, které mají relativně vysokou propustnost, se nazývají atmosférická okna. Energie v některých vlnových pásmech je téměř úplně absorbována atmosférou. Tyto vlnové délky proto nelze použít pro DPZ (Tso, 2009).

Pro označení rozsahu vlnových délek elektromagnetického záření se používá termín elektromagnetické spektrum (viz. Obrázek 1). Přestože je elektromagnetické spektrum vnímáno jako kontinuum vlnových délek a frekvencí, je podle vědecké konvence rozděleno do různých částí. Hlavní rozdělení elektromagnetického spektra zahrnuje gama záření, rentgenové záření, ultrafialové (UV) záření, viditelné světlo, infračervené záření, mikrovlnné záření a radiové vlny (Weng, 2010; Halounová, 2005).




Obrázek 1: Elektromagnetické spektrum

Zdroj: (Lavender, 2015)


1.2 Metody DPZ

Jednotlivé druhy dálkového průzkumu Země je možné rozdělit hned podle několika hledisek. Prvním hlediskem je zdroj elektromagnetického záření. Dle toho můžeme rozlišit aktivní, kdy zdroj záření je v rámci měřicího zařízení a dochází k měření odraženého záření, a pasivní, pokud je zdrojem záření Slunce a Země (viz. Obrázek 2) (Halounová, 2005).

Passive Sensors



Active Sensors



Obrázek 2: Aktivní a pasivní snímání

Zdroj: (Earth Data, 2021)

Druhé hledisko, podle kterého lze rozlišovat, je druh pořízených dat. Toto dělení vychází ze způsobu, kterým byla data zaznamenána. Při tomto hledisku lze metody rozdělit na konvenční a nekonvenční. Konvenční metoda DPZ využívá fotografie, které jsou pořizovány centrální projekcí. Celý snímek vzniká v jednom okamžiku buď z leteckých nebo družicových nosičů. Hlavní nevýhodou konvenčních metod je malý rozsah vlnových délek. Nekonvenčními metodami lze pak označit metody, při kterých snímek nevzniká najednou, ale postupně pomocí tzv. řádkování. Vzniklé záznamy mají digitální formát a tvoří velkou část obrazových dat zpracovávaných v DPZ (Halounová, 2005).

Mezi další hlediska můžeme zařadit (Halounová, 2005):

- Druh nosiče – družice, letadla, balóny apod.
- Velikost snímaného území – globální, oblastní, lokální a detailní
- A další...

1.3 Data DPZ

Bez ohledu na to, zda se jedná o aktivní nebo pasivní snímání, všechna snímací zařízení detekují a zaznamenávají energetické „signály“ z prvků zemského povrchu nebo atmosféry. Mezi příklady těchto zařízení můžeme zařadit např. letecké kamery nebo skenery. Data shromážděná těmito zařízeními mohou být buď v analogovém nebo digitálním formátu. Data v digitálním formátu je možné přímo vložit do GIS a následně je používat. Stejně tak mohou být použita v GIS i data analogová, ale musí být nejdříve využita analogově-digitální konverze nebo je nutné použít skenování (Weng, 2010).


Stejným způsobem jako metody DZP lze i rozdělit pořizovaná data. Pokud rozdělíme data podle počtu záznamů obrazových dat, jedná se o data monochromatická nebo panchromatická.

Monochromatická data jsou pořizována v rámci jednoho pásma, panchromatická se měří v celém vlnovém rozsahu viditelné části elektromagnetického spektra (Dobrovolný, 1998).

Mezi dalšími druhy dat lze najít data multispektrální, pro která je charakteristické, že jsou měřena ve dvou a více spektrálních pásmech. Dále multipolarizační data, která jsou snímána ve více polarizačních rovinách a také v současnosti hodně využívaná hyperspektrální data, která jsou měřena v řádech desítek až stovek pásem (Halounová, 2005).

Obrazové materiály DPZ, stejně jako mapy, v sobě nesou topografickou a tematickou informaci. Topografická informace vypovídá o poloze objektů, o jejich tvaru a velikosti, ale také o tom, jak vzdálené od sebe jednotlivé objekty jsou. Tematická informace pak vypovídá o tom, jaký typ vegetace nebo povrchu se na daném území nachází (Dobrovolný, 1998).

Úspěšný sběr dat DPZ vyžaduje pochopení čtyř základních rozlišovacích charakteristik, jmenovitě prostorového, spektrálního, radiometrického a časového rozlišení. Prostorové rozlišení určuje úroveň prostorových detailů, které lze pozorovat na zemském povrchu. Data hrubého prostorového rozlišení mohou zahrnovat velký počet smíšených pixelů, kde lze v jednom pixelu nalézt více než jeden typ krajinného pokryvu. Zatímco data s jemným rozlišením, jak je možné vidět na obrázku č. 3, značně snižují problém smíšených pixelů, mohou zvýšit vnitřní variaci v rámci typů krajinného pokryvu. Vyšší rozlišení také znamená potřebu většího úložiště dat a vyšší náklady a může způsobit potíže při zpracování obrazu pro velkou studijní oblast (Weng, 2010).



Obrázek 3: Prostorové rozlišení

Zdroj: (NEON Science, 2021)

Spektrální rozlišení senzoru se vztahuje k počtu a velikosti pásem, které je schopen nahrát. Popisuje schopnost senzoru definovat jemné intervaly vlnových délek. Čím jemnější je spektrální rozlišení, tím užší je rozsah vlnových délek pro konkrétní kanál nebo pásmo. Mnoho systémů DPZ zaznamenává energii v několika samostatných rozsazích vlnových délek v různých spektrálních rozlišeních. Pokročilé hyperspektrální senzory detekují stovky velmi úzkých spektrálních pásem ve viditelné, blízké infračervené a střední infračervené části

elektromagnetického spektra. Jejich velmi vysoké spektrální rozlišení usnadňuje jemné rozlišení mezi různými cíli na základě jejich spektrální odezvy v každém z úzkých pásem (Government of Canada, 2015; Weng, 2010).

Radiometrické rozlišení lze definovat jako schopnost zobrazovacího systému pro záznam mnoha úrovní jasu. Hrubé radiometrické rozlišení by zaznamenalo scénu s použitím pouze několika úrovní jasu nebo několik bitů (tj. na velmi vysokém kontrastu), zatímco jemné radiometrické rozlišení by zaznamenalo stejnou scénu s využitím mnoha úrovní jasu (Campbell, 2011).


Časové rozlišení označuje dobu, po kterou se senzor vrátí na dříve snímané místo. Proto má časové rozlišení důležitý význam při detekci změn a monitorování prostředí. Mnoho environmentálních jevů, jako je vegetace, počasí apod., se v průběhu času neustále mění. Z tohoto důvodu je časové rozlišení velmi důležitým faktorem (Weng, 2010).

1.4 Družicové systémy

Jako družicový systém je označováno několik družic, které mají podobné vlastnosti týkající se technických parametrů nosiče, kompatibility pořizovaných dat nebo parametrů snímacího zařízení. Většina parametrů systému je ovlivněna především oběžnou dráhou, na které se družice pohybuje (Dobrovolný, 1998).

V dnešní době existuje velká řada důvodů pro vypouštění družic na oběžnou dráhu. Jedná se o jediný prostředek sloužící k měření atmosféry a zemské magnetosféry. Družice umožňují získat pohled na zemský povrch ve všech oblastech elektromagnetického spektra. Lidstvo musí opustit Zemi, aby bylo schopné nasbírat rozsáhlé snímky kontinentů, oceánů a atmosféry. Družice jsou rovněž schopné komunikovat s velkým množstvím míst na Zemi současně a tvoří tak základ pro celosvětové telefonní a datové sítě, což platí i pro televizní přenosy. Systém navigačních družic pak poskytuje prostředky pro přesnou lokalizaci a navigaci po celém světě (Montenbruck, 2000).

Nepolární, nízké oběžné dráhy Země jsou ve výšce obvykle méně než 2000 km nad povrchem Země. Tyto oběžné dráhy nezajišťují globální pokrytí, ale pokrývají pouze částečný rozsah zeměpisných šířek. Geostacionární družice (viz. Obrázek 4) následují rotaci Země a pohybují se stejnou rychlostí rotace. Z tohoto důvodu se zdá, že satelity jsou pro pozorovatele na Zemi upevněny na jednom místě. Tyto družice zachycují stejný pohled na Zemi při každém pozorování a poskytují tak téměř nepřetržité pokrytí jedné oblasti. Mezi příklady geostacionárních družic patří meteorologické družice (Earth Data, 2021).



Obrázek 4: Oběžné dráhy

Zdroj: (Orbits)

2 IDENTIFIKACE ZMĚN V KRAJINĚ

2.1 Krajina

Pojem krajina je definován různě v závislosti na vědních disciplínách. Každá disciplína vidí krajinu jinými očima a analyzuje ji s ohledem na její specifické otázky. Z tohoto důvodu je obtížné vyjádřit obecně platnou definici krajiny. Asi největší rozdíl je mezi vědeckým a společenskovědním pohledem (Landscape, 2019).

Krajina je oblast země v různých měřítcích, obsahující vzory, které ovlivňují různé ekologické procesy, které nás zajímají, a jsou jimi ovlivněny. Krajina se skládá z různých fyzických a živých prvků včetně topografie, vegetace, vody a lidských činností (Wang, 2013).

Krajina je dynamický systém, který člověk neustále ovlivňuje. V závislosti na lidských vlivech se zvýšil tlak na krajinu a v důsledku toho se krajina v průběhu času mění. Krajinná ekologie zkoumá strukturu a změny v krajině, tedy jakoukoliv změnu probíhající v krajině v průběhu času (Gökyer, 2013).

2.1.1 Struktura krajiny

Ulrich Walz (2011) ve své práci uvádí, že krajinnou strukturou se rozumí vzor krajiny, který je dán způsobem jejího využití, ale také strukturou, tedy velikostí, tvarem, uspořádáním a rozložením jednotlivých krajinných prvků. Pro vymezení těchto krajinných prvků, nebo tzv. „záplat“ se často používají jednotky land use nebo land cover.

Ačkoli se pojmy krajinný pokryv (land cover) a využití půdy (land use) často zaměňují, jejich skutečné významy jsou zcela odlišné. Termín land use se týká lidské činnosti spojené se specifickou částí půdy, zatímco land cover je termín, který se využívá v souvislosti s typem pokryvu přítomného na povrchu Země. Krajinný pokryv i využití půdy lze snadno rozeznat na leteckých fotografiích. Barevné fotografie pak poskytují ještě lepší možnost rozlišení jednotlivých typů pokryvu nebo využití. Při práci v oblasti vysokých domů a objektů hrají důležitou roli také stíny (Reddy, 2008).


Využití půdy se vztahuje k účelu, pro který půda slouží, například k rekreaci nebo zemědělství. Aplikace využití půdy zahrnují jak základní mapování, tak následný monitoring, protože je zapotřebí včasných informací, abychom věděli, jaké množství půdy a jakého typu využití v současnosti je, a aby bylo možné identifikovat změny ve využívání půdy z roku na rok. Problémy, které řídí studie využití půdy, zahrnují odstraňování nebo narušování produktivní půdy, zasahování do měst a vyčerpání lesů (Land Cover & Land Use, 2015).

2.1.2 Spektrální projevy a vlastnosti krajiny

Jednotlivé charakteristiky odrazivosti prvků zemského povrchu lze kvantifikovat pomocí měření části dopadající energie, která se odráží. Ta se měří jako funkce vlnové délky a nazývá se spektrální odrazivost. Výsledky této funkce se zaznamenávají do grafu a označují se jako křivky spektrální odrazivosti (viz. Obrázek 5). Tyto křivky pak umožňují pozorovat spektrální charakteristiky objektů a mají velký vliv na výběr oblastí vlnových délek, ve kterých jsou získávána data dálkového průzkumu Země pro konkrétní aplikaci (Lillesand, c2008).

Při snaze o rozpoznání objektů nejsou důležité pouze spektrální vlastnosti zkoumaného objektu. Důležitou roli hrají také vlastnosti okolních objektů. Pokud nastane situace, že přilehlé objekty odrazí stejné množství záření, nebude jednoduché je od sebe odlišit. Tento problém může být vyřešen pomocí nalezení vhodného intervalu vlnových délek, ve kterém se mohou lišit (Dobrovolný, 1998).

Odrazové vlastnosti vegetace závisí na vlastnostech listů, včetně orientace a struktury. Množství záření odraženého pro určitou vlnovou délku závisí na pigmentaci listu, tloušťce a buněčné struktuře a na množství vody v pletivu listu. Odrazivost půdy závisí na tolika faktorech, že je obtížné zobrazit jednu typickou křivku odrazivosti půdy. Hlavními faktory ovlivňujícími odrazivost jsou barva půdy, obsah vlhkosti, přítomnost uhlíkatů a obsah oxidů železa. Voda má ve srovnání s vegetací a půdami nižší odrazivost. Vegetace může odrážet až 50 % a půdy až 30–40 %, zatímco voda odráží nejvýše 10 % dopadajícího záření (Spectral reflectance curves, 2020).



Obrázek 5: Spektrální křivky vegetace, půdy a vody

Zdroj: (Introduction to Categorisation of Objects from their Data)

2.1.3 Detekce změn krajiny

Lillesand (c2008) zmiňuje, že jednou z největších výhod snímků DPZ je jejich schopnost zachytit a uchovat záznam v různých okamžicích, aby bylo možné identifikovat a charakterizovat změny v průběhu času. Tento proces se nazývá detekce změn a patří mezi nejběžněji používané analýzy digitálního obrazu. Zároveň zmiňuje, že typy změn, které by mohlo být zajímavé sledovat, se mohou pohybovat od téměř okamžitých (pohyb vozidla nebo zvířete) až po dlouhodobé jevy, jako je například rozvoj měst.

Jensen (2015) definuje následující základní kroky při detekci změn:

- 1) Stanovení povahy problému
 - Zde se jedná především o určení zájmu, specifikaci geografické oblasti, stanovení časového období, definování tříd apod.
- 2) Úvahy o významu v rámci detekce změn
 - Řeší se prostorové, spektrální, časové a radiometrické rozlišení, dále také aspekty prostředí, jako je pokrytí snímků mraky, vlhkost půdy a další jevy jak přírodní, tak člověkem vytvořené
- 3) Zpracování dat DPZ a extrahování informace o změně
 - Třetí bod se zabývá získáním vhodných dat, řeší se jejich předzpracování pomocí geometrických a radiometrických korekcí, vybírá se logika pro klasifikaci dat a dochází k detekci změn pomocí GIS (tvoření mapových výstupů, výpočet statistik změny atd.)
- 4) Posouzení přesnosti
 - V rámci posouzení přesnosti se řeší výběr metody, definování počtu vzorků požadovaných třídou, výběr schématu vzorkování, získávání informací o pozemním referenčním testu. Dále se také tvoří a analyzuje matice chyb.
- 5) Interpretace a distribuce výsledků

V ideálním případě by postupy detekce změn měly zahrnovat data získaná stejným (nebo podobným) senzorem a měla by být zaznamenána s použitím stejného prostorového rozlišení, geometrie pozorování, spektrálních pásem, radiometrického rozlišení a denní doby. Pro zjišťování změn v časovém měřítku delším než jeden rok, se upřednostňují výroční data, aby se minimalizoval úhel slunce a sezónní rozdíly (Lillesand, c2008).

2.2 Digitální zpracování dat DPZ

Dálkově snímaná data lze použít k získání tematických a metrických informací a připravit je tak pro vstup do GIS. Tematické informace poskytují popisná data o prvcích zemského povrchu. Metrické informace zahrnují polohu, výšku a jejich odvozeniny, jako je plocha,

objem, úhel sklonu a tak dále. Tematické informace lze získat vizuální interpretací snímků dálkového průzkumu Země (včetně fotografií) nebo digitální analýzou obrazu. Metrické informace jsou získávány pomocí principů fotogrammetrie (Weng, 2010).

Neexistuje přesně definovaný postup zpracování obrazových dat. Jednotliví autoři se liší v počtu definovaných kroků. Halounová a Pavelka (2005) zdůrazňují, že digitální zpracování obrazových dat DPZ je velmi široké téma a definují 4 základní typy operací. Jednotlivé typy operací jsou popsány v následujících podkapitolách.

2.2.1 Rektifikace a restaurace

Předzpracování, jak se také jinak označuje rektifikace a restaurace, znamená počáteční zpracování vstupních dat pořízených dálkovým průzkumem Země. Hlavním cílem tohoto kroku je opravení dat, která mohou být poškozena například zkreslením (Halounová, 2005).

Horák (2014) popisuje rektifikaci jako proces transformace dat z jedné matice záznamu do matice druhé. K tomuto postupu se využívá polynomická transformace n -tého stupně. Jako základní kroky rektifikace pak uvádí nalezení identických bodů, které spočívá v určení jejich souřadnic), výpočet a test transformační matice a vytvoření výstupu.

Téměř ve všech případech existují určité operace předběžného zpracování, které se provádějí na nezpracovaných datech před jeho použitím. Některé z těchto operací jsou určeny k opravě nedostatků v datech, zatímco jiné umožňují, aby byla data přístupnější pro další zpracování. Mezi tyto operace můžeme zařadit odstranění šumu, radiometrické korekce, geometrické korekce a mozaikování. Některé z těchto operací může provést poskytovatel dat předtím, než jsou snímky poskytnuty analytikům, kteří je budou interpretovat. V jiných případech mohou uživatelé potřebovat provést jeden nebo více těchto kroků sami (Lillesand, 2008).

Radiometrické korekce pracují s hodnotou digital number (DN), kterou nesou jednotlivé pixely. Upravují tyto hodnoty v obrazovém záznamu tak, aby se co nejvíce podobaly skutečným odrazovým a zářivým vlastnostem objektů. Velká část obrazových záznamů obsahuje především náhodné nepřesnosti. Jedná se například o chybějící řádek záznamu způsobený nesprávnou kalibrací senzoru. Takovou chybu je pak možné odstranit v rámci radiometrické korekce, a to za pomoci průměrování hodnot sousedních řádků (Dobrovolný, 1998).

Horák (2014) uvádí jako typy radiometrických korekcí:

- Korekce pomocí kalibrace měřicího zařízení
- Opravy ze směru ozáření
- Opravy chyb plynoucích z geometrie lezu

- Odstranění náhodných radiometrických chyb
- Opravy ze stavu atmosféry

Vzdáleně snímané obrazy nejsou mapy. Informace extrahované z dálkových snímků jsou často integrovány s mapovými daty v rámci geografického informačního systému (GIS). Transformace dálkově snímaného obrazu na mapu s měřítkem a projekčními vlastnostmi se nazývá geometrická korekce. Geometrická korekce musí být provedena, pokud potřebujeme například (Reddy, 2008):

- Transformovat obraz tak, aby odpovídal mapové projekci
- Nalézt zájmové body na mapě nebo v obraze
- Integrovat snímky DPZ s GIS

Zdroje geometrických zkreslení lze rozdělit na dva typy chyb, a to chyby systematické a náhodné. Systematické chyby se dají vyjádřit matematickým vztahem, tzn. mají dobře formulovatelnou příčinu. Mezi tyto chyby můžeme zařadit například tangenciální zkreslení (velikost pixelu je nejmenší v ose letu a k okrajům skenované řady roste), chyba ze zakřivení Země (je patrná při snímání velkého území), chyby z nerovnosti terénu (lze je odvodit z výšky a odklonu od svislice) a další. Náhodné chyby vznikají výchyly v dráze nosiče. Oprava náhodných chyb se provádí až po opravě chyb systematických a odstraňují se pomocí geometrické transformace (Horák, 2014).

Plánka (2007) mezi zdroje geometrických chyb řadí změny výšky letu, polohy a rychlosti nosiče, zakřivení Země včetně její rotace nebo výškové změny reliéfu terénu a vlastnosti použitého senzoru. Obecný postup rektifikace pak podle autora zahrnuje čtyři kroky. Prvním krokem je vyhledání identických bodů. Druhým krokem je volba transformace, její výpočet a testování. Předposledním krokem je samotná rektifikace obrazu a závěrečným krokem pak je tzv. převzorkování neboli přenos informace z matice původní do matice upravené.

Brůha (2014) uvádí jako tři nejčastěji využívané metody převzorkování interpolaci nejbližším sousedem, bilineární interpolaci a kubickou konvolucí. Autor uvádí, že metoda nejbližšího souseda je vhodná především pro tematická nebo kategorická data. Důvodem je fakt, že tato metoda nemění hodnotu vstupních buněk. Metoda nejbližšího souseda pracuje na principu nalezení polohy středu pixelu. Nejprve je nutné najít polohu středu pixelu výstupního rastru v rastru původním a poté dojde k určení středu nejbližšího souseda, kdy je nalezená hodnota přiřazena do buňky výstupního rastru.

Bilineární interpolace určuje hodnotu pixelu pomocí váženého průměru hodnot DN čtyř nejbližších pixelů. Tato technika vytváří hladší převzorkovaný obrázek. Protože však proces

mění úrovně šedé původního obrazu, mohou se při následných analýzách rozpoznávání spektrálních vzorů v datech vyskytnout problémy. Z tohoto důvodu se převzorkování často provádí spíše po než před procesem klasifikace (Lillesand, c2008).

Kubická konvoluce je podobná bilineární interpolaci v tom, že počítá průměr okolních buněk. Místo použití čtyř nejbližších buněk je výstupní hodnota založena na zprůměrování šestnácti nejbližších buněk (Sabins, 2020).

Nejlepší, ale zároveň nejzdlouhavější metodou, je kubická konvoluce, která zachovává detaily a ostré hrany v obraze. Kubická konvoluce může být až desetkrát časově náročnější než metoda nejbližšího souseda, která ale má nejhorší výsledky týkající se výsledného obrazu. Poslední jmenovaná metoda, tedy bilineární interpolace, pak vytváří středně kvalitní výstup, který má plynulé přechody obrazu (Brůha, 2014).

Kromě výše zmíněných radiometrických a geometrických korekcí existují také korekce atmosférické. Jedná se o nejsložitější formy oprav. Při zaznamenávání dat dochází k úpravám hodnot DN vlivem rozptylu, pohlcování a emisivité atmosféry. Signál při snímání je ovlivněn obsahem kouřma a zákalu v atmosféře. Mezi typy atmosférických korekcí patří korekce z modelu vlivu atmosféry, metoda nejtmavšího pixelu a regresní analýza (Horák, 2014).

Korekce z modelu vlivu atmosféry využívají meteorologická data pořízená v době snímání obrazového záznamu. Meteorologická data, například o teplotě, znečištění nebo vlhkosti, spolu s hodnotami DN vstupují do numerických modelů. Výstupem těchto modelů pak jsou upravená data týkající se radiačních a zářivých vlastností objektů na zemském povrchu. Metoda nejtmavšího pixelu vychází z fyzikálního faktu, že vodní objekty v blízké infračervené části elektromagnetického spektra mají téměř nulové vyzařování. Je-li možné na snímku nalézt minimálně jednu vodní plochu, která je dostatečně hluboká, je možné signál považovat za příspěvek atmosféry. V tomto případě se od všech prvků odečte zjištěná hodnota radiometrické charakteristiky. Posledním typem je regresní analýza, která pracuje s daty získanými snímáním a daty z povrchového měření. Jedná se o velmi časově a finančně náročnou metodu, proto se často nevyužívá (Dobrovolný, 1998).

2.2.2 Zvýraznění obrazu

Zvýraznění obrazu je proces zlepšování vizuálního vzhledu digitálních snímků. Z důvodu rostoucího významu digitálních analýz je v rámci dálkového průzkumu zvýraznění obrazu velmi významné (Campbell, 2011).

Před samotným použitím metod zvýraznění obrazu je vhodné provést předzpracování obrazu. V rámci předzpracování, jak již bylo zmíněno, dochází například k odstranění šumu. Pokud by nebyly takové chyby odstraněny, mohlo by dojít k jejich významnému zvýraznění. Nelze definovat obecně platný postup zvýraznění, lze pouze dodržovat obecné zásady a znalost používaných algoritmů a metod (Horák, 2014).

Různé metody zvýraznění obrazu mohou být použity pro zlepšení vizuální interpretovatelnosti dat snímaných na dálku a také pro usnadnění následné tematické extrakce informací. Metody zvýraznění obrazu lze rozdělit do tří kategorií. Jedná se o bodová, prostorová a spektrální zvýraznění (Weng, 2010).

Bodové neboli radiometrické zvýraznění využívá histogram obrazu a zobrazovací funkci/tabulku. Pomocí zobrazovací funkce je hodnotě pixelu původního obrazu přiřazena nová DN hodnota v obraze výstupním. Mezi základní metody bodového zvýraznění se řadí tzv. prahování, hustotní řezy a zvýraznění kontrastu (Plánka, 2007).

