

Univerzita Pardubice

Fakulta ekonomicko-správní

Identifikace vodních ploch v obrazových datech

Bc. Radek Pešek

**Diplomová práce
2017**

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Radek Pešek