V rámci prahování dochází k převodu hodnot obrazové funkce do malé množiny prvků, typicky se jedná o množinu $(0,1)$. Nejčastěji se tato množina graficky reprezentuje pomocí bílé a černé barvy. Metoda prahování se díky svému způsobu rozdělení využívá pro tvorbu tzv. masek. Tyto masky lze pak snadno použít například pro klasifikaci obrazu po jednotlivých částech. Části obrazu se rozdělí na hodnoty 0 (u zamaskovaných částí) a 1. Následně lze odfiltrovat nepotřebnou informaci součinem původních dat a masky (Halounová, 2005; Horák 2014).

Na podobném principu jako prahování pracuje i další metoda zvaná hustotní řezy. I v této metodě jde v podstatě o snížení počtu jedinečných hodnot pixelů do menšího počtu jednotlivých tříd. Rozdíl oproti prahování je, že hustotní řezy využívají více než dvě kategorie, do kterých jsou data rozdělena. Data jsou rozdělena do jednotlivých, předem stanovených kategorií, pomocí histogramu. Pokud je potřeba lépe rozlišit jednotlivé kategorie, je vhodné přiřadit jednotlivým kategoriím jiné barvy než stupně šedi, které jsou pro lidské oko hůře rozlišitelné (Dobrovolný 1998).

Zvýraznění kontrastu spočívá v úpravě histogramu pomocí jeho roztažení do celého rozsahu, vyrovnaní, kde se hodnotám s větší četností přiřadí větší prostor a zvýraznění vybrané části histogramu. Další možností, kterou lze dosáhnout lepšího kontrastu je využití tzv. saturace neboli potlačení. Jedná se o odstranění části histogramu, ve které se nacházejí podprahové četnosti hodnot pixelů, které jsou hodnotou blízké nule nebo hodnotě 255 (Plánka 2007).

Prostorové zvýraznění je matematické zpracování obrazových dat využívané ke zdůraznění prostorových vztahů. Techniky prostorového zvýraznění využívají koncept prostorové

frekvence v rámci snímku. Prostorová frekvence je způsob, jakým se hodnoty ve stupních šedi mění vzhledem k jejich sousedům. Pokud dochází k pomalu se měnící změně v odstínech šedé z jedné strany snímku na druhou, znamená to, že obrázek má nízkou prostorovou frekvenci. Pokud se hodnoty pixelů výrazně liší od hodnot sousedních pixelů, jedná se o snímek s vysokou prostorovou frekvencí (Faust).

Mezi metody prostorového zvýraznění lze zařadit prostorové filtrace a Fourierovy transformace. Oproti bodovým metodám zvýraznění tyto metody pracují s hodnotami DN jistého počtu okolních prvků a určují hodnotu DN daného obrazového prvku v závislosti na jejich hodnotách. Při filtrování lze využít filtry s nízkou nebo vysokou propustností. Samotné filtrování se pak provádí pomocí matice o lichém počtu sloupců a řádků. Tato matice se označuje jako filtrovací okno (Plánka, 2007).

Spektrální zvýraznění se týká manipulace s více spektrálními pásmy za účelem získání užitečnějších informací a zahrnuje metody jako je přidělování a diferencování pásem, analýza hlavních komponent, vegetační indexy atd. (Weng, 2010).

Data DPZ se ve velké míře používají pro monitorování vegetace na velké ploše. Typicky jsou při tomto procesu využívána dvě spektrální pásma, a to viditelné a blízké infračervené. Mnoho vegetačních indexů bylo vyvinuto na základě skutečnosti, že rostliny odrážejí více záření v blízkém infračerveném pásmu než povrchy bez vegetace. Jako vegetační indexy jsou označovány různé matematické kombinace pásem RGB a NIR (viz. Tabulka 1). Mezi tři základní indexy patří jednoduchý vegetační index, poměrový vegetační index a normalizovaný diferenciální vegetační index (Weng 2010; Reddy, 2008).

Tabulka 1: Vegetační indexy

Vegetační index	Zkratka	Výpočet
Jednoduchý vegetační index (Simple Vegetation Index)	SVI	$SVI = NIR - RED$
Poměrový vegetační index (Ratio Vegetation Index)	RVI	$RVI = \frac{NIR}{RED}$
Normalizovaný diferenční vegetační index (Normalized Difference Vegetation Index)	NDVI	$NDVI = \frac{NIR - RED}{NIR + RED}$

Normalizovaný vodní index (Normalized Water Index)	diferenční Difference	NDWI	$NDWI = \frac{GREEN - NIR}{GREEN + NIR}$
---	--------------------------	------	--

Zdroj: upraveno dle (Weng, 2010; Richards, 2022)

2.2.3 Klasifikace

Cílem jednotlivých postupů klasifikace snímků je automaticky kategorizovat všechny pixely na snímku do tříd nebo témat krajinného pokryvu. Tento proces se často provádí pomocí tzv. spektrální vzorů, to znamená, že pixely, které mají podobné kombinace spektrální odrazivosti nebo emisivity, jsou seskupeny do tříd, o kterých se předpokládá, že představují konkrétní kategorie povrchových prvků. Každý pixel je klasifikován individuálně na základě nějakého statistického nebo deterministického modelu využívajícího hodnoty z více datových vrstev (Lillesand, c2008).

Existuje mnoho metod a technik, které lze využít v případě klasifikace dat pořízených pomocí DPZ. Prvotní rozdělení zahrnuje tři kategorie: automatická, manuální a hybridní klasifikace. Automatickou klasifikaci lze dále rozdělit na klasifikaci řízenou a neřízenou. Klasifikace řízená i neřízená se pak dále dělí na již jednotlivé metody a techniky (Abburu, 2015).

Obecný postup klasifikace se skládá z několika kroků (Al-doski, 2013):

- 1) Návrh schémat klasifikace snímků – definice tříd
- 2) Předzpracování obrazu včetně korekcí
- 3) Výběr reprezentativní oblasti obrazu a analýza počátečních výsledků shlukování nebo generování trénovacích ploch
- 4) Spuštění algoritmů klasifikace snímků
- 5) Postklasifikační úpravy
- 6) Hodnocení přesnosti

Řízená klasifikace se využívá v případě, kdy je identita a umístění některých typů krajinného pokryvu známa prostřednictvím kombinace práce v terénu, interpretace leteckého snímkování, analýzy map a osobní zkušenosti. Analytik se pokouší v datech DPZ lokalizovat konkrétní místa, která představují homogenní příklady těchto známých typů krajinného pokryvu. Tyto oblasti jsou běžně označovány jako trénovací plochy, protože spektrální charakteristiky těchto známých oblastí se používají k trénování klasifikačního algoritmu (Jensen, 2015).

Reddy (2008) definuje tři základní etapy řízené klasifikace:

- 1) Trénovací
- 2) Klasifikační
- 3) Výstupní

Prvním krokem celého procesu řízené klasifikace je definování trénovacích ploch. U snímků DPZ závisí počet trénovacích ploch na maximálním počtu zájmových tříd, které lze z dané oblasti extrahovat. Místa by měla být vybrána za předpokladu, že je jich dostatečný počet, jsou homogenní, skutečně reprezentují danou třídu, jsou dobře rozmístěna a velikost třídy odpovídá prostorovému rozlišení senzoru. Dobrá klasifikace závisí přímo na kvalitě trénovacích dat. Kvalita trénovacích dat tak může významně ovlivnit výsledek klasifikačního algoritmu (Kumar, 2020).

V rámci kvality trénovacích dat je potřeba dodržet především aspekt komplexnosti a reprezentativnosti. Aby byl dodržen aspekt komplexnosti, je potřeba, aby byly charakterizovány všechny třídy, které jsou předmětem zájmu daného zkoumání. Pokud má daný klasifikační proces stanovené tematické zaměření, může se stát, že některé typy povrchů nejsou natrénovány, a tím pádem je ve výsledku vysoký podíl nezatříděných obrazových prvků. Reprezentativnost pak souvisí s charakteristikou každé třídy. Pokud se v obraze nachází několik stejných typů ploch, které ale mají různé spektrální vlastnosti (např. různá hloubka vody), je dobré vytvořit více trénovacích ploch podle jednotlivých spektrálních tříd (Dobrovolný, 1998).

Správné definování trénovacích ploch je velmi důležité pro konečný úspěch klasifikace a je tedy potřeba dodržet určité faktory, které přispějí k tomuto stavu. Mezi takové faktory lze zařadit například (Červená, 2016):

- Každá trénovací plocha jedné třídy by měla obsahovat minimálně $N + 1$ pixelů. N je počet klasifikovaných spektrálních pásem.
- Každá z trénovacích ploch by měla být rovnoměrně rozmístěna v rámci snímku z důvodu možných odlišností vyzařovacích a odrazivých vlastností v jednotlivých částech daného snímku.
- Z důvodu možné smíšené spektrální informace okrajových pixelů jednotlivých objektů by tyto pixely neměly být zařazeny do trénovacích ploch

Po trénovací etapě následuje etapa klasifikační. V této fázi je každý pixel v sadě obrazových dat kategorizován do jednotlivých tříd v závislosti na tom, které třídě se nejvíce podobají jeho vlastnosti. Pixely jsou tříděny pomocí vyhodnocení spektrálních vzorů prostřednictvím předem definovaných rozhodovacích pravidel. Pokud není nějaký pixel podobný ani jedné definované třídě, je označen jako „Unknown“ (tedy jako neznámý) (Lillesand, c2008).

K přiřazení pixelů do jedné z možných tříd se využívají různé klasifikační algoritmy (viz. Tabulka 2). Výběr vhodného klasifikátoru nebo rozhodovacího pravidla závisí na povaze vstupních dat a na požadovaném výstupu. Klasifikační algoritmy lze rozdělit na parametrické a neparametrické. Rozdíl mezi těmito skupinami je jednoduchý. Parametrické algoritmy předpokládají, že pozorované vektory měření získané pro každou třídu v každém spektrálním pásmu, mají Gaussovské (normální) rozdělení. Neparametrické algoritmy tento předpoklad nemají (Jensen, 2015).

Mezi nejvyužívanější parametrické testy patří maximální pravděpodobnost a mezi neparametrické lze zařadit například klasifikátor pravoúhelníků, minimální vzdálenost, K-nejbližších sousedů nebo také neuronové sítě.

Klasifikátor maximální pravděpodobnosti je řízený statistický přístup k rozpoznávání vzorů. Základním principem klasifikátorů je výpočet pravděpodobnosti, že zkoumaný pixel patří do každé z předem definovaných tříd. Pixel je následně přiřazen do třídy, pro kterou je tato pravděpodobnost nejvyšší. Tento klasifikátor vychází z jasně stanoveného předpokladu, že shluky pixelů v trénovacích množinách mají normální rozdělení. Tento předpoklad normality je obecně platný pro běžnou spektrální odezvu. Za tohoto předpokladu pak lze jednotlivé kategorie popsat průměrovým vektorem a kovarianční maticí. Pomocí těchto parametrů je pak možné vypočítat statistickou pravděpodobnost, že daná hodnota pixelu patří do dané třídy (Tso, 2009; Lillesand, c2008).

Klasifikátor pravoúhelníku je rozhodovací pravidlo, které je založeno na Boolean logice. K provedení klasifikace se používají trénovací data v n spektrálních pásmech. V rámci každého pásma jsou vedeny linie pixelů s minimální a maximální hodnotou. Vedením těchto linií vzniknou vymezené oblasti, které obsahují pixely patřící do dané kategorie. Pokud se nějaký pixel nachází mimo všechny vzniklé oblasti, nebude klasifikován. Pixely, které se vyskytují v překrývajících se oblastech, jsou označeny jako neurčité nebo jsou libovolně umístěny do jedné z překrývajících se oblastí. Velikost vymezené oblasti rovněž vyjadřuje sensitivity klasifikátoru na rozptyl hodnot všech tříd (Jensen, 2015; Lillesand, c2008; Dobrovolný, 1998).

Klasifikátor minimální vzdálenosti středu shluků je jednoduché a běžně využívané rozhodovací pravidlo. Při správném použití může vykazovat přesnost klasifikace srovnatelnou s jinými výpočetně náročnějšími metodami, jako je například již zmíněný klasifikátor maximální pravděpodobnosti. Prvním krokem klasifikace je výpočet průměrné spektrální hodnoty pro každý shluk v každém spektrálním pásmu. Tyto hodnoty pak stanovují tzv. centroid neboli střed shluku. Klasifikátor pak počítá vzdálenost každého neznámého pixelu ke každému středu shluku. Tento klasifikátor není vhodný pro použití v případech, kdy

jednotlivé spektrální třídy mají vysoký rozptyl nebo jsou u sebe blízko v rámci multispektrálního prostoru (Jensen, 2015; Dobrovolný, 1998).

Klasifikátor K – nejbližších susedů (KNN) je založen na myšlence, že zařazení pixelu do třídy je závislé na hodnotách k nejbližších přilehlých pixelů. To znamená, že při klasifikaci požadovaného pixelu vyhledá klasifikátor předem stanovený počet nejbližších pixelů a zkoumaný pixel je zařazen do té třídy, která převládá v celé množině nejbližších sousedních pixelů. Tento klasifikátor je možné považovat za jakési rozšíření klasifikátoru minimální vzdálenosti (Kramer, c2013; Dobrovolný, 1998).

Tabulka 2: Porovnání klasifikátorů řízené klasifikace

Klasifikátor	Výhody	Nevýhody
Maximální pravděpodobnost (Maximum Likelihood)	Zajistí dobré rozdělení tříd	Vyžaduje dobrou trénovací sadu Výpočetní náročnost
Klasifikátor pravouhelníků (Parallelepiped)	Výpočetní efektivnost Rychlost provedení	Všechny pixely nemusí být klasifikovány Pixely se mohou objevit ve více třídách
Minimální vzdálenost (Minimum distance)	Rychlost provedení Všechny pixely jsou klasifikovány	Náchylnost k chybám
K-nejbližších susedů (K – nearest neighbors)	Nízké náklady Snaha o proces učení	Výpočetně náročné při velké datové sadě Výkon závisí na počtu dimenzí

Zdroj: (Varma, 2021)

Poté, co jsou všechny pixely kategorizovány, jsou výsledky prezentovány v rámci výstupní fáze. Výsledky lze využít mnoha různými způsoby, protože mají digitální formu. Základními třemi výstupy jsou tematické mapy, statistické tabulky pro jednotlivé třídy krajinného pokryvu a samotná digitální data, která lze dále využívat v rámci GIS (Lillesand, c2008).

Neřízená klasifikace známá také jako „clustering“ hraje důležitou roli při dolování dat a rozpoznávání vzorů, a má uplatnění ve velkém množství oborů. Při shlukování se sada neoznačených vzorů, nejčastěji vektorů ve vícerozměrném prostoru, seskupuje do shluků, kdy vzory ve stejném shluku jsou si v určitém smyslu podobné a vzory v různých shlucích se ve stejném smyslu liší. Z pohledu matematiky pak shlukování rozděluje vstupní prostor do oblastí na základě nějaké (ne)podobnosti (Bandyopadhyay, 2012).

Neřízená klasifikace je velmi účinnou metodou klasifikace multispektrálních dat získaných prostřednictvím dálkového průzkumu Země a získávání informací o krajinném pokryvu. Ve srovnání s řízenou klasifikací obvykle vyžaduje jen minimum vstupních informací, protože shlukování nevyžaduje trénovací data, jako tomu bylo u předchozího typu klasifikace. Z pohledu GIS je neřízená klasifikace procesem, při kterém se provádějí numerické operace, které hledají přirozené shlukování spektrálních vlastností jednotlivých pixelů. Výsledkem celého procesu je klasifikační mapa, která se skládá z K spektrálních tříd. Následně se analytik pokusí přiřadit jednotlivým spektrálním třídám informační význam (o jaký typ pokryvu se jedná). Aby byl analytik schopen tento nelehký úkol splnit, je důležité, aby dostatečně dobře rozuměl spektrálním charakteristikám terénu (Jensen, 2015).

Dobrovolný (1998) definuje následující základní kroky neřízené klasifikace:

1. Definice hrubého počtu výsledných shluků
2. Určení počáteční polohy středu shluků
3. Přiřazení pixelů do shluku, ke kterému mají nejbližší
4. Výpočet nového středu shluků dle přiřazených pixelů
5. Opakování 3. a 4. kroku, dokud se výrazně nemění poloha shluku nebo počet přiřazených pixelů
6. Přiřazení informačního významu stabilním shlukům
7. Vytvoření informačních tříd spojováním spektrálních tříd

Mezi často využívané metody neřízené klasifikace lze zařadit K-Means nebo ISO Data.

K-Means je přístup, který akceptuje počet shluků, které mají být definovány od analytika. Algoritmus pak libovolně stanovuje tento počet středů shluků ve vícerozměrném prostoru. Každý pixel je následně přiřazen ke shluku, jehož libovolný střední vektor je nejbližší. Poté, co jsou tímto způsobem klasifikovány všechny pixely, jsou vypočítány nové střední vektory pro každý ze shluků. Tyto střední vektory jsou pak použity jako základ pro reklasifikaci obrazu. Postup pokračuje, jak již bylo zmíněno výše, do doby, kdy nedojde k žádné významné změně v po sobě jdoucích iteracích. Jakmile je dosaženo tohoto bodu, analytik určí identitu krajinného pokryvu každé spektrální třídy (Lillesand, c2008).

ISO Data je algoritmus shlukování, který je založen na přístupu K-means pomocí zavedení řady kontrol vytvořených shluků, buď během, nebo na konci procesu iterativního přiřazení. Tyto kontroly se vztahují k počtu pixelu přiřazených ke shlukům a jejich tvaru ve spektrální doméně (Richards ,2022).

Mimo již výše zmíněné klasifikátory, které se řídí základním rozdělením na řízené a neřízené, existuje v dnešní době více dalších možností, jak obrazová data klasifikovat. V další části jsou proto přiblíženy další často využívané možnosti.

Neuronové sítě

Umělé neuronové sítě (angl. Artificial Neural Networks, zkráceně ANN) byly původně navrženy jako nástroj pro rozpoznávání vzorů a analýzu dat, které napodobují ukládání a analytické operace mozku. ANN mají oproti metodám statistické klasifikace výhodu v tom, že vyžadují malou nebo nulovou znalost distribučního modelu vstupních dat. Mezi výhody neuronových sítí pak lze zařadit paralelní výpočty, schopnost odhadnout nelineární vztah mezi vstupními daty a požadovaným výstupem a schopnost rychlého zobecnění. Mezi příklady takových neuronových sítí se řadí například SOM (Kohonen's Self-Organizing Mapping) nebo MLP (Multi-Layer Perceptron). Autor také uvádí, že vícero studií týkajících se využití ANN pro klasifikaci multispektrálních snímků potvrdilo, že neuronové sítě fungují lépe než „tradiční“ metody a pokud jde o přesnost klasifikace, tak dosahují podobných výsledků jako dříve zmíněný klasifikátor maximální pravděpodobnosti (Yuan, 2009).

Support Vector Machine (SVM)

SVM jsou založeny na statistické teorii učení a mají za cíl určit umístění hranic rozhodování, které vedou k optimálnímu oddělení tříd. V případě problému rozpoznávání dvou tříd, kde jsou třídy lineárně oddělitelné, vybere SVM z nekonečného počtu lineárních rozhodovacích hranic tu, která minimalizuje chybu zobecnění. Vybraná hranice tedy bude ta, která ponechává největší rozpětí mezi dvěma třídami, kde rozpětí je definováno jako součet vzdáleností k nadrovině od nejbližších bodů obou tříd. Pokud tyto dvě třídy nejsou lineárně oddělitelné, SVM se pokusí najít nadrovinu, která maximalizuje rozpětí a zároveň minimalizuje množství úměrné počtu chyb nesprávné klasifikace. Kompromis mezi marží a chybnou klasifikací je řízen uživatelem definovanou konstantou. SVM lze také rozšířit o zpracování nelineárních rozhodovacích ploch (Pal, 2006).

Rozhodovací stromy

Rozhodovací stromy jsou definované jako klasifikační procedury, které rekurzivně rozdělují soubor dat do menších částí na základě sady testů definovaných v každé větvi nebo uzlu stromu. Strom se skládá z kořenového uzlu, ten tvoří všechna data, sady vnitřních uzlů a sady konečných uzlů. Každý uzel v rozhodovacím stromě má pouze jeden nadřazený uzel a dva nebo více uzlů podřízených. Pomocí této procedury je soubor dat klasifikován postupným dělením podle rozhodovacího rámce definovaného stromem a každému pozorování je přiřazen štítek

třídy podle koncového uzlu, do kterého spadá. Rozhodovací stromy mají oproti klasickým řízeným klasifikátorům výhodu v tom, že nevyžadují předpoklady týkající se distribuce vstupních dat, zvládají nelineární vztahy mezi funkcemi a třídami, doplňují chybějící hodnoty a jsou schopny zpracovat jak číselné, tak kategoriální vstupy. Neposlední výhodou je pak jasná klasifikační struktura a je proto snadné výsledky interpretovat (Friedl, 1997).

Deep Learning

Algoritmy hlubokého učení získávají v posledních letech velkou pozornost v rámci zpracování dat dálkového průzkumu Země. Hluboké učení pochází z umělých neuronových sítí, v podstatě se jedná o tzv. hluboké neuronové sítě, které mají mnoho různých vrstev. DL mají oproti neuronovým sítím díky přítomnosti více vrstev, větší přesnost, která je kompenzována delším časem při trénování hluboké sítě. Mezi modely doporučené pro využití v rámci DPZ lze zařadit Deep Belief Networks (DBN), Stacked Autoencoders (SAE), Generative Adversarial Networks (GAN), Recurrent Neural Networks (RNN), Convolution Neural Networks (CNN) (Lv, 2020; Cheng, 2020).

2.2.4 Postklasifikační úpravy a hodnocení přesnosti

Po dokončení klasifikačního procesu se ve výsledném obraze nachází velký počet osamocených pixelů nebo malých skupin pixelů zatříděných jinak než jejich okolí. Tento stav je důsledkem spektrálního chování jednotlivých tříd. U více tříd se překrývá a vzniklý snímek má obraz, který se nazývá „sůl a pepř“. Z tohoto důvodu po samotné klasifikaci přichází na řadu také postklasifikační úpravy (Dobrovolný, 1998).

K odstranění takto vzniklého obrazu se využívají vyhlazovací algoritmy, které fungují spíše na základě logických operací než jednoduchých aritmetických výpočtů. Jedním ze způsobů vyhlazování, je použití majoritních filtrů. Při použití takového filtru prochází pohyblivé okno přes sadu klasifikovaných dat a je určena většinová třída v rámci daného okna. Pokud středový pixel v okně není majoritní třída, je jeho identita změněna právě na třídu majoritní. Pokud v okně není žádná třída majoritní, identita středového pixelu se nemění. Při postupu okna datovou sadou se nepoužívají upravené kódy z předchozích pozic, ale původní kódy tříd (Lillesand, c2008).

Na konci celého procesu se nachází vyhodnocení přesnosti provedené klasifikace. Mezi možnosti hodnocení lze zařadit například matici chyb nebo Kappa koeficient.

Matice chyb (Error matrix) je jedním z často používaných způsobů pro určení přesnosti klasifikace dat DPZ. Matice chyb je čtvercové pole čísel v řádcích a sloupcích, které vyjadřuje

počet jednotek vzorku, to znamená pixelů nebo shluků pixelů, přiřazených do konkrétní kategorie vzhledem ke skutečnému stavu. Sloupce obvykle představují referenční data a řádky pak značí klasifikaci generovanou z dat DPZ. Skutečný stav lze získat například pozorováním nebo měřením na povrchu Země. Chybová matice je účinný způsob, jak znázornit přesnost klasifikace, protože přesnost každé kategorie je jasně popsána (Congalton, 1991).

Kappa koeficient je hodnota, která kvantitativně vyjadřuje přesnost výsledků automatické klasifikace. Tato hodnota porovnává klasifikaci náhodnou s klasifikací pomocí rozhodovacího pravidla. Samotný výpočet předpokládá správnost zařazení určitého procenta pixelů při čistě náhodném postupu umístování pixelů do jednotlivých tříd. Výsledná hodnota koeficientu se pohybuje mezi hodnotami 0 a 1. Pokud výsledná hodnota bude 0,8, znamená to, že klasifikátor se vyhnul 80 % chyb, které by nastaly při náhodném umístění do jednotlivých tříd. Minimální počet pixelů, který je potřebný pro odhad průměrné přesnosti třídy $\pm 5\%$ je 250 (Dobrovolný, 1998; Halounová, 2005).

2.3 Shrnutí stávajícího stavu

V následující podkapitole je vybráno několik studií, které se zabývají detekcí změn v krajině a klasifikaci obrazů dálkového průzkumu Země. Jedná se o studie, které klasifikují základní typy zemského pokryvu.

Studie 1 – Posouzení metod detekce změn LULC a hodnocení přesnosti

Studie se zabývá porovnáním vybraných metod klasifikace obrazu DPZ. Autoři vybrali do případové studie následující klasifikační techniky: SVM, Maximum likelihood classifier, Neural network, Mahalanobis distance, Minimum distance, Spectral angle mapper, Spectral information divergence a Parrallelepiped classification. Tyto jednotlivé techniky následně aplikovali na vybrané území národního parku Khirthar v Pákistánu. Data byla pořízena z družice Landsat 8. Jako klasifikované třídy byly vybrány: urbanizované oblasti, voda, les a zemědělská půda. Následující tabulka č. 3 ukazuje výsledky klasifikace.

Tabulka 3: Hodnocení přesnosti studie 1

Klasifikátor	Klasifikované/ celkové pixely	Celková přesnost [%]	Kappa koeficient
SVM	2376/2433	97,65	0,96
Maximum likelihood	2371/2433	97,45	0,96
Neural network	2359/2433	96,95	0,95
Mahalanobis distance	2228/2433	91,57	0,87
Minimum distance	2033/2433	83,55	0,76

Spectral angle mapper	1934/2433	79,49	0,70
Spectral information divergence	1928/2433	79,24	0,70
Parallelepiped classification	1676/2433	68,88	0,52

Zdroj: Zpracováno dle (Chughtai, 2021)

Studie 2 – Multi-temporální analýza obrazu pro klasifikaci LULC a detekce změn

Tato studie se zaměřuje na využití GIS a využívání půdy. Cílem je identifikace změn v oblasti Ananthapur v jižní Indii na základě průzkumu topografické mapy Indie a obrazů shromážděných z družic Landsat. Jako třídy zde byly zvoleny lesy, zemědělská půda, voda, urbanizovaná oblast a ostatní půda. Jako klasifikátor byl pak zvolen Maximum likelihood classifier. Výsledky přesnosti klasifikace ukazuje tabulka č. 4.

Tabulka 4: Hodnocení přesnosti studie 2

Rok	Přesnost klasifikace [%]	Kappa koeficient
1978	81,25	0,785
2018	87,46	0,857

Zdroj: Zpracováno dle (Vivekananda, 2021)

Studie 3 - Studium klasifikace využití půdy v aridním regionu pomocí multispektrálních satelitních snímků

Tato studie zkoumá varianty využívání půdy ve vyprahlé oblasti s využitím snímků pořízených družicemi Liss-III a Landsat TM pomocí již několikrát zmíněné techniky Maximum likelihood. Využití pozemků bylo rozděleno do pěti hlavních tříd. Jedná se o zemědělskou půdu, zastavěnou oblast, pustinu, lesy a vodu. V rámci studie byly zjištěny významné změny v oblasti zemědělské půdy a lesů v důsledku několika faktorů jako jsou například nárůst populace, sucho, rozvoj silniční infrastruktury a dalších. Tabulka 5 ukazuje výsledky hodnocení této klasifikace.

Tabulka 5: Hodnocení přesnosti studie 3

Rok	Přesnost klasifikace [%]	Kappa koeficient
2008	92,32	0,94
2015	94,13	0,93

Zdroj: Zpracováno dle (Pande, 2018)

Studie 4 – Detekce změn pobřežních mokřadů pomocí vysokého prostorového rozlišení snímku družice Kompsat-2

Studie představuje metodu mapování a monitorování změn LULC v pobřeží pomocí klasifikace multispektrálních obrazů získaných z Korejské družice Kompsat-2. Změny mokřadů jsou

monitorovány ve třech různých oblastech na pobřeží Žlutého moře v období 2008-2015 (viz. Tabulka 6). Výsledná klasifikace se týká vody, mokřadů, lesů, zemědělské půdy a urbanizovaného území a byla provedena pomocí neřízené klasifikační metody ISODATA.

Tabulka 6: Hodnocení přesnosti studie 4

Místo	Rok	Přesnost klasifikace [%]	Kappa koeficient
Gyeonggi	2009	95,40	0,93
	2015	94,04	0,92
Jeonbuk	2009	90,04	0,85
	2014	87,60	0,82
Jeonnam	2008	88,70	0,85
	2014	91,30	0,88

Zdroj: Zpracováno dle (Sunwoo, 2018)

Studie 5 – Analýza detekce změn LULC oblasti Bostanlik, Uzbekistán

Následující studie prezentuje analýzu detekce změn dvou multispektrálních datových sad pro oblast Bostanlik. Zdrojem dat byla družice Landsat-5 v případě dat z roku 1989 a Landsat-8 pro data z roku 2017 (viz. Tabulka 7). V obou případech pak byla využita technika Maximum likelihood, pomocí které byla provedena klasifikace tříd: sníh, holá půda, les, voda, urbanizovaná oblast a zemědělská půda. Studie prezentuje významné změny v třídách lesy, urbanizované území, holá půda a sněhová pokrývka.

Tabulka 7: Hodnocení přesnosti studie 5

Rok	Přesnost klasifikace [%]	Kappa koeficient
1989	90,91	0,88
2017	80,49	0,75

Zdroj: Zpracováno dle (Juliev, 2019)

Studie 6 – Porovnání přesnosti klasifikace LC pomocí multispektrálních snímků Landsat-8 a Pleiades s využitím dvou různých klasifikačních schémat

Cílem této studie je porovnat výsledky multispektrální klasifikace pomocí techniky Maximum likelihood pro generování map LC, založených na snímcích Landsat-8 a Pleiades. Klasifikace je rovněž zaměřena na dvě různá klasifikační schémata. První se týká spektrálních a druhé prostorových dimenzí (viz. Obrázek 6). Výsledky ukázaly, že multispektrální klasifikace v rámci spektrálního schématu aplikovaná na data družice Pleiades, poskytla vyšší celkovou přesnost ve srovnání s Landsat-8 (viz. Tabulka 8).

Tabulka 8: Hodnocení přesnosti studie 6

Schéma	Družice	Přesnost klasifikace [%]	Kappa koeficient
C – Spektrální	Landsat-8	66,28	0,59
	Pleiades	81,70	0,77
S – Prostorové	Landsat-8	69,59	0,65
	Pleiades	64,60	0,62

Zdroj: Zpracováno dle (Putri, 2019)

Spectral related cover dimension		Spatial dimension	
Code	Class object	Code	Class object
C11	Deep water	S11	Sea
C12	Shallow water	S12	Lake
C22	Woody broadleaves	S13	River and channel
C22	Non-woody broadleaves	S21	Block coverage vegetation
C31	Bare soil, dry	S22	Field pattern
C32	Bare soil, moist	S24	Other vegetation feature with specific shapes
C41	Asphalt, concrete and cemented surface	S31	Coastal barren land
C42	Compacted clay surface	S41	Built-up area, whether isolated or not
		S43	Built-up features with linear shapes

Obrázek 6: Třídy klasifikace studie 6

Zdroj: (Putri, 2019)

Studie 7 – Časoprostorová analýza satelitních snímků Landsat pro detekci změn v lesním ekosystému Česma

Studie se zabývá detekcí a analýzou změn v lesní oblasti Česma u Vrbovce v Chorvatsku. V rámci studie jsou použity vegetační indexy NDVI, NDWI, GNDVI, EVI a SAVI. Autoři využívají satelitní snímky pořízené družicemi Landsat 7 a Landsat 8. Při stanovování vegetačních indexů využívají autoři jak nezpracované snímky, tak i snímky, které byly upraveny pomocí radiometrické korekce DOS1.

Výzkum potvrdil, že EVI nelze využít pro snímky bez využití radiometrické korekce. U ostatních indexů toto tvrzení neplatí a lze je využít na ne předzpracovaná data, což umožňuje snadnější zpracování obsáhlých dat na větších plochách. Závěrem studie pak upozorňuje na fakt, že predikce vývoje lesních ekosystémů na základě podrobné analýzy s využitím vegetačních indexů je možná (Vela, 2020).

Studie 8 - Vzájemné srovnání mezi vegetačními indexy odvozenými od Landsat 8 (OLI) a Landsat 7 (ETM+) ve středomořském prostředí

Studie je založena na vyhodnocení specifických inter-kalibračních funkcí pro standardizaci hlavních vegetačních indexů vypočítaných ze snímků pořízených dvěma generacemi družic Landsat s ohledem na hlavní typy využití půdy. Mezi sledované indexy se řadí NDVI, NDWI, LSWI, NBR, VIgreen, SAVI a EVI, které jsou aplikovány na snímky Landsat (viz. Tabulka 9).

Studijní oblastí je region Basilicata, který se nachází v jižní části Itálie, a byl vybrán jako vysoce reprezentující středomořské prostředí. Výsledky ukazují mírné rozdíly v hodnotách průměrné odrazivosti pro každé pásmo. Z hlediska klasifikace dle jednotlivých tříd využití půdy byly zjištěny statisticky významné rozdíly pro téměř všechny zmíněné indexy (Mancino, 2020).

Tabulka 9: Výsledky studie 8

Vegetační index	Průměrná hodnota – Landsat 7	Průměrná hodnota – Landsat 8
NDVI	0,4985	0,6215
NDWI	-0,6337	-0,6842
NBR	1,2542	0,4088
LSWI	0,0831	0,1652
VIgreen	-0,1919	-0,0543
SAVI	0,4909	0,4183
EVI	0,3051	0,4072

Zdroj: Zpracováno dle (Mancino, 2020)

Vybrané studie potvrzují časté využití metody Maximum likelihood, které je dle některých zdrojů považováno za vůbec nejběžněji využívanou metodou klasifikace. Mezi další často využívané metody pak lze zahrnout Minimum distance, ISODATA nebo také Neuronové sítě. Nelze opomenout ani možnost využití vegetačních indexů, pomocí kterých lze snadno určit požadovaný typ pokryvu, který koresponduje s účelem vybraného indexu. Mezi často využívaný zdroj dat pak jednoznačně patří družice Landsat.

3 CHARAKTERISTIKA ZÁJMOVÉHO ÚZEMÍ, POUŽITÉ METODY, DATA A SOFTWARE

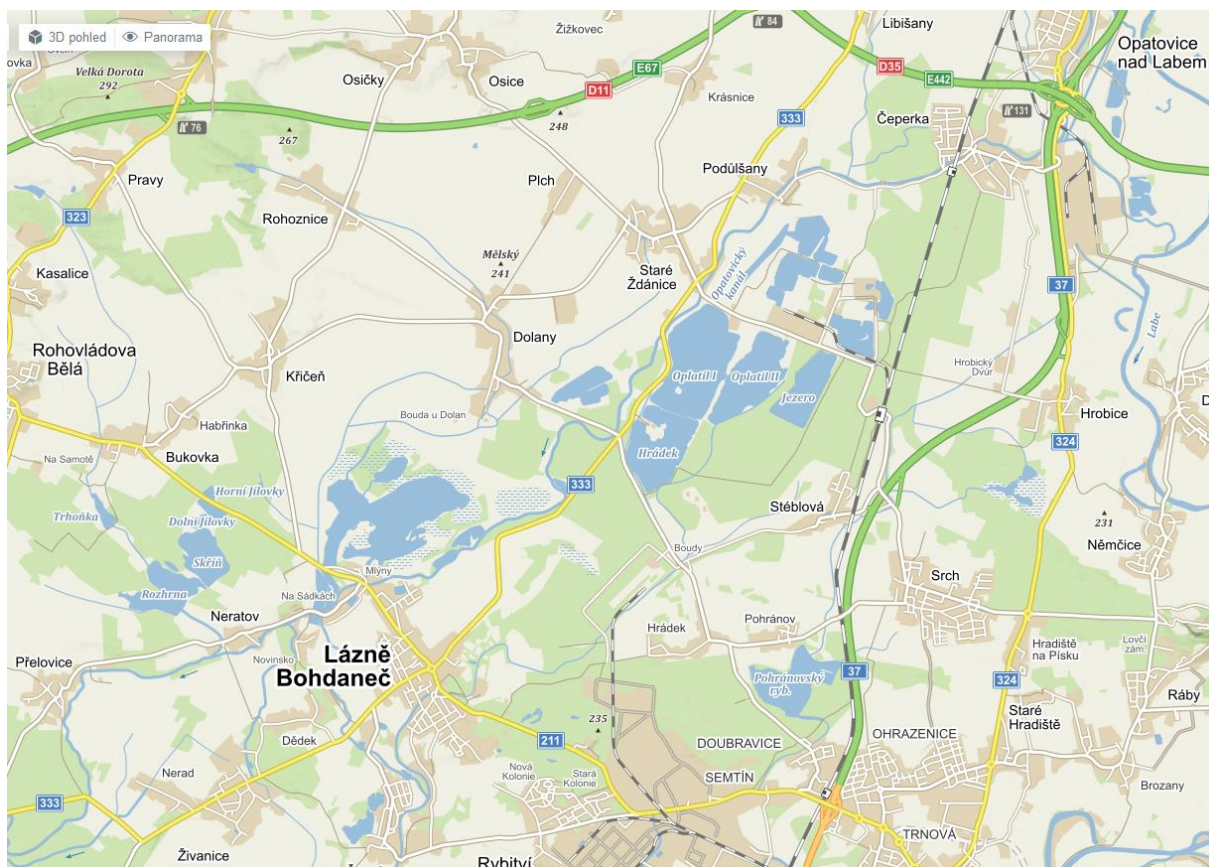
Následující kapitola se věnuje popisu vybraného zájmového území a také způsobu výběru a stažení samotných dat, týkajících se této oblasti. Pro zpracování práce byl navržen následující postup.

1. Výběr zájmového území
 - a. Zvolení požadovaného území
 - b. Definice požadavků na data (družice, pokrytí mraky, období)
 - c. Stažení dat obsahujících korekce
2. Předzpracování dat
 - a. Oříznutí snímků na požadované území
 - b. Sloučení jednotlivých pásem
3. Klasifikace stažených dat
 - a. Výběr vegetačních indexů a dalších klasifikátorů
 - b. Klasifikace typů pokryvu zájmového území
4. Hodnocení přesnosti klasifikace
 - a. Výběr hodnotících technik
 - b. Definování testovacích bodů
 - c. Výpočet zvolených hodnotících technik
5. Vizualizace a interpretace výsledků
 - a. Tvorba kartografických výstupů
 - b. Detekce změn v krajinném pokryvu

3.1 Charakteristika zájmového území

Identifikace změn se zaměřuje na vybrané zájmové území v blízkosti města Pardubice. Hlavní podstatou je klasifikace změn zahrnující oblast rybníků mezi Pardubicemi a Opatovicemi nad Labem, která zahrnuje i rybníky Skříň a Baroch nad kterými provádí Ústav systémového inženýrství a informatiky univerzity Pardubice pravidelný sběr dat (viz. Obrázek 7).

Území se vyznačuje rovinnou oblastí, výskytem vodních ploch, lesů, zemědělské půdy i zastavěných oblastí.



Obrázek 7: Zájmová oblast

Zdroj: Mapy.cz

3.2 Použitá data

Samotná data se týkají vybraného území ve vegetačním období, zahrnující měsíce květen, červen, červenec a srpen v roce 2021, které umožňují nejlepší výsledky klasifikace. Jako zdroje dat jsou vybrány družice Landsat-8 a Sentinel-2.

Družice Landsat-8 poskytuje více různých datových sad, které mohou uživatelé použít v jedenácti spektrálních pásmech (viz. Tabulka 10). V této práci se konkrétně jedná o data Landsat 8 OLI/TIRS Collection 2 Level-2. Tato datová sada se vyznačuje tím, že jsou data již upravena pomocí atmosférických korekcí a není tedy nutné tyto korekce provádět.

Tabulka 10: Spektrální pásma družice Landsat-8

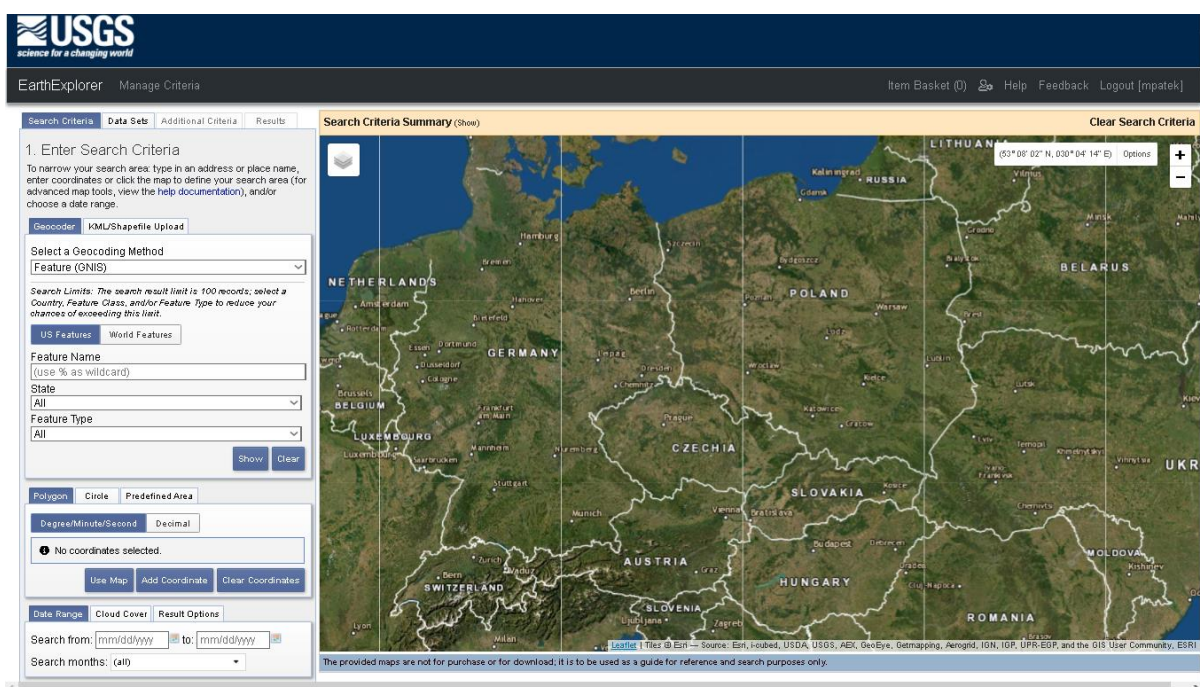
Pásma	Vlnová délka [μm]	Spektrální rozlišení [m]
1 – Aerosol	0,43-0,45	30
2 – Modré	0,45-0,51	30
3 – Zelené	0,53-0,59	30
4 – Červené	0,64-0,67	30

5 – Blízké infračervené (NIR)	0,85-0,88	30
6 – Krátkovlnné infračervené (SWIR1)	1,57-1,65	30
7 – Krátkovlnné infračervené (SWIR2)	2,11-2,29	30
8 – Panchromatické	0,50-0,68	15
9 – Oblačné	1,36-1,38	30
10 – Termální infračervené (TIRS 1)	10,6-11,19	100
11 – Termální infračervené (TIRS 2)	11,50-12,51	100

Zdroj: (What are the band designations for the Landsat satellites?)

Družice Sentinel-2 je evropská širokopásmová družice sloužící k multispektrálnímu snímkování. Využívá celkem 13 spektrálních pásem, z toho čtyři základní (pásma RGB a pásmo NIR) mají rozlišení 10 metrů. Využitá data z portálu Earth Explorer jsou zpracována na úrovni C1, to znamená, že již obsahují radiometrické a geometrické korekce a není tedy opět nutné tyto korekce provádět (USGS EROS Archive – Sentinel-2, 2018).

Samotná data jsou poté získána z portálu <https://earthexplorer.usgs.gov> (viz. Obrázek 8). Ke stažení dat je nutné, aby se uživatel zaregistroval. Po registraci a přihlášení do portálu je možné vybírat kritéria, podle kterých budou následně vyhledána data v databázi.



Obrázek 8: Úvodní obrazovka webu Earth Explorer

Zdroj: (USGS)

Na úvodní obrazovce je uživateli umožněno vybírat jednotlivá kritéria. Mezi hlavní volená kritéria pak patří zejména zájmová oblast, datum pořízení snímku a také pokrytí snímku mraky. Poslední zmíněné kritérium je velmi důležité, protože vysoké procento pokrytí snímku mraky

uživateli znemožní další práci, kterou se chystá se snímkem vykonat. V tomto případě pak může zcela zamezit celé klasifikaci území.

Po vybrání zájmového území a ostatních požadovaných kritérií dochází k výběru datové sady, tedy družice, která bude využita. V tomto případě bylo takto stanoveno zájmové území v časovém období 1.5.2021 – 31.8.2021. Jak bylo zmíněno výše, datové sady se týkají družic Landsat-8 a Sentinel-2. Následující tabulka č. 11 popisuje procento pokrytí mraky jednotlivých získaných snímků, jedná se o dostupné snímky s nejnižším procentem pokrytí mraky v daném měsíci.

Tabulka 11: Procentuální pokrytí snímku mraky

Družice	Pokrytí snímku mraky za jednotlivé měsíce [%]			
	Květen	Červen	Červenec	Srpen
Landsat-8	84,52	18,17	33,66	35,43
Sentinel-2	11,36	3,03	6,66	1,63

Zdroj: zpracováno dle stažených dat

Z této tabulky vyplývá, že při snímání požadovaného území, bylo pokrytí mraky výrazně nižší při průletu družice Sentinel-2. Další postup zpracování je proveden na 7 různých snímcích, a to z toho důvodu, že kvůli velmi vysokému podílu mraků na snímku z družice Landsat v květnu, není možné tento snímek dále využít. U snímků z července a srpna je rovněž vyšší pokrytí mraky, než byla původně volená hranice 25 %. V těchto dvou případech se může stát, že po oříznutí snímků na požadované zájmové území bude pokrytí mraky již přijatelné, a proto budou dále zpracována.

3.3 Použité metody a software

V této práci je využito několik metod, které jsou určeny jak pro předzpracování, klasifikaci tak i hodnocení přesnosti klasifikace zdrojových dat a následnou vizualizaci výsledků. Pro zpracování této práce jsou využity aplikace dostupné v rámci balíku MS Office 365 a dále software ArcGIS Desktop 10.5.1 od společnosti ESRI, který je nejvhodnější k použití v tomto konkrétním případě, a to vzhledem k získání základní znalosti a orientace v programovém prostředí během cvičení v rámci školní výuky předmětů Geografické informační systémy a Kartografie. Další výhodou pro zvolení tohoto produktu je také možnost využití školní licence.

Mezi metody použité v rámci předzpracování dat patří prostorové dotazy na data. To znamená nástroje pro tvorbu polygonu, dále nástroje určené pro ořez dat a spojování rastrů. Mezi další

použité metody lze zařadit nástroje pro výpočet vegetačních indexů (jedná se o integrovaný nástroj pro výpočet indexu NDVI a kalkulátor rastrů pro index NDWI) a zvolené klasifikátory.

Mezi vybrané nástroje pro hodnocení přesnosti klasifikace patří nástroje pro náhodné generování testovacích bodů a nástroj pro výpočet matice chyb a kappu koeficientu.

Pro vizualizaci výsledků je využito možností tvorby tabulek a grafů pomocí softwaru MS Office a dále možnosti SW ArcGIS Desktop pro tvorbu kartografických výstupů.

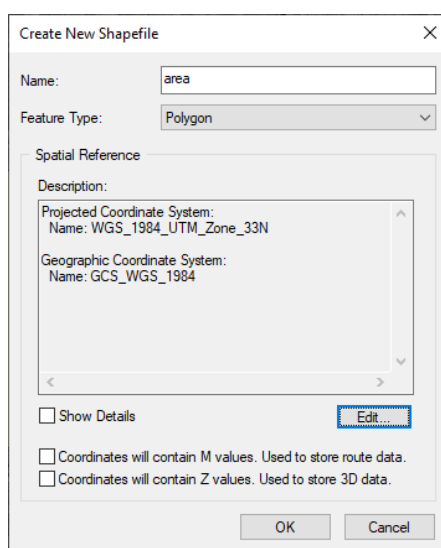
4 IDENTIFIKACE ZMĚN ZÁJMOVÉHO ÚZEMÍ

V této kapitole se již zaměřím na samotnou klasifikaci a identifikaci změn zájmového území. Před začátkem klasifikace a výpočtu vegetačních indexů je potřeba stažená data (dle předcházející kapitoly) upravit tak, aby byla vhodná pro další použití. Jelikož jsou data upravena pomocí korekcí, není potřeba již tyto úpravy provádět. Hlavní úpravou tedy zůstává oříznutí původních rozsáhlých dat na zájmovou oblast.

4.1 Příprava dat

Oříznutí snímků je možné několika způsoby. Vybraný způsob se týká vytvoření nového shapefilu, který vzniká přidáním jednotlivých bodů dle souřadnic, aby bylo zájmové území definováno co nejpřesněji. Před samotným vytvořením polygonu tímto způsobem je důležité vyhledat, jaký souřadnicový systém používají stažená data. Data použitá v této diplomové práci používají souřadnicový systém WGS 1984 UTM Zone 33N. Jedná se o souřadnicový WGS 84 využívající Mercatorovo válcové konformní zobrazení a základní poledník 15°.

Po zjištění potřebného souřadnicového systému začíná tvorba polygonu (viz. Obrázek 9), který bude sloužit pro oříznutí všech snímků.



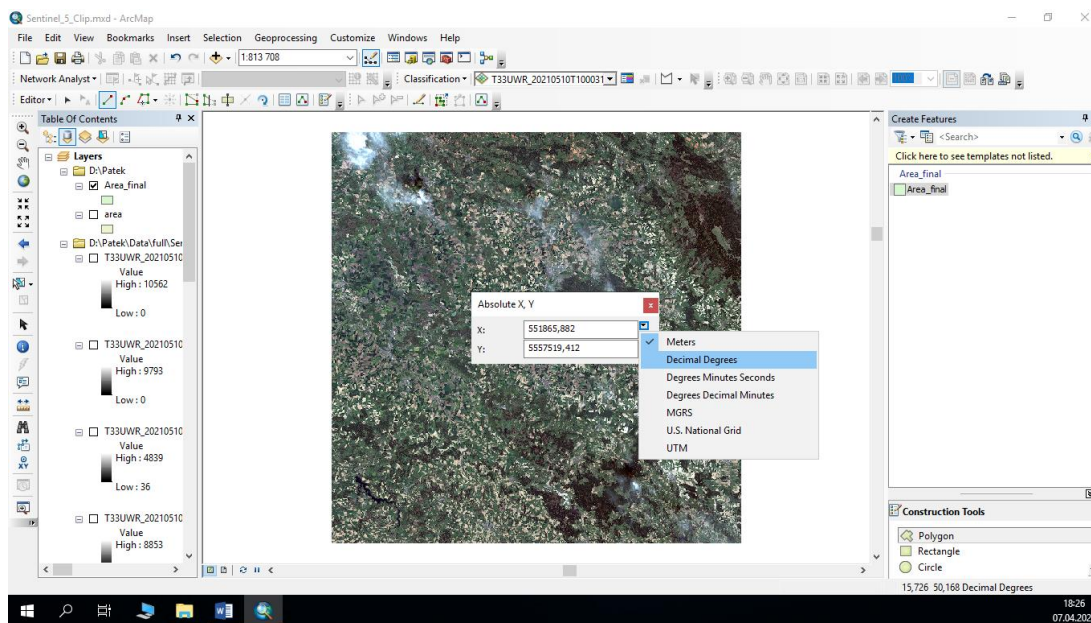
Obrázek 9: Tvorba polygonu pro ořez dat

Zdroj: vlastní zpracování

Po vytvoření nového shapefilu je potřeba přiřadit jednotlivé body (v tomto případě souřadnice), které označují konkrétní body, mezi nimiž vznikne výsledný polygon. K vytvoření těchto bodů je nejprve nutné zapnout režim editace a následně otevřít nabídku „Create Features“. Jakmile jsou tyto kroky provedeny, nebrání nic samotné tvorbě jednotlivých bodů. Přesné souřadnice

vybraných bodů lze zadat pomocí kliknutí pravým tlačítkem myši a výběru možnosti „Absolute X,Y...“ nebo pomocí klávesy F6.


Při následné definici souřadnic jednotlivých bodů je důležité správně zvolit jednotky, ve kterých se hodnoty zadávají. Protože, v tomto případě zjištěné, souřadnice mají podobu stupňů v decimální formě, je potřeba přepnout jednotky na možnost „Decimal Degrees“ (viz. Obrázek 10).



Obrázek 10: Tvorba bodů polygonu

Zdroj: vlastní zpracování

Jakmile jsou vybrány veškeré potřebné body, přichází na řadu ukončení editace pomocí klávesy F2. Po ukončení editace vzniká požadovaný polygon, který lze vidět na obrázku č. 11.



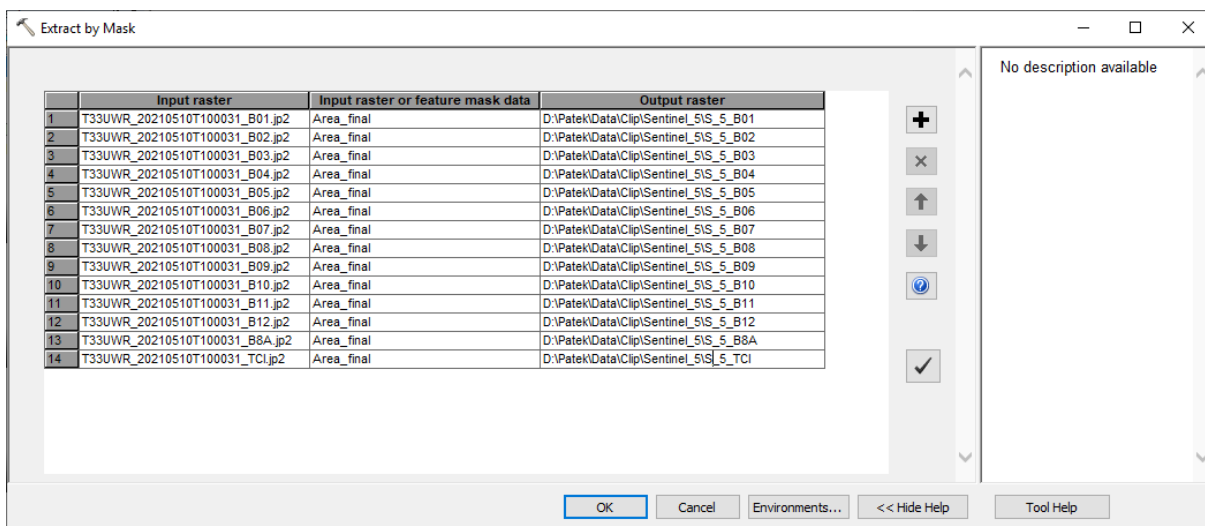
Obrázek 11: Výsledný polygon

Zdroj: vlastní zpracování

Po vytvoření samotného polygonu přichází na řadu oříznutí snímků dle vybraných období. K tomuto účelu je využito nástroje „Extract by Mask“, který je v prostředí ArcGIS Desktop dostupný v rámci nástrojů „Spatial Analyst Tools“, konkrétně v sekci „Extraction“.

Pomocí tohoto nástroje lze ořezávat jednotlivé vrstvy (spektrální pásma) zvlášť, nebo je možné využít tzv. „Batch“, kde lze všechna tato pásma oříznout najednou.


Na obrázku č. 12 níže lze vidět příklad ořezu všech pásem družice Sentinel. V prvním sloupci jsou vybrána jednotlivá pásma původních dat. Ve druhém sloupci je vybrán dříve vytvořený polygon a poslední sloupec pak slouží k definování, místa a názvu vzniklého rastru.



Obrázek 12: Nástroj Extract by Mask (Batch)

Zdroj: vlastní zpracování

Výsledkem tohoto kroku jsou oříznutá data, která kopírují zvolenou oblast zájmu.



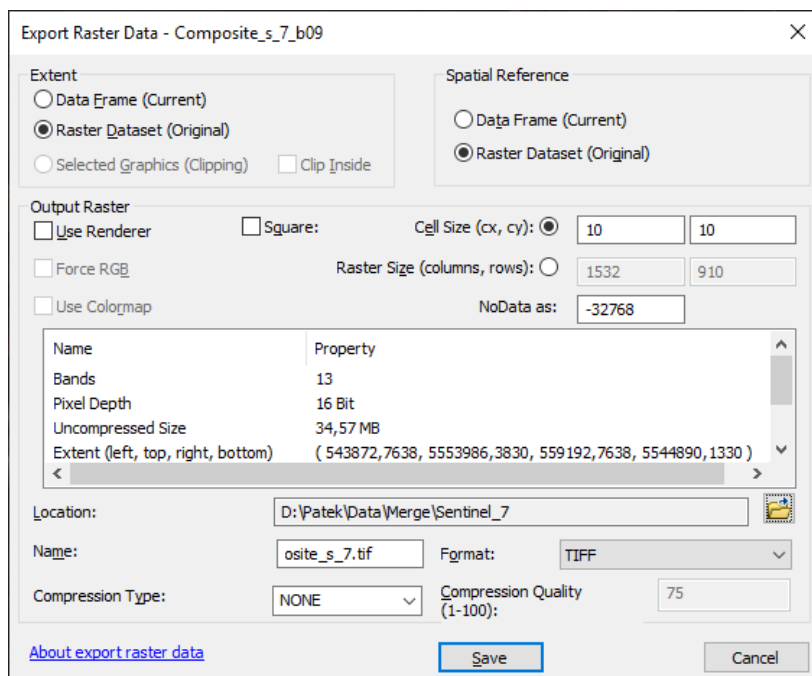
Obrázek 13: Oříznutá data Landsat – červenec

Zdroj: vlastní zpracování

Při zpracování dat družice Landsat bylo zjištěno, že kromě snímku z května obsahuje většina ořezaných snímků tak vysoký podíl mraků (viz. Obrázek 13), že nejsou vhodné pro další použití, z tohoto důvodu je využit alespoň jeden snímek družice Landsat, aby bylo možné porovnat, jakých rozdílů může být dosaženo mezi družicemi s různým prostorovým rozlišením.

Protože jsou jednotlivá pásma rozdělena v jednotlivých souborech, je následujícím krokem vytvoření jednoho snímku, který bude obsahovat tato jednotlivá pásma. Tento krok je potřebný pro možnost využití vestavěné funkce výpočtu vegetačního indexu NDVI a provádí se pomocí funkce „Composite Bands“ v rámci nástrojů „Image Analysis“.

Při otevření nabídky „Image Analysis“ se v její vrchní části zobrazují jednotlivé vrstvy, které jsou v programu nahrány. Jednotlivé vrstvy, které jsou požadovány pro sloučení je nejprve nutné v této části označit a poté kliknout na možnost „Composite Bands“. Na obrázku 14 lze vidět nastavení možností slučování rastrů. Důležitou roli v tomto případě hraje zachování velikosti pixelů dle původních dat. Z tohoto důvodu je nutné znát rozlišení pixelů u dat využívaných dle jednotlivých družic. Pro družici Landsat platí rozlišení 30 m a pro družici Sentinel pak 10 m. Další důležitou možností je nastavení prostorové reference, výběr formátu, ve kterém má být výstupní rastr uložen a také umístění a název výsledného rastru. Takto exportovaná data jsou již zcela připravena ke klasifikaci.



Obrázek 14: Ukázka nastavení nástroje Composite Bands

Zdroj: vlastní zpracování

4.2 Klasifikace zájmového území

Pro tuto práci byly na základě literatury a výše zmíněných studií vybrány 2 vegetační indexy a 2 metody klasifikace. Mezi vybrané vegetační indexy se řadí NDVI a NDWI. Jako zástupce řízené klasifikace je zvolen klasifikátor Maximum Likelihood a ISODATA jako klasifikátor neřízený.

4.2.1 Vegetační indexy

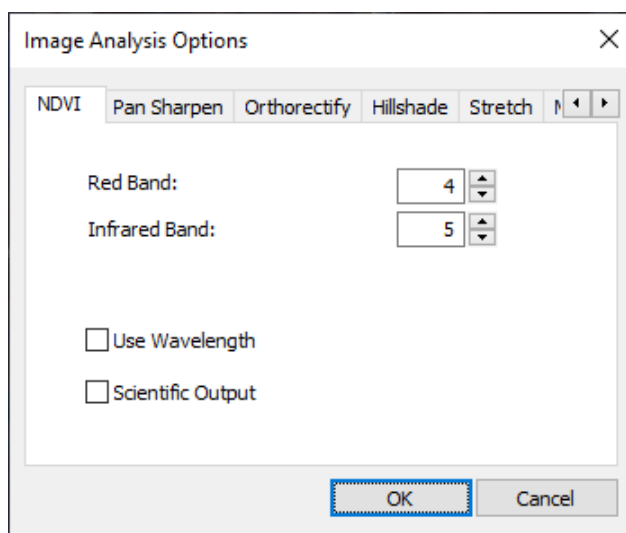
Prvním vybraným indexem je vegetační index NDVI. Jedná se o index zaměřený na vegetaci, nabývající hodnot od -1 do 1. Čím vyšší je výsledná hodnota, tím větší je výsledná hustota zeleně.

Samotný výpočet je již zahrnut v rámci programového prostředí ArcGIS Desktop. Z tohoto důvodu není nutné počítat rovnici viz. Tabulka 1: Vegetační indexy Jak bylo zmíněno v části vytváření jednotného rastru, možnost výpočtu indexu NDVI lze provést v rámci „Image Analysis“.

Před samotným spuštěním je nejprve potřeba správně ve vrchní části nastavit, které pásmo je červené, a které je blízké infračervené.

Správné nastavení těchto čísel opět vychází ze znalostí získaných při stažení dat. Pokud se jedná o družici Landsat, tak červené pásmo je pásmo čtvrté a NIR je pásmo páté (viz. Obrázek 15).

Při využití dat z družice Sentinel-2 pak jsou hodnoty čtyři a osm ve stejném pořadí.




Obrázek 15: Nastavení Image Analysis

Zdroj: vlastní zpracování

Při špatném nastavení těchto pásem nelze index NDVI spočítat a aplikace uživatele upozorní, že jsou tyto hodnoty zadány špatně. Pokud je nastavení v pořádku, nic nebrání vybrání vrstvy, na které bude index počítán a výběru možnosti NDVI ve spodní části nabídky.

Na obrázku č. 16 lze již vidět vypočítaný index, který má ještě upravené zobrazení barev pro lepší přehlednost. Z obrázku lze snadno vyčíst, ve kterých částech se jedná o území, na kterém se zeleň nachází a na kterém ne.

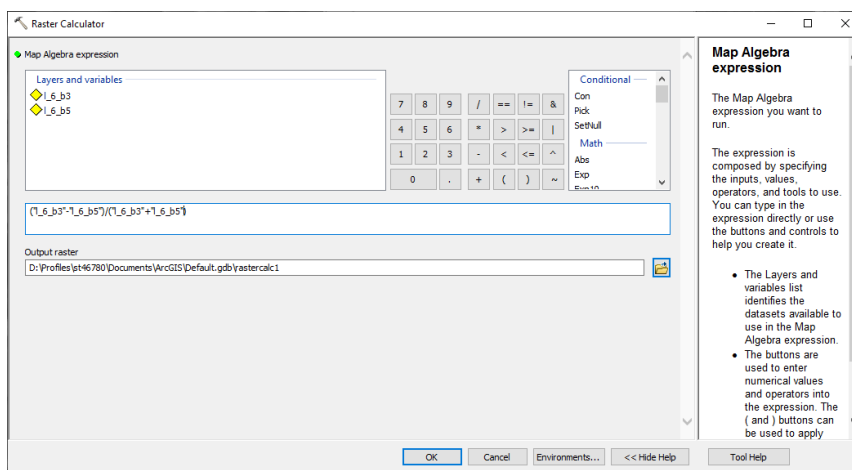


Obrázek 16: Index NDVI na snímku z družice Sentinel

Zdroj: vlastní zpracování

Druhým vybraným indexem je NDWI, který se místo vegetace zaměřuje na zobrazení vodních ploch. Tento index rovněž nabývá hodnot od -1 do 1. Z důvodu absence integrovaného výpočtu v prostředí ArcGIS Desktop je nutné využít nástroje pro výpočet rastru na základě definované rovnice. Tento nástroj se opět nachází v rámci „Spatial Analyst Tools“, tentokrát ale v sekci „Map Algebra“. Nástroj „Raster Calculator“ po otevření umožňuje vytvořit požadovanou rovnici, která má být použita pro výsledný rastr (viz. Obrázek 17). Na základě rovnice zmíněné v tabulce č. 1 je opět nutné znát, která pásma je potřeba využít pro daný výpočet. Index NDWI využívá pro výpočet pásma zelené a blízké infračervené.

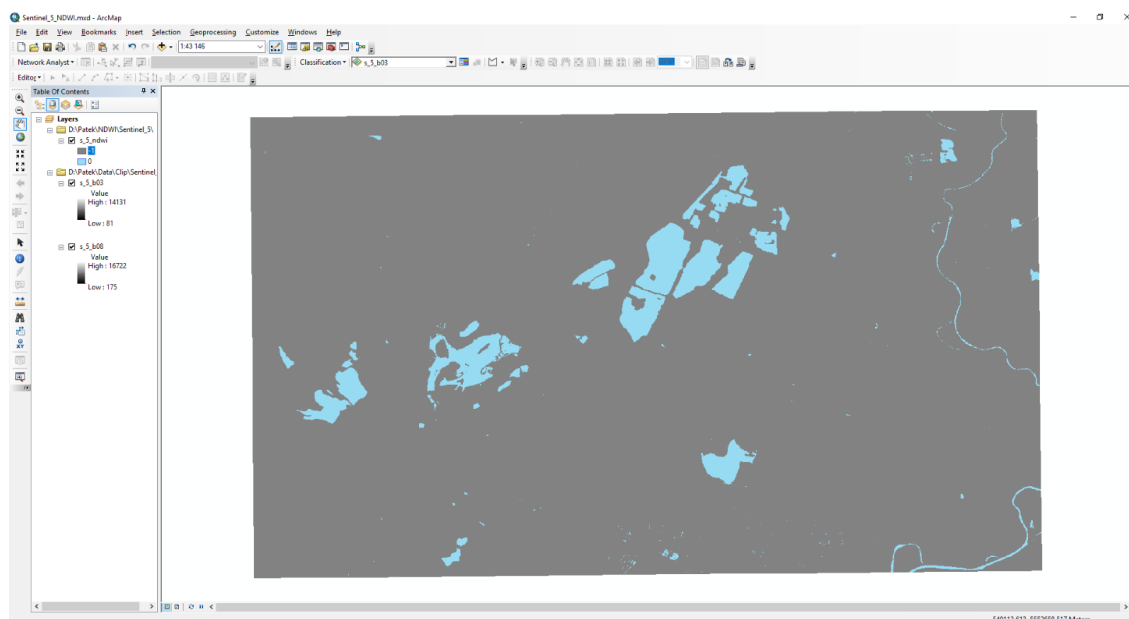
Prvním krokem výpočtu je načtení požadovaných dat do prostředí softwaru. Jedná se tedy o pásma 3 a 5 pro výpočet nad daty Landsat nebo pásma 3 a 8 pro výpočet nad daty družice Sentinel. Na obrázku níže lze vidět sestavení výpočtu pro data pořízená družicí Landsat.



Obrázek 17: Výpočet indexu NDWI pomocí nástroje Raster Calculator

Zdroj: vlastní zpracování

Výsledkem toho výpočtu je zájmová oblast, která je reprezentována pouze dvěma kategoriemi. První kategorií je plocha, jejíž pokryv není voda. Na obrázku 18 je reprezentována šedou barvou. Druhou kategorií jsou vodní plochy (barva modrá).



Obrázek 18: Index NDWI nad daty družice Landsat

Zdroj: vlastní zpracování

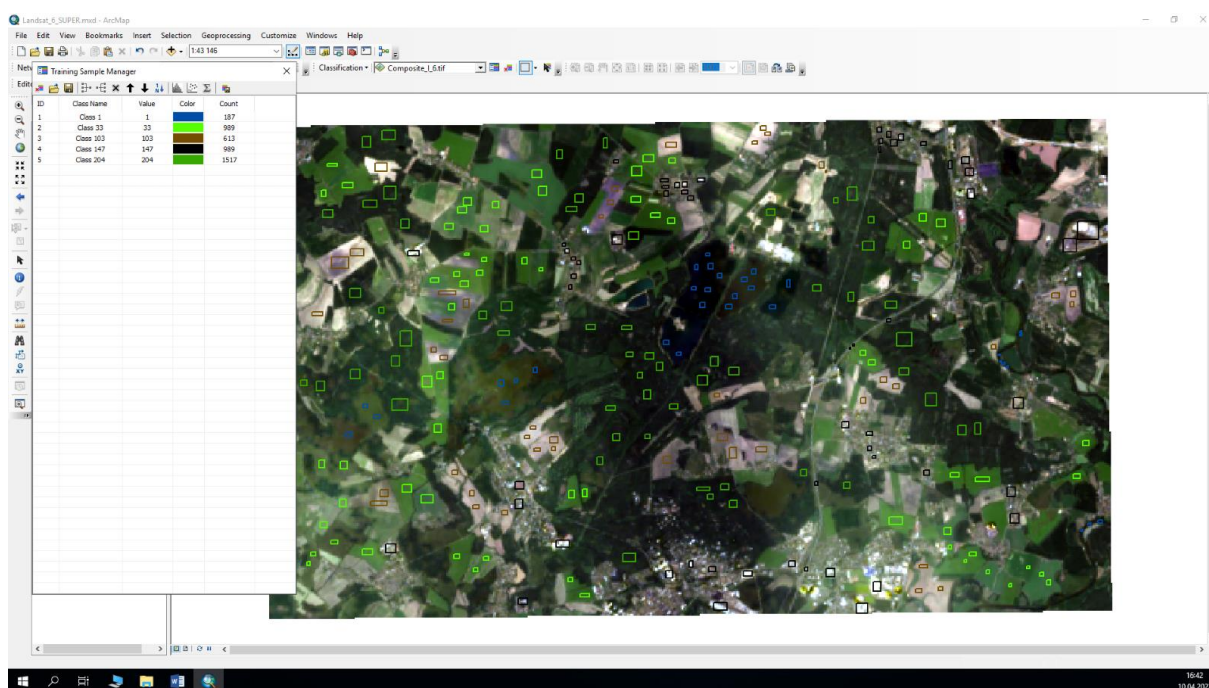
4.2.2 Řízená klasifikace

Tato podkapitola se zabývá procesem řízené klasifikace za použití klasifikátoru Maximum Likelihood. Tento klasifikátor je stejně jako index NDVI přímo integrován v prostředí ArcGIS Desktop.

Protože se jedná o metodu řízené klasifikace, je před samotným spuštěním klasifikace potřeba vytvořit trénovací sadu, na jejímž základě bude klasifikátor pracovat. Vytvoření trénovací sady

probíhá pomocí vybírání pixelů pomocí nástroje „Training Sample Manager“ (viz. Obrázek 19) v rámci nástroje „Image Classification“. Pixely jsou vybrány z původních dat podle pozemní znalosti území pomocí čtyřúhelníku.

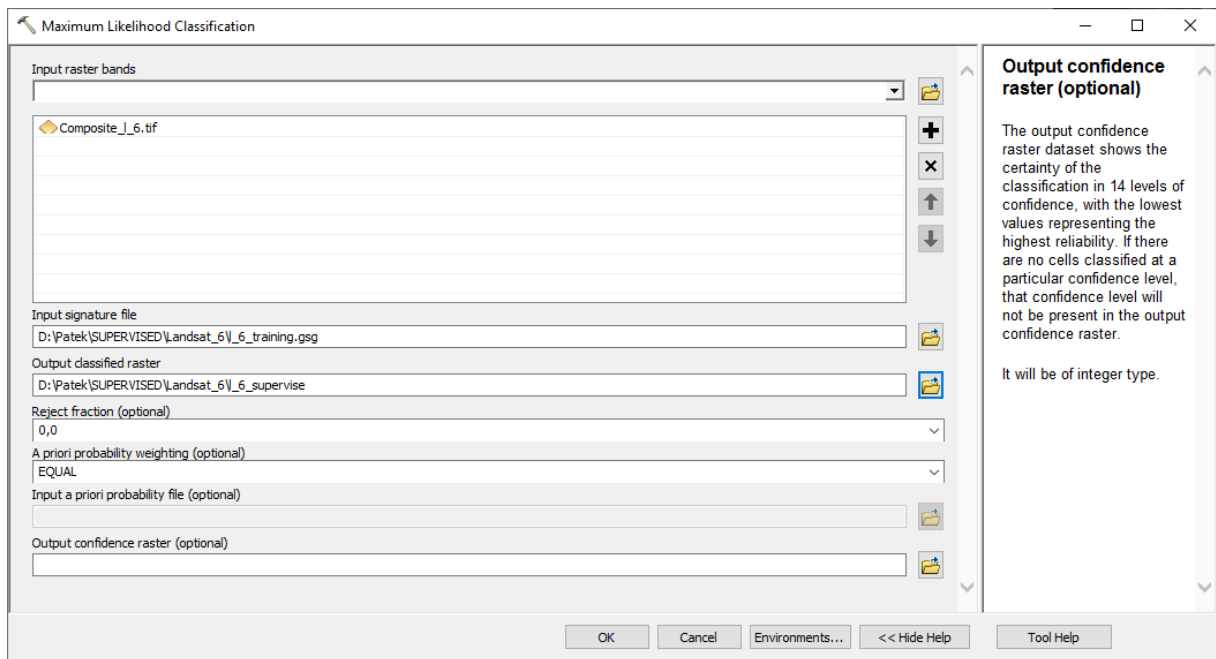
Nejprve je vybrána jedna kategorie, např. voda, pro kterou jsou vybrána trénovací data. Na snímku jsou vybrána území obsahující danou třídu, která bude cílem klasifikace a jednotlivé skupiny pixelů jsou následně sloučeny do jedné třídy pomocí tlačítka „Merge“ přímo v okně „Training Sample Manager“. Tímto způsobem dochází k výběru trénovacích dat pro všechny stanovené výsledné kategorie.



Obrázek 19: Výběr trénovacích dat

Zdroj: vlastní zpracování

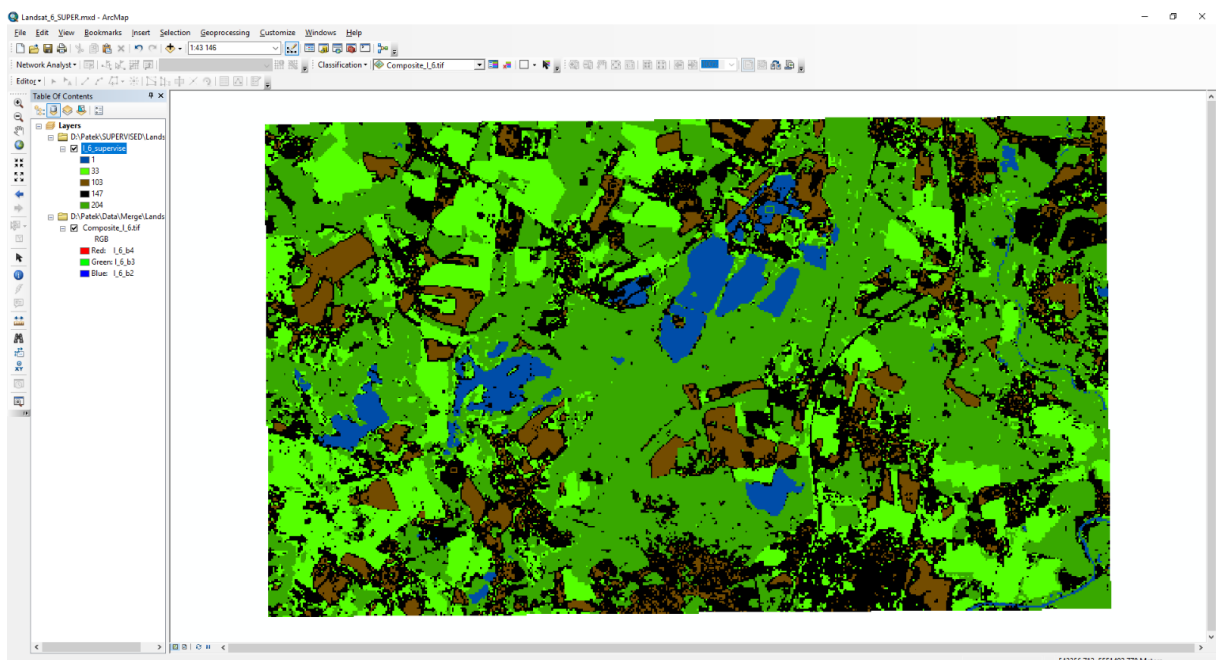
Po tomto kompletním sesbírání trénovacích dat je potřeba, pro účely dalšího využití, uložit tuto sadu jako signature file. Na následujícím obrázku č. 20 lze vidět nastavení klasifikátoru na základě trénovací sady (Input signature file). Kromě trénovací sady je dále potřeba vybrat vrstvu, která má být klasifikována, umístění a název výstupního rastru, hodnota reject fraction, která určuje, zda bude buňka klasifikována na základě pravděpodobnosti. Hodnota 0 v tomto případě vyústí v kompletní klasifikaci všech pixelů v rastru. Další možností je nastavení, jakým způsobem budou určeny počty buněk v každé třídě vzhledem k počtu buněk trénovací sady pro každou třídu.



Obrázek 20: Nastavení klasifikátoru Maximum Likelihood

Zdroj: vlastní zpracování

Poté co dojde k nastavení jednotlivých možností popsaných výše, je spuštěna klasifikace. Po krátké době program vypočítá danou klasifikaci a přidá novou vrstvu do prostředí. Výsledek klasifikace po přenastavení odpovídajících barev pro jednotlivé třídy lze vidět na obrázku č 21.



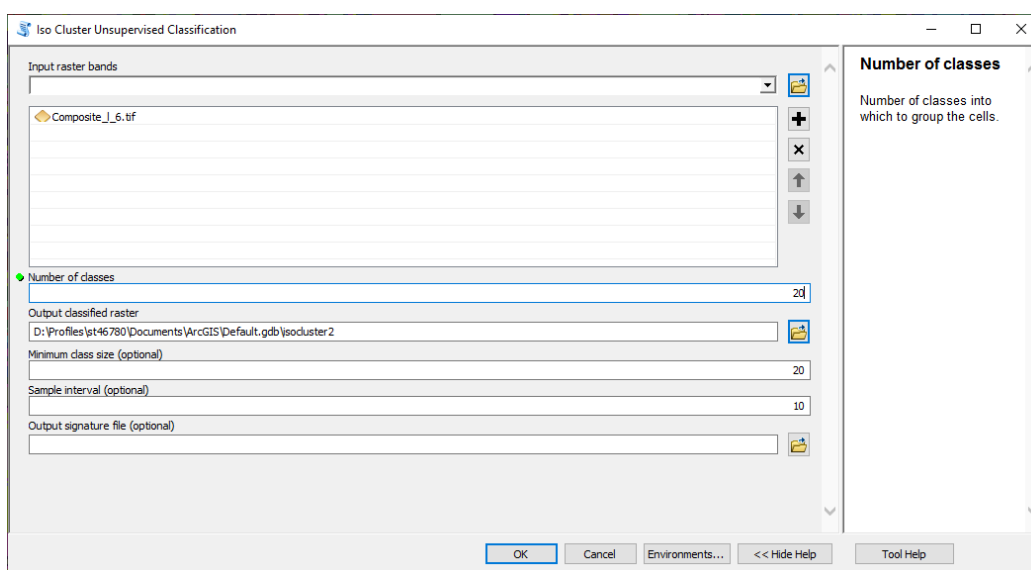
Obrázek 21: Výsledek řízené klasifikace v červenci nad daty Sentinelu

Zdroj: vlastní zpracování

4.2.3 Neřízená klasifikace

Posledním provedeným klasifikátorem je využití rovněž integrované možnosti „ISO Cluster Unsupervised Classification“. Jak název napovídá, jedná se o techniku neřízené klasifikace. Hlavním rozdílem mezi použitím této a předchozí řízené metody je ten, že pro výpočet klasifikátor nevyužívá předem definovanou trénovací sadu vytvořenou uživatelem.

Pro spuštění klasifikátoru stačí mít v SW pouze nahraná data a poté již v rámci nástrojů „Image Classification“, stejně jako u použité řízené klasifikace, vybrat možnost ISO Clusteru. Po spuštění se nabízí okno (viz. Obrázek 22), ve kterém uživatel definuje základní parametry potřebné pro výpočet klasifikace.



Obrázek 22: Nastavení klasifikátoru ISO Cluster

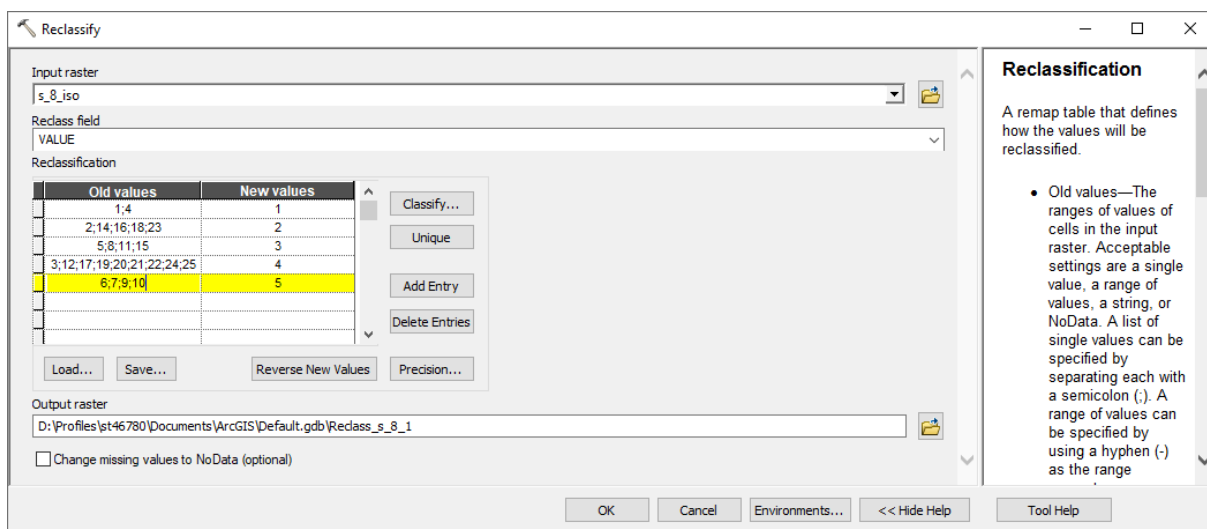
Zdroj: vlastní zpracování

Mezi hlavní parametry patří výběr vstupních dat, dále počet tříd, které budou klasifikovány. V této práci jsou data klasifikována do 5 tříd. Z důvodu větší přesnosti je potřeba několikrát opakovat tento proces se změněným počtem tříd. Po vyzkoušení několika zvyšování počtu tříd, se výsledná hodnota v rámci zpracování snímků v této práci zastavila na počtu 25. Kromě těchto hodnot je dále možné nastavit ještě umístění a název výstupního rastru, minimální počet pixelů ve třídě nebo interval využitý pro vzorkování.

Poté co jsou nastaveny všechny požadované parametry stačí spustit klasifikaci a program spustí výpočet. Po chvíli se v prostředí objeví nová vrstva, která obsahuje kategorizované zájmové území do definovaného počtu tříd. Jelikož bylo kvůli dosažení větší přesnosti nastaveno více tříd, než jaký má být výsledný počet, je důležité pomocí pozemních znalostí seskupit jednotlivé třídy tak, aby vznikl právě požadovaný počet stanovených tříd.

Prvním krokem pro dosažení správného seskupení je změna barev jednotlivých tříd na barvy dle typu pokryvu, který se zde nachází. Např. zeleň nemá všude stejnou hustotu a zdravotní stav, z tohoto důvodu bude mít ve výsledku klasifikace více tříd. Po nastavení správných barev jednotlivým třídám je možné tento rastr reklasifikovat.

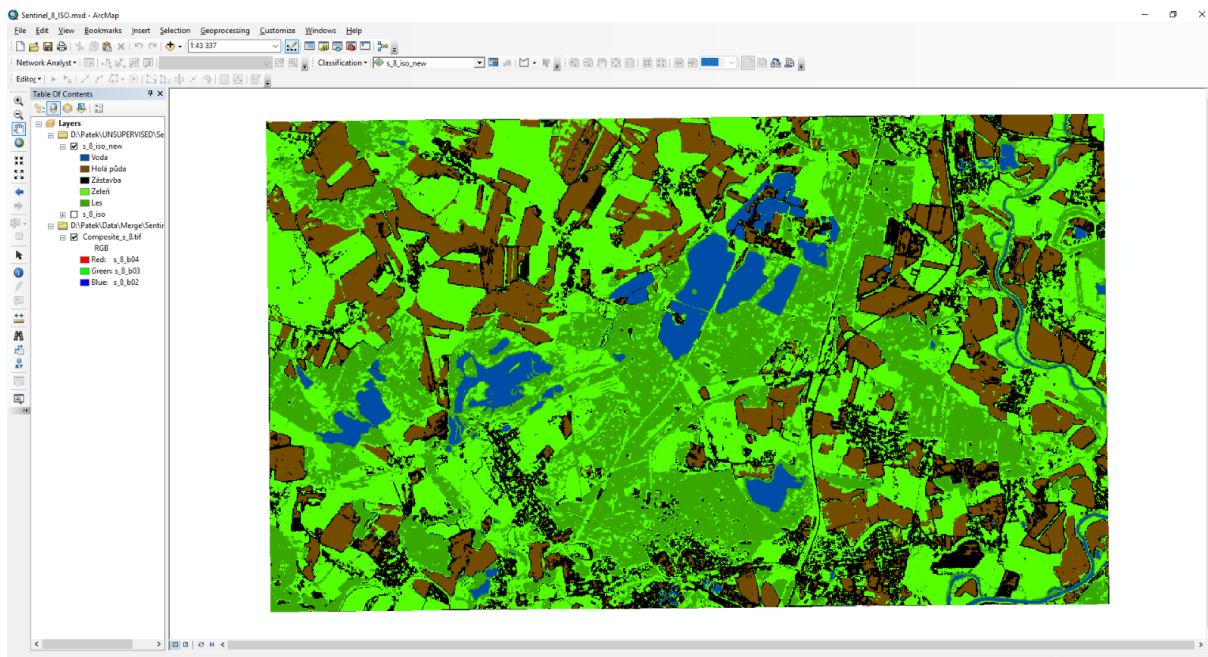
Reklasifikace rastru probíhá pomocí integrovaného nástroje „Reclassify“. Tento nástroj umožňuje na vstupním rastru vybrat více starých hodnot do jedné nové. Tento postup je ukázán na obrázku č. 23.



Obrázek 23: Nastavení nástroje Reclassify

Zdroj: vlastní zpracování

Výsledkem této reklasifikace je výstupní rastr (viz. Obrázek 24), který obsahuje právě 5, v tomto případě 5, zvolených tříd. Před samotným koncem klasifikace je opět potřeba změnit barvy jednotlivých tříd tak, aby dávaly logický význam a přepsat číselné hodnoty jednotlivých tříd na názvy příslušných kategorií.



Obrázek 24: Výsledek reklasifikace – srpen

Zdroj: vlastní zpracování


4.3 Hodnocení přesnosti klasifikace

V této části přichází čas na hodnocení přesnosti výše provedených metod klasifikace. Použitý software přímo umožňuje výpočet matice chyb a kappa koeficientu. Pro dosažení požadovaných výstupů je zapotřebí nejprve vytvořit sadu testovacích bodů a poté přiřadit reálné hodnoty dle typu pokryvu. Po provedení těchto dvou činností je možné nechat vypočítat matici chyb a kappa koeficient.

Přidání bodů sloužících pro hodnocení přesnosti probíhá pomocí nástroje „Create Accuracy Assessment Points“. Jedná se o nástroj, který zvoleným náhodným způsobem rozmístí body po snímku. V rámci nastavení nástroje uživatel definuje následující možnosti (viz. Obrázek 25):

- Input rastr – jedná se o vstupní rastr, na kterém budou body rozmístěny
- Output – slouží k nastavení cesty a názvu výstupních bodů
- Target field – uživatel volí možnost Classified pokud je vstupem již klasifikované území, nebo Ground Truth při využití původního snímku
- Number of random points – číselná hodnota stanovující počet náhodně vytvořených bodů (v rámci této práce je voleno 50 bodů pro každou třídu).
- Sampling strategy – strategie rozdělení bodů
 - Stratified Random – vytvořené body jsou náhodně rozmístěny v každé třídě, kde každá třída má počet bodů úměrný její relativní ploše

- Equalized Stratified Random – vytvořené body jsou náhodně rozmístěny v každé třídě, kde každá třída má stejný počet bodů
- Random – vytvořené body jsou náhodně rozmístěny po celém obrázku

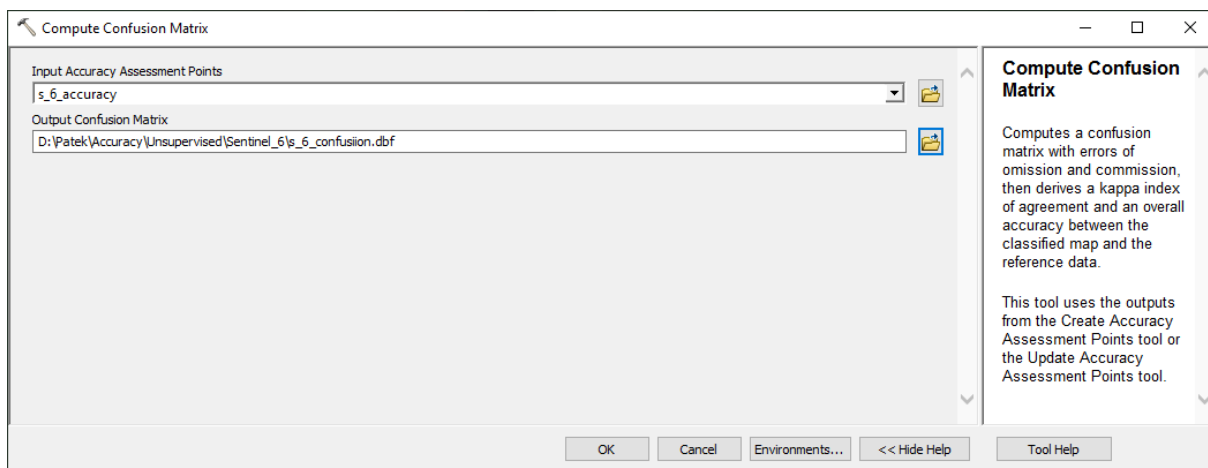


Obrázek 25: Nastavení nástroje Create Accuracy Assessment Points

Zdroj: vlastní zpracování

Při zpracování této práce bylo zvoleno 50 bodů pro třídu, kdy každá třída má stejný počet bodů. Po úspěšném provedení náhodného generování bodů se tyto jednotlivé body zobrazí na snímku. Atributová tabulka obsahuje několik sloupců, kdy nejdůležitějšími sloupci pro vytvoření matice chyb a výpočtu kappa koeficientu jsou Classified a Ground Truth. Sloupec Classified obsahuje hodnoty dle třídy, na které byl vytvořen a sloupec Ground Truth obsahuje prázdné hodnoty značené -1.

Dalším krokem je tedy přiřazení reálných hodnot Ground Truth do tabulky. Aby bylo možné upravovat záznamy v tabulce, je nejprve nutné spustit editaci na vybrané vrstvě. Po spuštění editace může uživatel lehce změnit záznamy v požadované tabulce. Pomocí původního snímku lze určit správné zatřídění vygenerovaných bodů. Přepisováním hodnot -1 na reálné hodnoty tříd ve sloupci Ground Truth vznikne kompletní tabulka, kterou lze vyhodnotit pomocí nástroje „Compute Confusion Matrix“. Nastavení nabídky je ukázáno na obrázku č. 26.



Obrázek 26: Nastavení nástroje Compute Confusion Matrix

Zdroj: vlastní zpracování

Tento nástroj slouží k výpočtu matice chyb a kappa koeficientu. Je přímo přizpůsobený k tomu, aby využíval správné sloupce vzniklé při vytváření náhodných bodů. Není tedy nutné tyto sloupce nijak specifikovat. Uživatel definuje pouze vstupní body, výstupní umístění a název matice.

Po stisknutí tlačítka OK program sám vypočítá matici chyb a kappa koeficient. Na obrázku č. 27 lze vidět výslednou matici chyb, která kromě samotné matice obsahuje i hodnoty o přesnosti klasifikace a také hodnotu kappa koeficientu.

OID	ClassValue	C 1	C 2	C 3	C 4	C 5	Total	U Accuracy	Kappa
0	C_1	46	2	1	0	1	50	0,92	0
1	C_2	0	36	4	2	8	50	0,72	0
2	C_3	0	0	39	10	1	50	0,78	0
3	C_4	0	0	6	43	1	50	0,86	0
4	C_5	0	4	4	2	40	50	0,8	0
5	Total	46	42	54	57	51	250	0	0
6	P_Accuracy	1	0,857143	0,722222	0,754386	0,784314	0	0,816	0
7	Kappa	0	0	0	0	0	0	0	0,77

Obrázek 27: Výsledek výpočtu matice chyb a kappa koeficientu

Zdroj: vlastní zpracování

Výpočet tabulky probíhá na základě hodnoty označující danou třídu, nikoliv dle jejich názvu. Pro jasnější pochopení je třeba definovat jaké označení představuje kterou třídu. V tomto případě se jedná o následující přeznačení:

C_1 = Voda, C_2 = Les, C_3 = Zástavba, C_4 = Holá půda a C_5 = Ostatní zeleň.

Z tabulky lze vyčíst, jakým způsobem byly klasifikovány jednotlivé náhodné body, dále také uživatelskou a zpracovatelskou přesnost, celkovou přesnost a kappa koeficient. Pro přehlednost tabulky je na závěr potřeba upravit názvy tříd na přesné názvy klasifikovaných tříd, které byly zvoleny při klasifikaci.

Stejným způsobem, jako je výše zmíněný postup použití vegetačních indexů, klasifikace a hodnocení přesnosti, byly zpracovány všechny vybrané snímky družice Sentinel-2. Celkem byl tedy postup použit na čtyřech snímcích, kde každý snímek reprezentoval jeden měsíc ze zvoleného vegetačního období květen až srpen.

5 VIZUALIZACE A INTERPRETACE VÝSLEDKŮ

Posledním krokem, kterému se věnuje tato kapitola, je vizualizace a interpretace výsledků, kterých bylo dosaženo v rámci zpracování požadovaných dat. Vizualizace výsledků se týká vytvoření jednotlivých mapových výstupů pro výsledné zobrazení využitých vegetačních indexů, klasifikátorů a hodnot zjištěných při hodnocení přesnosti klasifikace.

5.1 NDVI

Prvním bodem zpracování bylo využití vegetačního indexu NDVI. Jak bylo zmíněno, tento index se využívá pro přehledné zobrazení zeleně nacházející se na snímku. Při pohledu na data zpracovaná pomocí tohoto indexu lze snadno pozorovat změny zájmového území v průběhu jednotlivých měsíců.

Výsledný snímek má po použití indexu NDVI černobílou formu. Aby bylo možné dosáhnout zřetelnějšího porozumění v jaké části je více vegetace a v jaké méně, došlo k úpravě tohoto zobrazení na barevnou škálu od červené po zelenou. Čím více zelené se na dané části snímku nachází, tím více (případně zdravější) vegetace se na daném místě nachází. Přejít do červené barvy naopak značí území bez vegetace (viz Obrázek 28).



Obrázek 28: Vegetační index NDVI na snímcích družice Sentinel-2

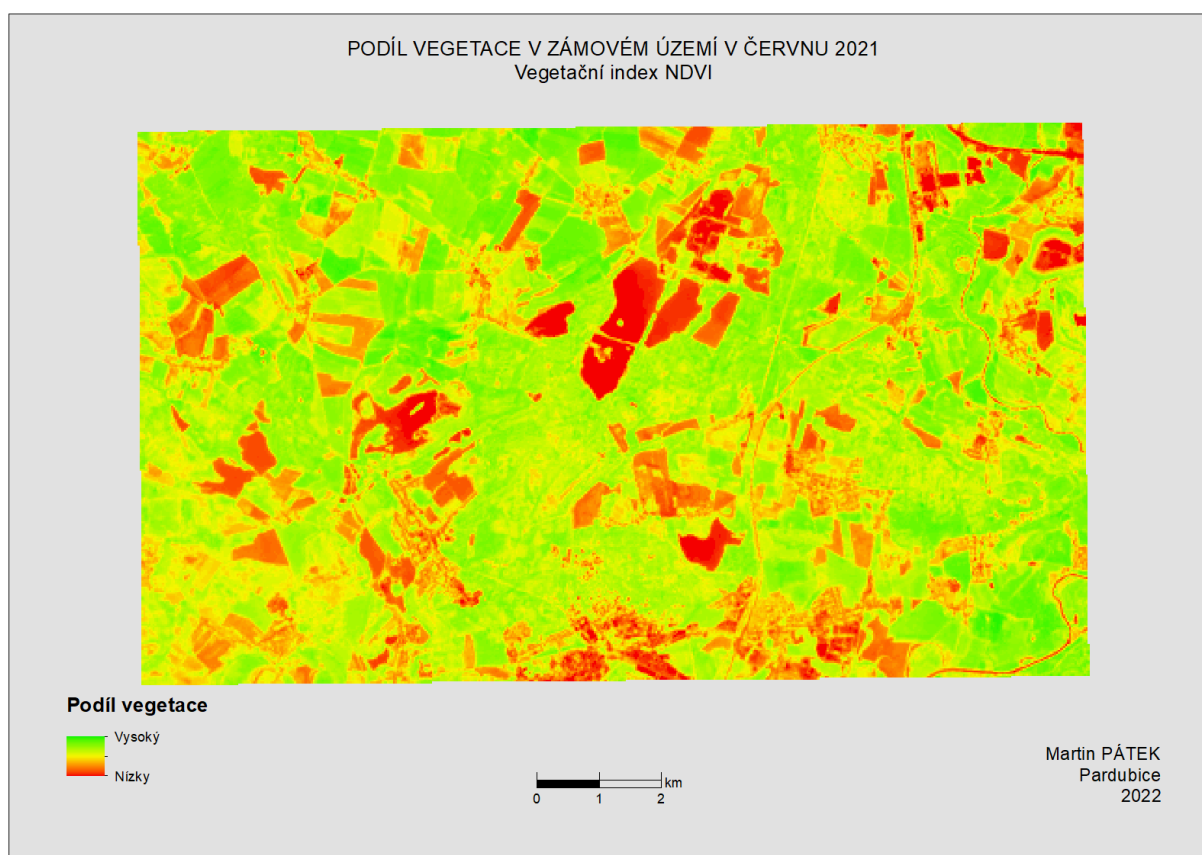
Zdroj: vlastní zpracování

Z následující vizualizace lze snadno vyčíst meziměsíční změnu ve stavu vegetace. Zájmová oblast vyobrazená pomocí vegetačního indexu v květnu přehledně ukazuje jednotlivá zoraná pole a další oblasti s holou půdou. Zajímavostí také na tomto snímku je, že oproti ostatním jsou jako oblast s vysokým podílem vegetace vyobrazeny také vodní plochy.

Výsledek indexu NDVI v červnu 2021 ukazuje nejvyšší podíl vegetace, to znamená že v tomto období mají stromy nejvíce zdravých listů, a také že největší část zemědělské půdy je již oseta a rostou zde plodiny.

Na snímku z července lze pozorovat v jeho levé části přítomnost mraků. Jedná se o jediný vybraný snímek družice Sentinel-2, který je takto mraky pokryt. Dále je patrný vyšší podíl žluté barvy, to může znamenat, že v tomto období bylo větší sucho a vegetace tedy nedosahovala optimálního zdravotního stavu.

Pokud jde o výsledný mapový výstup pro index NDVI u snímku družice Landsat, je možné ho vidět na následujícím obrázku č. 29.



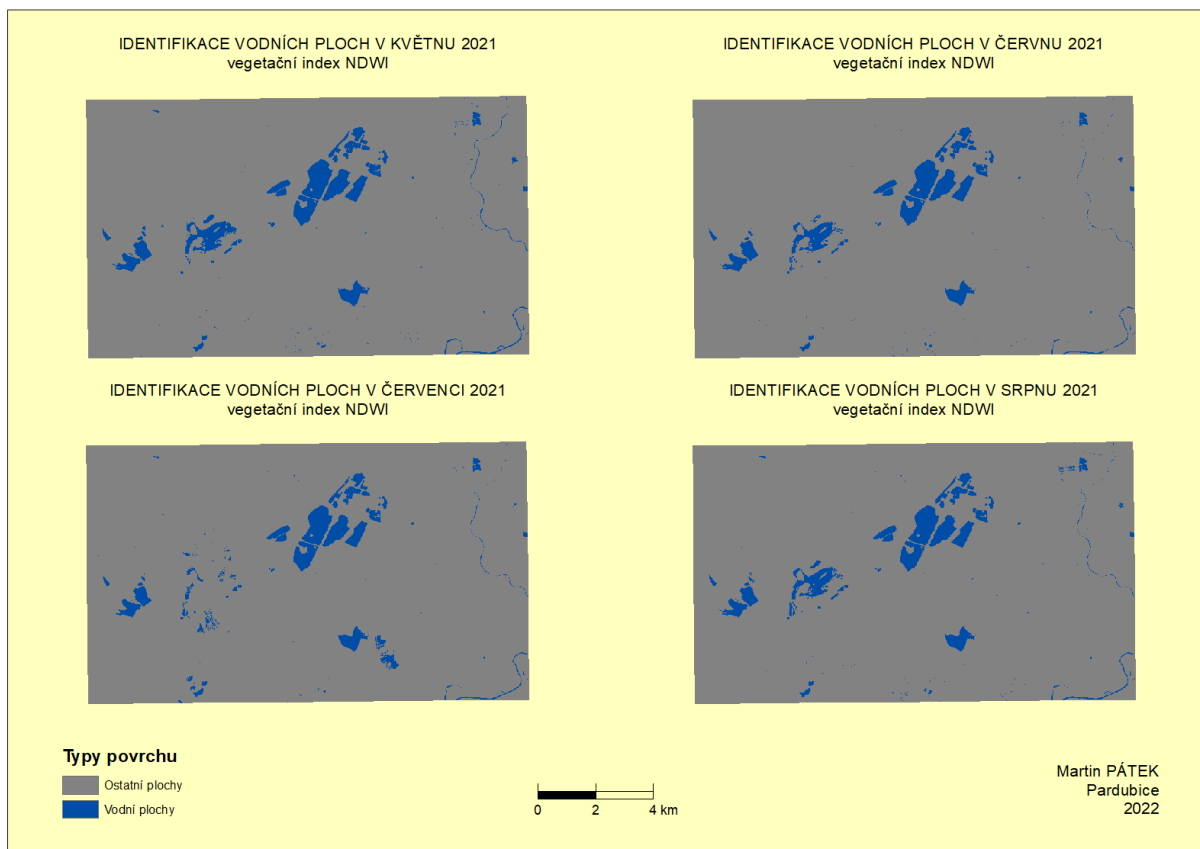
Obrázek 29: Vegetační index NDVI na snímku Landsat

Zdroj: vlastní zpracování

5.2 NDWI

Dalším využitým vegetačním indexem bylo zpracování dat pomocí výpočtu indexu NDWI. Jedná se o index, který se zaměřuje na zobrazení vodních ploch a lze tak s jeho pomocí snadno identifikovat veškeré vodní plochy, nacházející se na zájmovém území. Zároveň je možné tento index využít také k určení celkové plochy, kterou vodní plochy na snímku dosahují.

Výsledný index dělí zájmové území na dvě oblasti. První oblastí jsou vodní plochy a druhou pak plochy ostatní. Jednotlivé výstupy tohoto indexu družice Sentinel ukazuje obrázek č. 30.

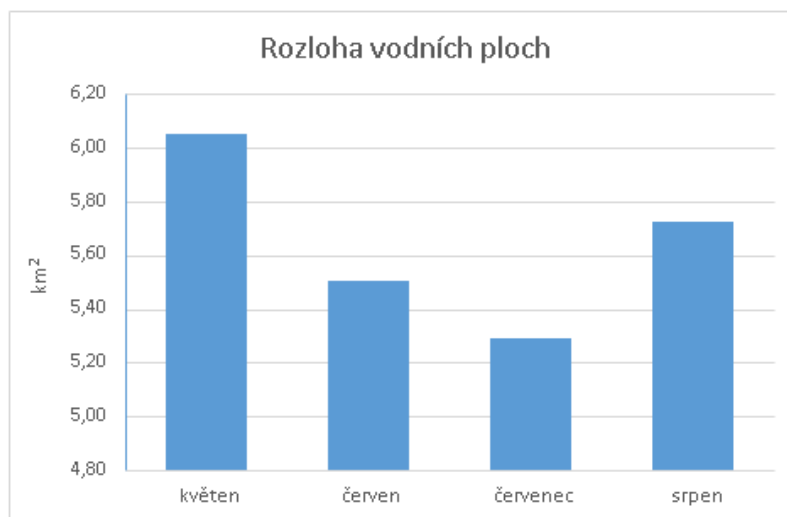


Obrázek 30: Vegetační index NDWI na snímcích družice Sentinel-2

Zdroj: vlastní zpracování

Z vizualizace indexu NDWI je patrné, že vodní plochy jsou ve všech vybraných obdobích na podobné úrovni. Zpracovaná data za červenec opět ukazují, jakým způsobem mraky ovlivňují zpracování družicových dat. Je zde zřetelně vidět většinová chybějící plocha Bohdanečského rybníku. Stejně jako u výstupu indexu NDVI toto ovlivňuje výsledky detekce změn, protože není možné přesně určit jakou plochu na snímku zmíněný rybník zaujímá.

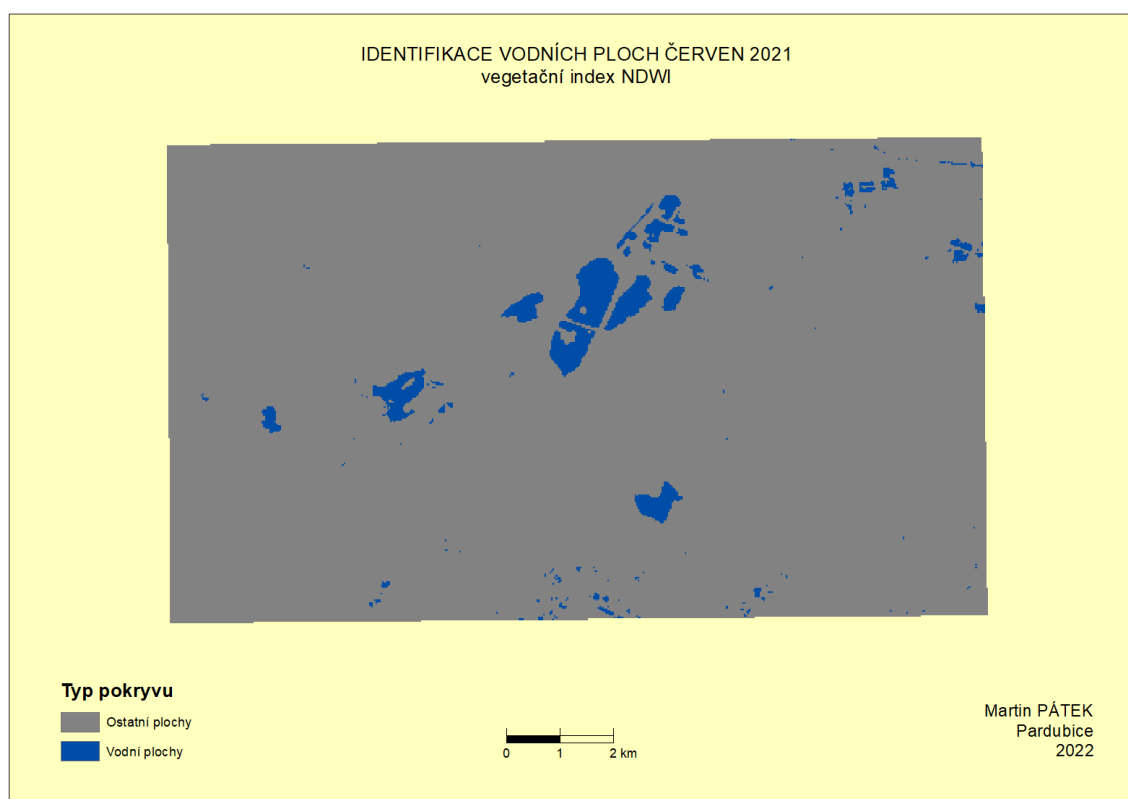
Potvrzení tohoto stanoviska dokazuje i výpočet plochy vodních ploch na jednotlivých snímcích. Hodnoty pro výpočet jsou dostupné v atributové tabulce rastru vzniklého výpočtem indexu NDWI.



Graf 1: Rozloha vodních ploch – Sentinel

Zdroj: vlastní zpracování

Graf č. 1 rovněž jasně ukazuje chybějící plochu pokrytou mraky na území v červenci. Dále zde také vidíme pokles rozlohy vodních ploch v červnu. Tento fakt může být důsledkem většího sucha, stejně jak již bylo zmíněno u toho snímku při využití indexu NDVI a nižších hodnot vegetace. Jedná se tedy o další náznak, který by mohl potvrzovat tuto myšlenku. Zpracování tohoto indexu pro snímek družice Landsat ukazuje obrázek č. 31.



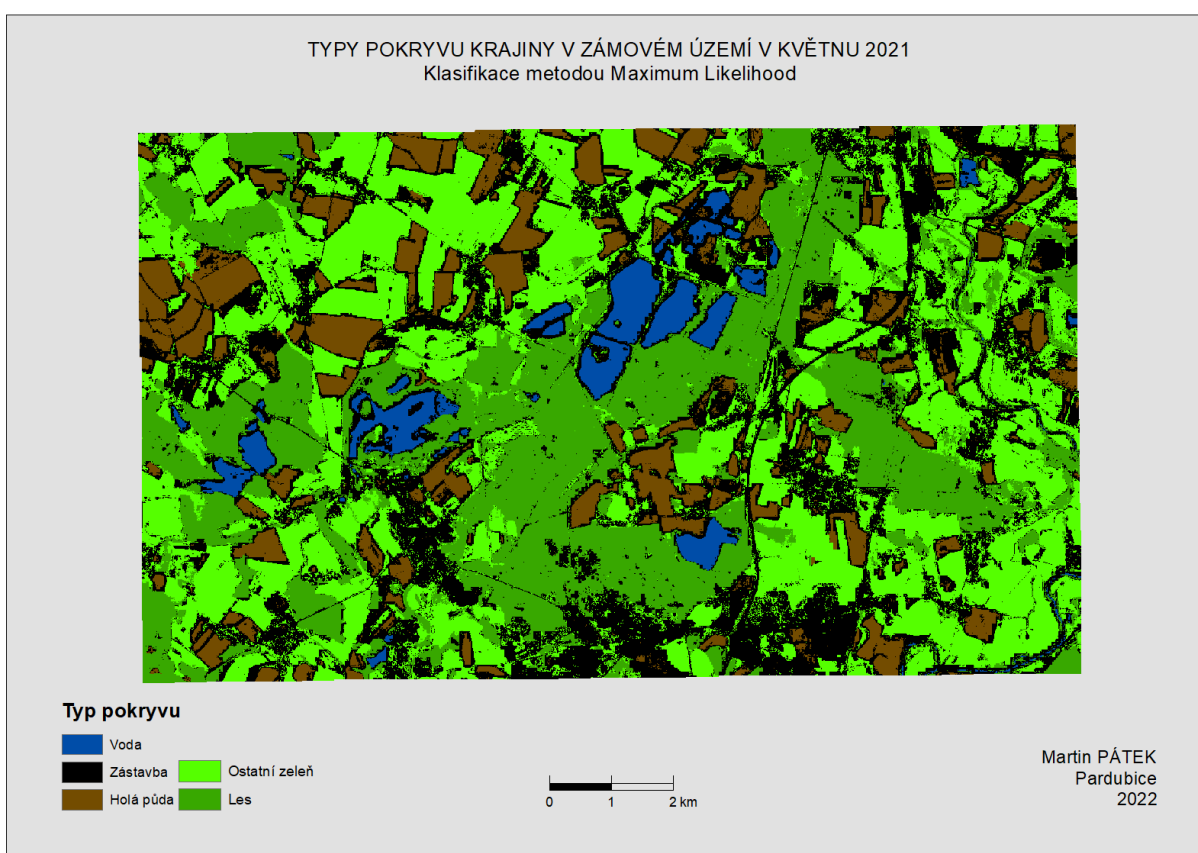
Obrázek 31: Vegetační index NDWI na snímku družice Landsat

Zdroj: vlastní zpracování

5.3 Řízená klasifikace

Prvním použitým klasifikátorem je „Maximum Likelihood Classifier“. Pomocí tohoto klasifikátoru bylo na základě trénovacích dat (viz. Řízená klasifikace) klasifikováno celkem 5 tříd v případech, kdy na snímku nebyly obsaženy mraky a 6 tříd v rámci klasifikace zájmového území v červenci.

Jako výsledné klasifikační třídy byly vybrány základní typy pokryvu, které se vyskytují v běžných podmínkách vegetačního období ve vybrané oblasti zájmu. Jedná se o následující typy pokryvu: Voda, Les, Ostatní zeleň, Zástavba, Holá půda a v případě zmíněného snímku z července také Mraky.



Obrázek 32: Výsledek klasifikace MLC – květen

Zdroj: vlastní zpracování

Prvním klasifikovaným územím je období **května** (viz. Obrázek 32). Jedná se o období, kdy bývá ještě dostatek vody z roztátého sněhu a jarních dešťů. Rozloha vodních ploch je v tomto období dle klasifikace nejvyšší ze všech měsíců a to 4,64 km². Největší plochu v tomto období na snímku zaujímá zeleň s celkovou rozlohou 45,07 km² a podílem 33,26 % z celku.

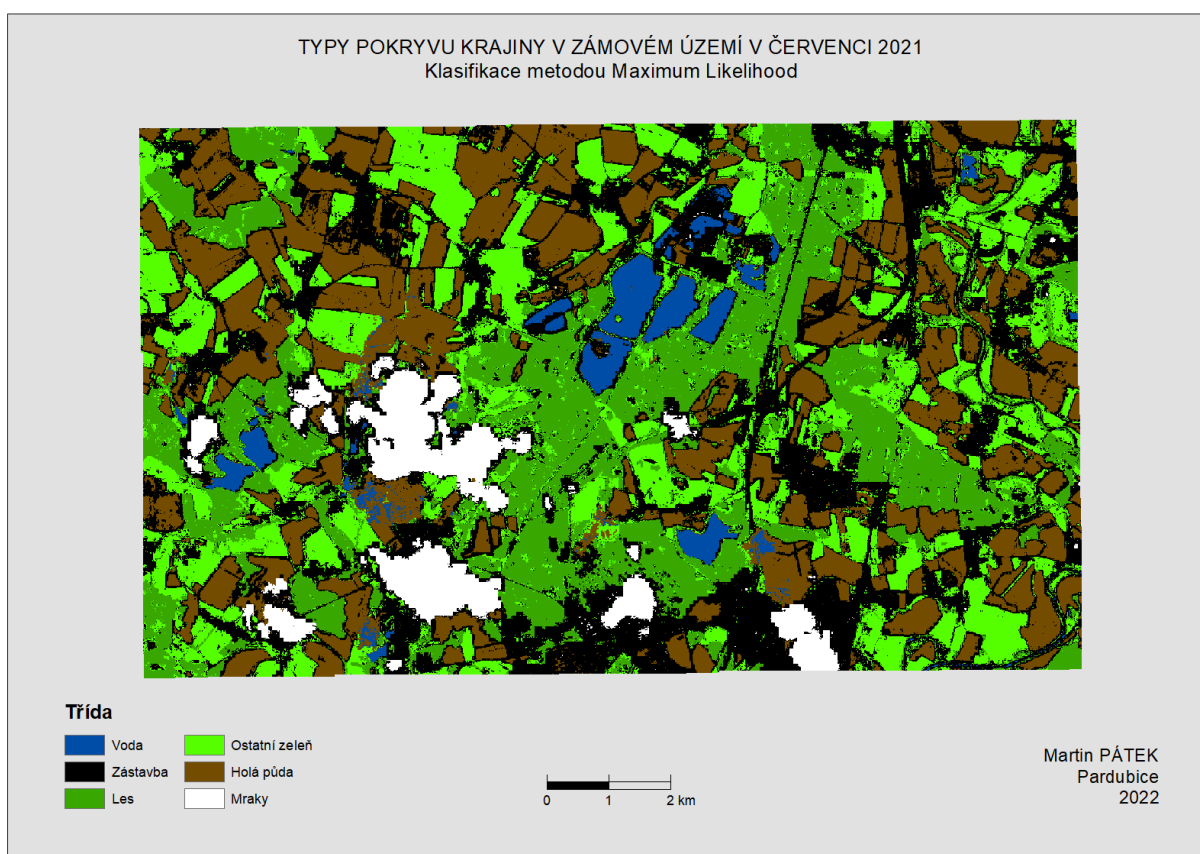
Výsledná rozloha jednotlivých typů pokryvu je vyjádřena v tabulce č. 12.

Tabulka 12: Rozloha tříd MLC – Sentinel-2 v květnu

Třída	Počet pixelů	Plocha [km ²]	Podíl [%]
Voda	46 386	4,64	3,42
Zeleň	450 703	45,07	33,26
Les	342 394	34,24	25,27
Holá půda	138 691	13,87	10,23
Zástavba	376 935	37,69	27,82

Zdroj: vlastní zpracování


Územím, pro které bylo potřeba klasifikovat více tříd, se stala data z měsíce **července**. Jak již bylo zmíněno, na tomto snímku se vyskytuje značné množství oblačnosti, která dosahovala 5,04 % pokrytí snímku. Největší území v tomto měsíci lze zaznamenat u třídy zástavba. Výsledná vizualizace tohoto výstupu je ukázána na obrázku č. 33.



Obrázek 33: Výsledek klasifikace MLC – červenec

Zdroj: vlastní zpracování

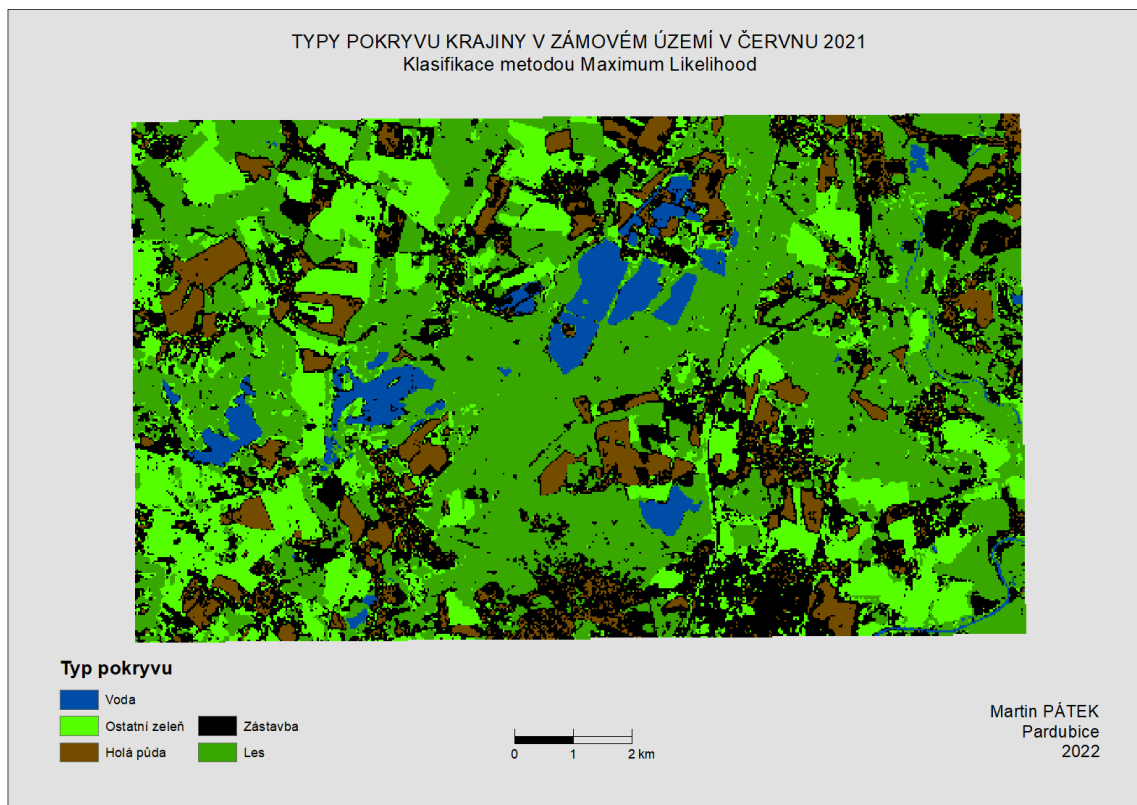
Mapové výstupy měsíců červen a srpen pak reprezentují obrázky č. 38 a č. 39 uvedené v příloze A. Výsledné rozlohy všech tříd v jednotlivých obdobích je možné vyčíst z grafu č. 2.



Graf 2: Rozloha tříd MLC – Sentinel

Zdroj: vlastní zpracování

Jelikož se jedná o zájmové území, které obsahuje velkou část území využívanou pro zemědělské účely, lze snadno vysvětlit jednotlivé výrazné změny tříd holá půda a ostatní zeleň, které se během zvoleného období výrazně mění v závislosti na stavu právě této zemědělské půdy. Jedná se o nejvýraznější změny mezi jednotlivými měsíci. Změny v ploše zástavby jsou s největší pravděpodobností ovlivněny nižší úspěšností klasifikace právě této třídy. Následující obrázek č. 34 pak zobrazuje mapový výstup pro snímek družice Landsat.



Obrázek 34: Výsledek klasifikace MLC – červen (Landsat)

Zdroj: vlastní zpracování

Následující tabulka č. 13 jasně dokazuje, že prostorové rozlišení družic hraje podstatnou roli ve výsledcích klasifikace.

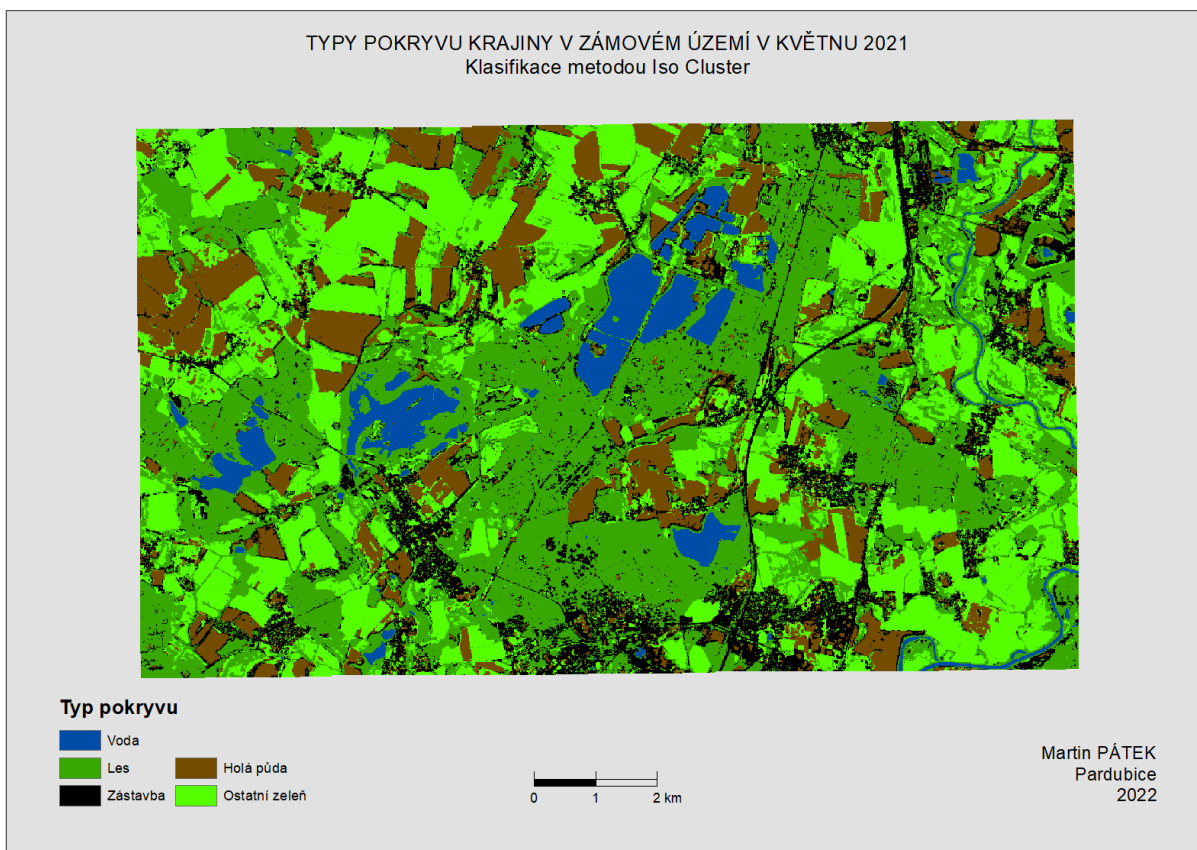
Tabulka 13: Porovnání ploch tříd MLC mezi družicemi

Třída / Červen	Plocha [km2]	
	Sentinel	Landsat
Voda	4,47	5,93
Zeleň	45,08	27,65
Les	27,77	55,61
Holá půda	11,10	11,13
Zastavěná oblast	47,10	35,55

Zdroj: vlastní zpracování

5.4 Neřízená klasifikace

Druhým využitým klasifikátorem je ISO Cluster. Jedná se o neřízený klasifikátor, který byl rovněž využit pro klasifikaci do stejných 5/6 tříd. Jelikož se jedná o neřízenou klasifikaci, nebyly pro klasifikaci využity žádné trénovací plochy a výsledná klasifikace je tedy čistě na výpočtu klasifikátoru. První mapový výstup tohoto klasifikátoru lze vidět na obrázku č. 35.

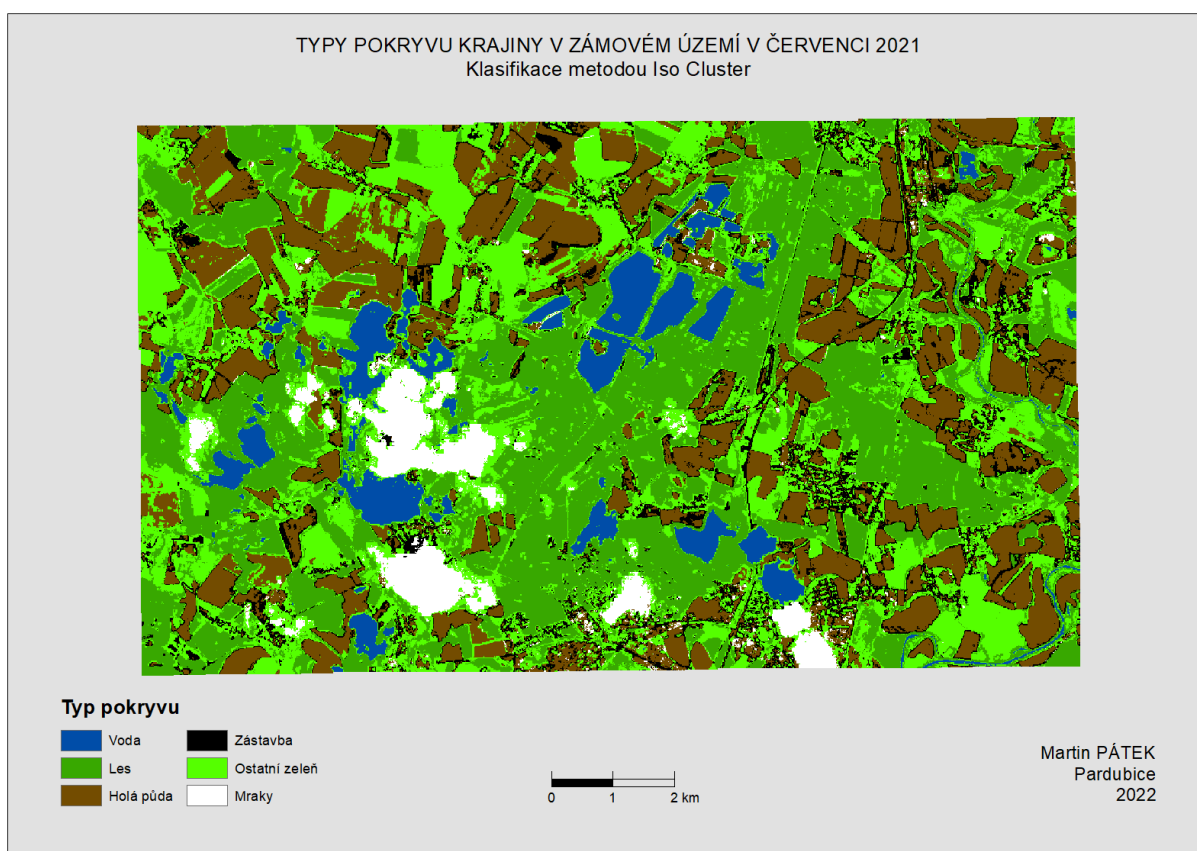


Obrázek 35: Výsledek klasifikace ISO – květen

Zdroj: vlastní zpracování

Při využití tohoto klasifikátoru pro zpracování dat z **května** převládá na snímku třída les, která svou plochou zaujímá téměř 40 % celého snímku. Nejméně zastoupenou třídou je voda, stejně jako při využití řízené klasifikace. Mapový výstup je možné vidět na obrázku č. 35.

V tomto případě je rovněž možné všimnout si prvních rozdílů mezi oběma typy klasifikací. Při zpracování dat pomocí MLC byla totiž nejčetnější třídou na snímku z května ostatní zeleň, a nikoliv les jako v tomto případě. Významných rozdílů je také dosaženo v klasifikaci území zástavby. V rámci této třídy činí rozdíl mezi jednotlivými metodami téměř 20 km². Jedná se o nejvyšší rozdíl mezi těmito metodami při zpracování květnového snímku.




Obrázek 36: Výsledek klasifikace ISO – červenec

Zdroj: vlastní zpracování

Při pohledu na obrázek č. 36 lze vidět zpracování snímku z července, obsahujícího mraky, metodou ISO Cluster. V rámci této metody činil samotný pokryv mraky celkem 5,6 km². Jedná o nejméně vyskytující se třídu na tomto území. Mezi nejvíce zastoupené třídy patří les a ostatní zeleň. Oproti klasifikaci řízenou metodou lze při porovnání Graf 2: Rozloha tříd MLC – Sentinel a Graf 3: Rozloha tříd ISO – Sentinel sledovat výrazné rozdíly mezi výslednými plochami jednotlivých tříd. Nejvíce rozdílů pak lze pozorovat u klasifikovaného území zástavby.

Dle následujícího grafu č. 3 lze také snadno porovnat vývoj jednotlivých ploch pro třídy v průběhu jednotlivých zvolených období. Největší rozdíl u třídy holá půda lze pozorovat mezi měsíci červen a červenec, kdy v červenci došlo k nárůstu této plochy na přibližně dvojnásobek. Při bližším zkoumání vývoje plochy lesů lze pozorovat, že se tato plocha každým měsícem zmenšuje.

U ostatní zeleně lze pozorovat pravidelný pokles a růst této plochy, který může souviset se stavem úrody na jednotlivých zemědělských plochách. Změny v oblasti zástavby jsou tak rozsáhlé, že lze předpokládat, že jsou tyto změny primárně ovlivněny nesprávnou klasifikací dané třídy. Toto tvrzení potvrzují i výsledky hodnocení přesnosti klasifikace uvedené v tabulce č. 15 a tabulkách uvedených v příloze D.




Graf 3: Rozloha tříd ISO – Sentinel



Zdroj: vlastní zpracování

Posledním zpracovaným snímkem se stal stejně jako u předchozího klasifikátoru červnový snímek pořízený družicí Landsat. Výsledek tohoto zpracování lze vidět na obrázku č. 37. Jelikož se jedná o jediný snímek družice Landsat, není možné mezi nimi výsledky nijak porovnat.

TYPY POKRYVU KRAJINY V ZÁMOVÉM ÚZEMÍ V ČERVNU 2021
Klasifikace metodou Iso Cluster



Typ pokryvu



Martin PÁTEK
Pardubice
2022

Obrázek 37: Výsledek klasifikace ISO – červen (Landsat)

Zdroj: vlastní zpracování

5.5 Hodnocení přesnosti klasifikace

Posledním krokem této práce je vyhodnocení přesnosti klasifikace a vyjádření možných příčin nízké přesnosti ať už klasifikace celkové, tak i klasifikace jednotlivých tříd.

Pro všechny snímky v rámci obou typů klasifikací byly jako výstup vytvořeny matice chyb (viz. přílohy C a D) a vypočítána hodnota kappa koeficientu. Tyto hodnoty jsou seskupeny v tabulce č.14.

Tabulka 14: Výsledky hodnocení přesnosti klasifikace – Sentinel

Měsíc	Přesnost MLC [%]	Kappa koef. MLC	Přesnost ISO [%]	Kappa koef. ISO
Květen	89,60	0,87	86,80	0,84
Červen	92,00	0,90	81,60	0,77
Červenec	82,33	0,79	79,33	0,75
Srpen	87,20	0,84	85,20	0,82

Zdroj: vlastní zpracování

Z výše uvedené tabulky vyplývá, že obě metody klasifikace dosáhly vysoké přesnosti klasifikace. Nejvyšší dosaženou hodnotou je přesnost klasifikace snímku z června metodou Maximum Likelihood s hodnotou 92,00 %.

Metoda řízené klasifikace se rovněž stala úspěšnější než metoda neřízená při zpracování všech časových období. Nejnižší hodnoty přesnosti dosáhly oba klasifikátory v měsíci červenci. Jedná se, jak už bylo zmíněno, o jediný měsíc, který byl pokryt mraky. Mraky tedy jistě přispěly k horším výsledkům klasifikace, nejedná se pouze o mraky jako takové, ale také stín, který vrhají na snímanou oblast. Při detailnějším zkoumání si lze všimnout, že část území, která byla pokryta stínem, byla často klasifikována stejně jako vodní plochy.

Dalším problémem, na který je potřeba upozornit bylo více chyb u klasifikace zástavby. Velké procento pixelů této třídy bylo chybně klasifikováno. Nejčastěji se jednalo o třídy holá půda, zeleň nebo v případě snímků z července mrak. Tyto chyby lze rovněž vyčíst z matice chyb. Kromě těchto chyb tak lze z matice vyčíst celkovou dosaženou přesnost (tučně v pravé spodní buňce). Kromě celkové přesnosti se v tabulce dále nachází přesnost uživatelská a zpracovatelská (viz. tabulka 15). Uživatelská přesnost definuje, s jakou pravděpodobností zařazený pixel skutečně reprezentuje právě tuto třídu. Zpracovatelská přesnost pak vyjadřuje poměr správně zařazených pixelů vůči pixelům, které byly použity pro testování dané třídy.

Tabulka 15: Matice chyb klasifikace ISO – květen

Třída	Voda	Les	Zástavba	Holá půda	Zeleň	Celkem	Uživatelská přesnost [%]
Voda	48	0	0	1	1	50	96,00
Les	0	47	0	1	2	50	94,00
Zástavba	0	0	32	9	9	50	64,00
Holá půda	0	0	2	45	3	50	90,00
Zeleň	0	1	4	0	45	50	90,00
Celkem	48	48	38	56	60	250	
Zpracovatelská přesnost [%]	100,00	97,92	84,21	80,36	75,00		86,80

Zdroj: vlastní zpracování

Pokud jde o výsledky hodnocení přesnosti klasifikace u snímku Landsat, dosahovala 85,20 % při použití metody MLC a 77,2 % v případě ISO Clusteru. Jedná se tedy o nižší úspěšnost než při využití snímků družice Sentinel v tomto období. Výsledné hodnoty kappu koeficientu jsou pro řízenou metodu 0,815 a pro neřízenou 0,715.

ZÁVĚR

Cílem práce bylo navrhnout vhodný postup a identifikovat změny pokryvu zájmového území, kterým byla oblast nacházející se severně od Pardubic. Identifikace byla provedena pomocí vegetačních indexů a metod řízené a neřízené klasifikace v prostředí softwaru ArcGIS Desktop.

Staženy byly celkem 4 snímky z družice Sentinel-2 a 3 snímky z družice Landsat-8. Celý postup klasifikace zájmového území a následné identifikace byl proveden na družicových datech Sentinel-2 a jednom snímku družice Landsat-8. Prvotním plánem bylo porovnat jednotlivé výsledky klasifikace s daty družice Landsat-8, byť má odlišné prostorové rozlišení. Z důvodu vysokého pokryvu mraky na snímcích družice Landsat nebyla data s pokryvem oblačnosti větším než 25 % dále zpracovávána a byl tedy zpracován pouze jeden její snímek z června.

Data z července družice Sentinel-2 jasně dokazují, jakých rozdílů může klasifikace dosahovat při použití dat obsahujících oblačnost oproti „čistým“ snímkům. Z tohoto pohledu je tedy nejdůležitější správně zvolit vstupní data, což někdy nemusí být snadné vzhledem k časovému rozlišení jednotlivých družic. Doba oběhu družice Sentinel-2 je 5 dní, ale u družice Landsat-8 se jedná o dní 16.

V rámci zájmového území došlo k identifikaci změn pomocí využití spektrálních indexů NDVI a NDWI, klasifikátoru Maximum Likelihood pro řízenou a klasifikátoru ISO Cluster pro neřízenou klasifikaci.

Index NDVI ukazuje převážně zdravotní stav vegetace, lze tedy po použití tohoto indexu snadno na snímku sledovat vývoj vegetace v rámci území. Index NDWI pak slouží k pozorování vývoje vodních ploch. Vzhledem k tomu, že je možné z atributové tabulky vypočítat celkovou plochu, je snadné určit jednotlivé změny v požadovaném období.

Výsledky klasifikací jednotlivých období obou klasifikátorů byly porovnány s reálnými daty. Ve všech sledovaných obdobích dosáhla řízená metoda vyššího hodnocení přesnosti než metoda neřízená.

Na základě zvolených metod byly identifikovány jednotlivé typy pokryvu krajiny a jejich změny. Nejvýraznější změny byly v oblastech zeleně a holé půdy, do které se řadí i zemědělská půda, která se mění během vegetačního období nejvíce. Nejmenší změny byly naopak identifikovány v rámci třídy vody. Mezi nejčastější problémy při klasifikaci a identifikaci změn patřilo špatné klasifikování třídy zástavba a pokrytí snímku mraky.

Přínosem práce je navržený postup zpracování družicových dat, následná vizualizace výsledků s využitím kartografických metod a identifikace změn v krajině.

POUŽITÁ LITERATURA

ABBURU, Sunitha a Suresh Babu GOLLA, 2015. Satellite Image Classification Methods and Techniques: A Review. International Journal of Computer Applications [online]. 119(8) [cit. 2022-01-09]. Dostupné z:

<https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.695.1415&rep=rep1&type=pdf>

AL-DOSKI, Jwan, 2013. Image Classification in Remote Sensing. Journal of Environment and Earth Science [online]. 3(10) [cit. 2022-01-09]. ISSN 2225-0948. Dostupné z: https://www.academia.edu/4960915/Image_Classification_in_Remote_Sensing

BANDYOPADHYAY, Sanghamitra a Sriparna SAHA, 2012. Unsupervised Classification: Similarity Measures, Classical and Metaheuristic Approaches, and Applications. Kolkata: Springer-Verlag. ISBN 978-3-642-32450-5.

BRŮHA, Lukáš, 2014. Georeferencování rastrových dat [online]. Praha [cit. 2021-12-12]. Dostupné z: <https://www.natur.cuni.cz/geografie/geoinformatika-kartografie/ke-stazeni/projekty/moderni-geoinformacni-metody-ve-vyuce-gis-a-kartografie/georeferencovani-rastrovych-dat/>. Výukový materiál. Univerzita Karlova.

CAMPBELL, James B. a Randolph H. WYNNE, 2011. Introduction to remote sensing. 5th Edit. New York: Guilford Press. ISBN 978-1-60918-176-5.

CONGALTON, Russell G., 1991. A review of assessing the accuracy of classifications of remotely sensed data. Remote Sensing of Environment [online]. 37(1), 35-46 [cit. 2022-02-16]. ISSN 00344257. Dostupné z: doi:10.1016/0034-4257(91)90048-B

ČERVENÁ, Lucie, 2016. Řízená klasifikace [online]. Praha [cit. 2022-01-15]. Dostupné z: <https://www.natur.cuni.cz/geografie/geoinformatika-kartografie/ke-stazeni/projekty/moderni-geoinformacni-metody-ve-vyuce-gis-kartografie-a-dpz/rizena-klasifikace/>. Výukový materiál. Univerzita Karlova.

DOBROVOLNÝ, Petr. Dálkový průzkum Země: digitální zpracování obrazu. Brno: Masarykova univerzita, 1998. ISBN 80-210-1812-7.

FAUST, Nickolas. Spatial Enhancement [online]. Atlanta [cit. 2021-12-14]. Dostupné z: http://knightlab.org/rscc/legacy/RSCC_Spatial_Enhancement.pdf. Georgia Institute of Technology.

- FRIEDL, M.A. a C.E. BRODLEY, 1997. Decision tree classification of land cover from remotely sensed data. *Remote Sensing of Environment* [online]. 61(3), 399-409 [cit. 2022-02-11]. ISSN 00344257. Dostupné z: doi:10.1016/S0034-4257(97)00049-7
- GÖKYER, Ercan, 2013. Understanding Landscape Structure Using Landscape Metrics [online]. July 1st 2013. [cit. 2021-12-05]. Dostupné z: doi:10.5772/55758
- HALOUNOVÁ, Lena a Karel PAVELKA. Dálkový průzkum Země. V Praze: Česká technika – nakladatelství ČVUT, 2005. ISBN 80-01-03124-1.
- HORÁK, Jiří, 2014. Dálkový průzkum Země [online]. Ostrava [cit. 2021-12-07]. Dostupné z: <http://homel.vsb.cz/~hor10/Vyuka/DPZ%20prednasky/DPZ%202014.pdf>. E-learningová podpora. VŠB – Technická univerzita Ostrava.
- CHENG, Gong, Xingxing XIE, Junwei HAN, Lei GUO a Gui-Song XIA, 2020. Remote Sensing Image Scene Classification Meets Deep Learning: Challenges, Methods, Benchmarks, and Opportunities. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* [online]. 13, 3735-3756 [cit. 2022-03-03]. ISSN 1939-1404. Dostupné z: doi:10.1109/JSTARS.2020.3005403
- CHUGHAI, Ali Hassan, Habibullah ABBASI a Ismail Rakip KARAS, 2021. A review on change detection method and accuracy assessment for land use land cover. *Remote Sensing Applications: Society and Environment* [online]. 22 [cit. 2022-03-07]. ISSN 23529385. Dostupné z: doi:10.1016/j.rsase.2021.100482
- Introduction to Categorisation of Objects from their Data: Finding similar objects. SEOS [online]. Oldenburg: Carl von Ossietzky Universität Oldenburg [cit. 2021-12-06]. Dostupné z: <https://seos-project.eu/classification/classification-c01-p05.html>
- JENSEN, John R., 2015. *Introductory digital image processing: A Remote Sensing Perspective*. 4th ed. South Carolina: Pearson Education. ISBN 978-0-13-405816-0.
- JULIEV, Mukhiddin, Alim PULATOV, Sven FUCHS a Johannes HÜBL, 2019. Analysis of Land Use Land Cover Change Detection of Bostanlik District, Uzbekistan. *Polish Journal of Environmental Studies* [online]. 28(5), 3235-3242 [cit. 2022-03-07]. ISSN 1230-1485. Dostupné z: doi:10.15244/pjoes/94216
- KUMAR, Anil, Priyadarshi UPADHYAY a A. Senthil KUMAR, 2020. *Fuzzy Machine Learning Algorithms for Remote Sensing Image Classification* [online]. Boca Raton: CRC Press [cit. 2022-01-09]. ISBN 978-0-429-34036-9. Dostupné z: <https://books.google.cz/books?id=ygTuDwAAQBAJ&pg=PT30&dq=supervised+classificatio>

n&hl=cs&sa=X&ved=2ahUKEwj0n_7zlaX1AhXUQeUKHbdwDRAQ6AF6BAgFEAI#v=onepage&q=supervised%20classification&f=false

Land Cover & Land Use, 2015. Government of Canada: Natural Resources Canada [online]. 2015-11-20 [cit. 2021-12-06]. Dostupné z: <https://www.nrcan.gc.ca/maps-tools-and-publications/satellite-imagery-and-air-photos/tutorial-fundamentals-remote-sensing/educational-resources-applications/land-cover-biomass-mapping/land-cover-land-use/9373>

LAVENDER, Samantha a Andrew LAVENDER, 2015. Practical Handbook of Remote Sensing. Boca Raton: CRC Press. ISBN 978-1-1384-6330-1.

LILLESAND, Thomas M., Ralph W. KIEFER a Jonathan W. CHIPMAN. Remote sensing and image interpretation. 6th ed. Hoboken: Wiley, c2008. ISBN 978-0-470-05245-7.

LV, Wenjing a Xiaofei WANG, 2020. Overview of Hyperspectral Image Classification. Journal of Sensors [online]. 2020, 1-13 [cit. 2022-03-03]. ISSN 1687-725X. Dostupné z: [doi:10.1155/2020/4817234](https://doi.org/10.1155/2020/4817234)

MANCINO, Giuseppe, Agostino FERRARA, Antonietta PADULA a Angelo NOLÈ, 2020. Cross-Comparison between Landsat 8 (OLI) and Landsat 7 (ETM+) Derived Vegetation Indices in a Mediterranean Environment. Remote Sensing [online]. 12(2) [cit. 2022-03-13]. ISSN 2072-4292. Dostupné z: [doi:10.3390/rs12020291](https://doi.org/10.3390/rs12020291)

MONTENBRUCK, Oliver a Eberhard GILL, 2000. Satellite Orbits: Models, Methods and Applications. Berlin: Springer-Verlag. ISBN 978-3-642-63547-2.

Orbits. The European Space Agency: Types of orbits [online]. [cit. 2021-11-24]. Dostupné z: https://www-acc.esa.int/Enabling_Support/Space_Transportation/Types_of_orbits

PAL, M. a P. M. MATHER, 2006. Support vector machines for classification in remote sensing. International Journal of Remote Sensing [online]. 26(5), 1007-1011 [cit. 2022-02-11]. ISSN 0143-1161. Dostupné z: [doi:10.1080/01431160512331314083](https://doi.org/10.1080/01431160512331314083)

PANDE, Chaitanya B., Kanak N. MOHARIR, S. F. R. KHADRI a Sanjay PATIL, 2018. Study of land use classification in an arid region using multispectral satellite images. Applied Water Science [online]. 8(5) [cit. 2022-03-07]. ISSN 2190-5487. Dostupné z: [doi:10.1007/s13201-018-0764-0](https://doi.org/10.1007/s13201-018-0764-0)

PLÁNKA, Ladislav, 2007. Dálkový průzkum Země: Modul 3 - Zpracování dat [online]. Brno [cit. 2021-12-07]. Dostupné z: <https://adoc.pub/queue/vysoke-ueni-technicke-v-brn-fakulta>

stavebni-dalkovy-przkum-641901b03f175607e955cc886e95c2dd87436.html. Studijní opora. Vysoké učení technické v Brně.

PUTRI, Erisa Ayu W. A., Projo DANOEDORO, Nur Muhammad M. FARDA, et al., 2019. Comparing land-cover maps accuracies generated from multispectral classification of Landsat-8 OLI dan Pleiades images using two different classification schemes. In: Sixth Geoinformation Science Symposium [online]. SPIE, 2019-11-21, s. 31- [cit. 2022-03-07]. ISBN 9781510633896. Dostupné z: doi:10.1117/12.2548888

REDDY, M. Anji, 2008. Textbook of Remote Sensing and Geographical Information Systems. 3rd ed. Hyderabad: BS Publications. ISBN 978-81-7800-135-7.

RICHARDS, John A., 2022. Remote Sensing Digital Image Analysis. 6th ed. Canberra: Springer. ISBN 978-3-030-82326-9.

SABINS, Floyd F. a James M. ELLIS, 2020. Remote Sensing: Principles, Interpretation, and Applications. 4th ed. Long Grove: Waveland Press. ISBN 978-1-4786-3710-3.

Spectral reflectance curves, 2020. Living Textbook [online]. Twente: University of Twente [cit. 2021-12-06]. Dostupné z: <https://ltb.itc.utwente.nl/498/concept/81713>

Spectral Resolution. Government of Canada: Natural Resources Canada [online]. 2015 [cit. 2021-11-24]. Dostupné z: <https://www.nrcan.gc.ca/maps-tools-and-publications/satellite-imagery-and-air-photos/tutorial-fundamentals-remote-sensing/satellites-and-sensors/spectral-resolution/9393>

SUNWOO, Wooyeon, Hoang Hai NGUYEN a Minha CHOI, 2018. Coastal wetland change detection using high spatial resolution KOMPSAT-2 imagery. Terrestrial, Atmospheric and Oceanic Sciences [online]. 29(5), 509-521 [cit. 2022-03-07]. ISSN 1017-0839. Dostupné z: doi:10.3319/TAO.2018.05.18.01

TSO, Brandt a Paul M. MATHER. Classification Methods for Remotely Sensed Data. 2. Boca Raton: CRC Press, 2009. ISBN 978-1-4200-9072-7.

USGS EROS Archive - Sentinel-2. USGS [online]. 2018 [cit. 2022-03-26]. Dostupné z: https://www.usgs.gov/centers/eros/science/usgs-eros-archive-sentinel-2?qt-science_center_objects=0#qt-science_center_objects

USGS: Earth Explorer [online]. [cit. 2022-03-26]. Dostupné z: <https://earthexplorer.usgs.gov>

VARMA, Mantena Krishna Satya, K. RAJA a Konadala Kameswara RAO, 2021. Analysis of Satellite Images Using Supervised Image Classification Methods. Solid State Technology [online]. (64), 2616-2621 [cit. 2022-01-09]. Dostupné z:

https://www.researchgate.net/profile/Konadala-Kameswara-Rao-Nynalasetti/publication/349547893_Analysis_of_Satellite_Images_Using_Supervised_Image_Classification_Methods/links/6035d81892851c4ed5912052/Analysis-of-Satellite-Images-Using-Supervised-Image-Classification-Methods.pdf

VELA, Ela, Vanja MILJKOVIĆ a Luka BABIĆ, 2020. Spatiotemporal Analysis of LANDSAT Satellite Imagery for Change Detection in Česma Forest Ecosystem. Tehnicki vjesnik - Technical Gazette [online]. 27(5) [cit. 2022-03-13]. ISSN 13303651. Dostupné z: doi:10.17559/TV-20190214121800

VIVEKANANDA, GN, R SWATHI a AVLN SUJITH, 2021. Multi-temporal image analysis for LULC classification and change detection. European Journal of Remote Sensing [online]. 54(sup2), 189-199 [cit. 2022-03-07]. ISSN 2279-7254. Dostupné z: doi:10.1080/22797254.2020.1771215

WALZ, Ulrich, 2011. Landscape Structure, Landscape Metrics and Biodiversity. Living Reviews in Landscape Research [online]. 5 [cit. 2021-12-06]. ISSN 1863-7329. Dostupné z: doi:10.12942/lrlr-2011-3

WANG, Guangxing a Qihao WENG, 2013. Remote Sensing of Natural Resources. Bosa Roca: Taylor & Francis. ISBN 978-1-4665-5692-8.

WENG, Qihao. Remote sensing and GIS integration: theories, methods, and applications. New York: McGraw-Hill, c2010. ISBN 978-0-07-160653-0.

What are the band designations for the Landsat satellites?. USGS [online]. [cit. 2022-03-26]. Dostupné z: <https://www.usgs.gov/faqs/what-are-band-designations-landsat-satellites>

What is Remote Sensing? EarthData [online]. 2021 [cit. 2021-11-24]. Dostupné z: <https://earthdata.nasa.gov/learn/backgrounders/remote-sensing#orbits>

YUAN, Hui, Cynthia F. VAN DER WIELE a Siamak KHORRAM, 2009. An Automated Artificial Neural Network System for Land Use/Land Cover Classification from Landsat TM Imagery. Remote Sensing [online]. 2009, 1(3), 243-265 [cit. 2022-02-11]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs1030243

SEZNAM PŘÍLOH

Příloha A – Mapové výstupy klasifikátoru Maximum Likelihood

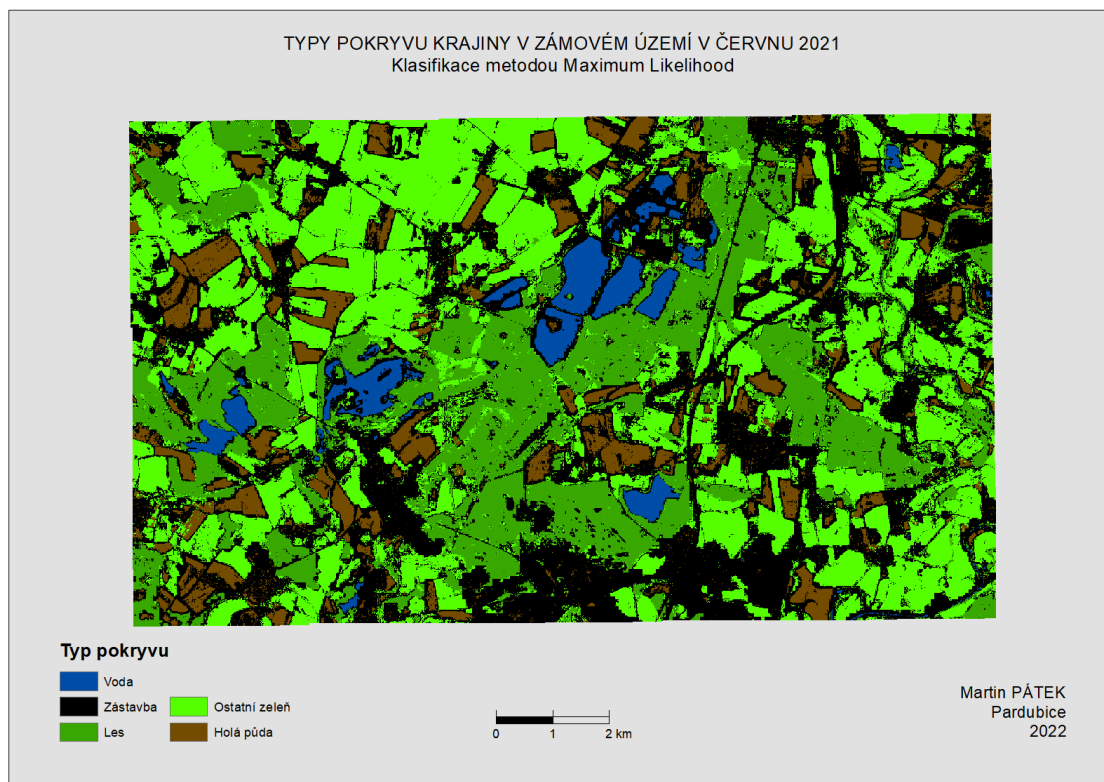
Příloha B – Mapové výstupy klasifikátoru ISO Cluster

Příloha C – Tabulky hodnocení přesnosti – MLC

Příloha D – Tabulky hodnocení přesnosti – ISO Cluster

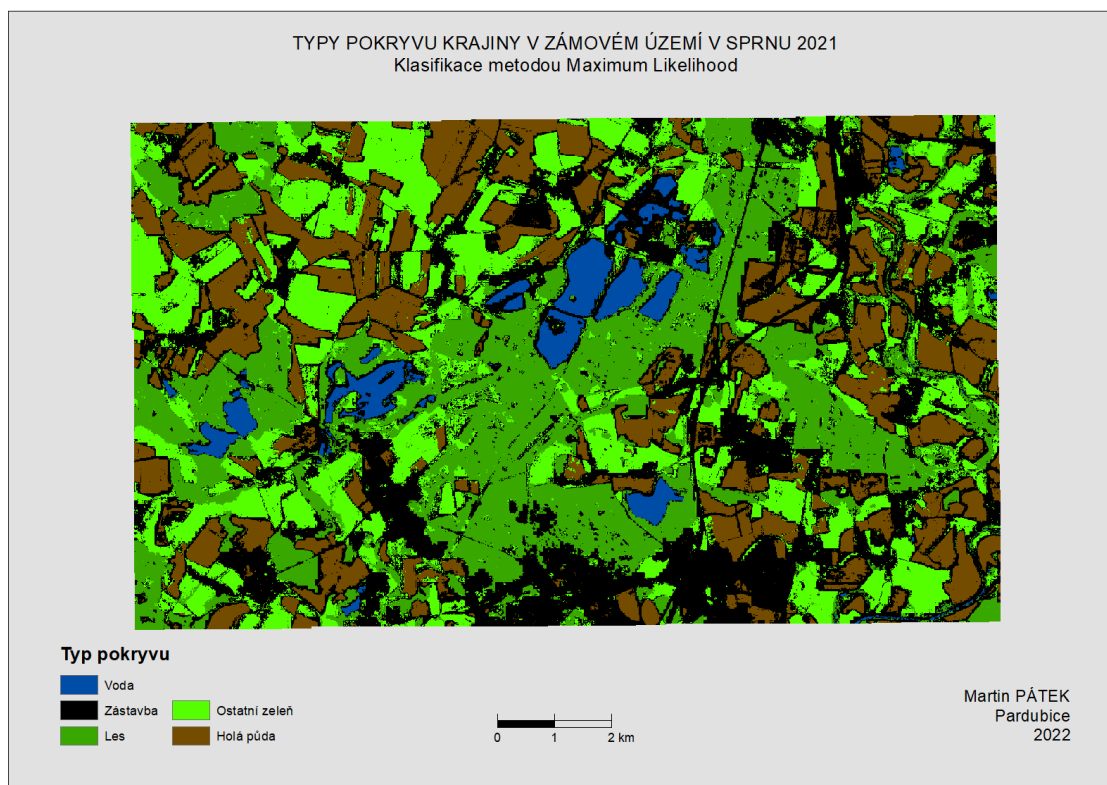
Příloha E – Tabulky hodnocení přesnosti snímku Landsat

Příloha A – Mapové výstupy klasifikátoru Maximum Likelihood



Obrázek 38: Výsledek klasifikace MLC – červen

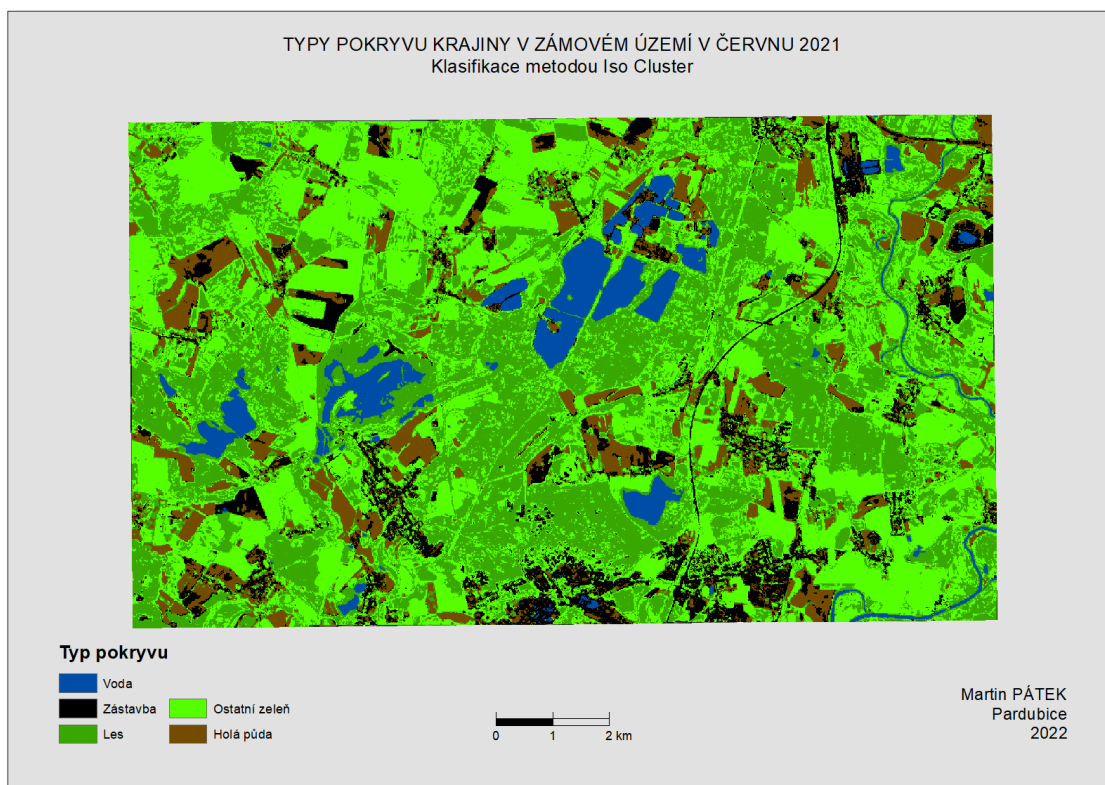
Zdroj: vlastní zpracování



Obrázek 39: Výsledek klasifikace MLC – srpen

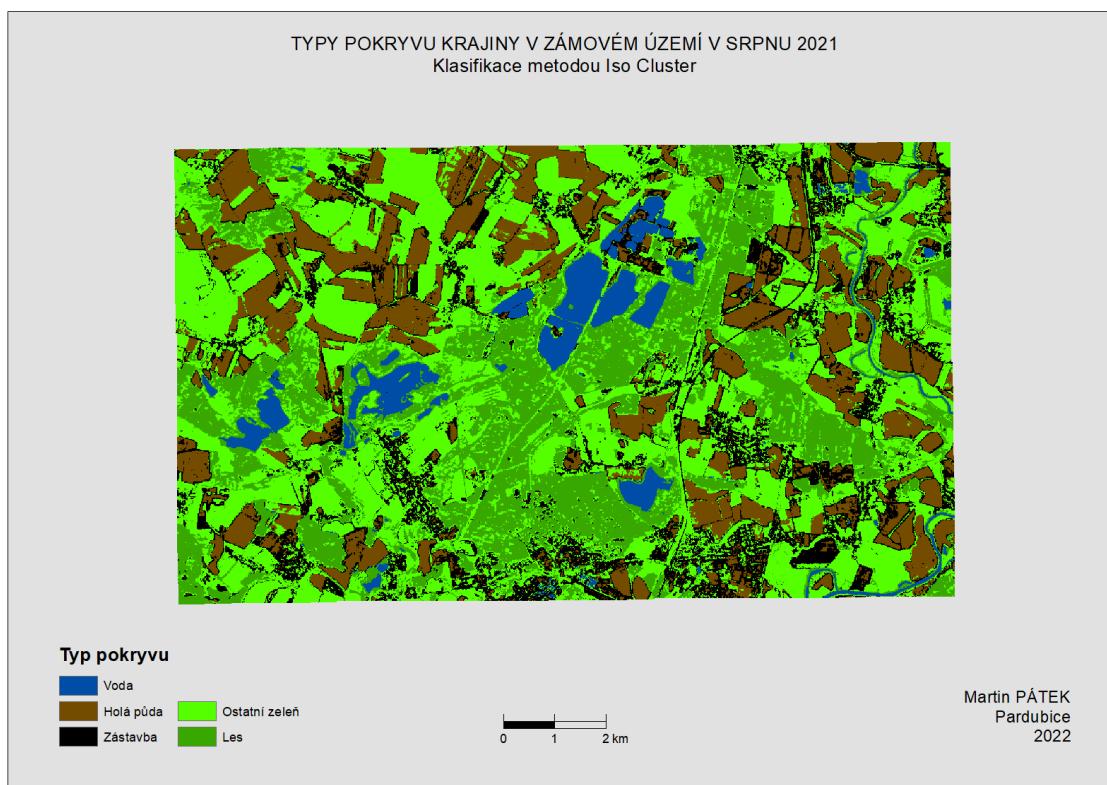
Zdroj: vlastní zpracování

Příloha B – Mapové výstupy klasifikátoru ISO Cluster



Obrázek 40: Výsledek klasifikace ISO – červen

Zdroj: vlastní zpracování



Obrázek 41: Výsledek klasifikace ISO – srpen

Zdroj: vlastní zpracování

Příloha C – Tabulky hodnocení přesnosti – MLC

Tabulka 16: Matice chyb MLC – květen

Třída	Voda	Zástavba	Holá půda	Ostatní zeleň	Les	Celkem	Uživatelská přesnost [%]
Voda	50	0	0	0	0	50	100,00
Zástavba	1	29	9	8	3	50	58,00
Holá půda	0	0	50	0	0	50	100,00
Ostatní zeleň	0	2	1	46	1	50	92,00
Les	1	0	0	0	49	50	98,00
Celkem	52	31	60	54	53	250	
Zpracovatelská přesnost [%]	96,15	93,55	83,33	85,19	92,45		89,60

Zdroj: vlastní zpracování

Tabulka 17: Matice chyb MLC – červen

Třída	Voda	Zástavba	Les	Ostatní zeleň	Holá půda	Celkem	Uživatelská přesnost [%]
Voda	50	0	0	0	0	50	100,00
Zástavba	1	34	1	8	6	50	68,00
Les	0	0	50	0	0	50	100,00
Ostatní zeleň	0	0	1	49	0	50	98,00
Holá půda	0	3	0	0	47	50	94,00
Celkem	51	37	52	57	53	250	
Zpracovatelská přesnost [%]	98,04	91,89	96,15	85,96	88,68		92,00

Zdroj: vlastní zpracování

Tabulka 18: Matice chyb MLC – červenec

Třída	Voda	Zástavba	Les	Ostatní zeleň	Holá půda	Mrak	Celkem	Uživatelská přesnost [%]
Voda	38	0	3	4	5	0	50	76,00
Zástavba	0	20	5	12	13	0	50	40,00
Les	0	0	49	1	0	0	50	98,00
Ostatní zeleň	0	0	2	48	0	0	50	96,00
Holá půda	0	1	1	2	46	0	50	92,00
Mrak	0	0	2	0	2	46	50	92,00
Celkem	38	21	62	67	66	46	300	
Zpracovatelská přesnost [%]	100,00	95,24	79,03	71,64	69,70	100,00		82,33

Zdroj: vlastní zpracování

Tabulka 19: Matice chyb MLC – srpen

Třída	Voda	Zástavba	Les	Ostatní zeleň	Holá půda	Celkem	Uživatelská přesnost [%]
Voda	50	0	0	0	0	50	100,00
Zástavba	2	26	3	12	7	50	52,00
Les	0	0	49	1	0	50	98,00
Ostatní zeleň	0	3	2	43	2	50	86,00
Holá půda	0	0	0	0	50	50	100,00
Celkem	52	29	54	56	59	250	
Zpracovatelská přesnost [%]	96,15	89,66	90,74	76,79	84,75		87,20

Zdroj: vlastní zpracování

Příloha D – Tabulky hodnocení přesnosti – ISO Cluster

Tabulka 20: Matice chyb ISO – červen

Třída	Voda	Les	Zástavba	Holá půda	Ostatní zeleň	Celkem	Uživatelská přesnost [%]
Voda	46	2	1	0	1	50	92,00
Les	0	36	4	2	8	50	72,00
Zástavba	0	0	39	10	1	50	78,00
Holá půda	0	0	6	43	1	50	86,00
Ostatní zeleň	0	4	4	2	40	50	80,00
Celkem	46	42	54	57	51	250	
Zpracovatelská přesnost [%]	100,00	85,71	72,22	75,44	78,43		81,60

Zdroj: vlastní zpracování

Tabulka 21: Matice chyb ISO – červenec

Třída	Voda	Les	Holá půda	Zástavba	Ostatní zeleň	Mraky	Celkem	Uživatelská přesnost [%]
Voda	28	4	8	0	10	0	50	56,00
Les	0	48	0	0	2	0	50	96,00
Holá půda	0	0	49	1	0	0	50	98,00
Zástavba	0	1	25	21	3	0	50	42,00
Ostatní zeleň	0	1	3	0	46	0	50	92,00
Mraky	0	0	1	2	1	46	50	92,00
Celkem	28	54	86	24	62	46	300	
Zpracovatelská přesnost [%]	100,00	88,89	56,98	87,50	74,19	100,00		79,33

Zdroj: vlastní zpracování

Tabulka 22: Matice chyb ISO – srpen

Třída	Voda	Holá půda	Zástavba	Ostatní zeleň	Les	Celkem	Uživatelská přesnost [%]
Voda	46	0	2	2	0	50	92,00
Holá půda	0	47	2	1	0	50	94,00
Zástavba	0	12	29	8	1	50	58,00
Ostatní zeleň	0	5	1	42	2	50	84,00
Les	0	0	1	0	49	50	98,00
Celkem	46	64	35	53	52	250	
Zpracovatelská přesnost [%]	100,00	73,44	82,86	79,25	94,23		85,20

Zdroj: vlastní zpracování

Příloha E – Tabulky hodnocení přesnosti snímku Landsat

Tabulka 23: Matice chyb MLC – Landsat

Třída	Voda	Ostatní zeleň	Holá půda	Zástavba	Les	Celkem	Uživatelská přesnost [%]
Voda	49	0	1	0	0	50	98,00
Ostatní zeleň	0	48	0	2	0	50	96,00
Holá půda	0	0	39	11	0	50	78,00
Zástavba	0	9	10	31	0	50	62,00
Les	0	3	0	1	46	50	92,00
Celkem	49	60	50	45	46	250	
Zpracovatelská přesnost [%]	100,00	80,00	78,00	68,89	100,00		85,20

Zdroj: vlastní zpracování

Tabulka 24: Matice chyb ISO – Landsat

Třída	Voda	Holá půda	Zástavba	Ostatní zeleň	Les	Celkem	Uživatelská přesnost [%]
Voda	50	0	0	0	0	50	100,00
Ostatní zeleň	0	28	21	0	1	50	56,00
Holá půda	0	14	33	3	0	50	66,00
Zástavba	0	3	9	32	6	50	64,00
Les	0	0	0	0	50	50	100,00
Celkem	50	45	63	35	57	250	
Zpracovatelská přesnost [%]	100,00	62,22	52,38	91,43	87,72		77,20

Zdroj: vlastní zpracování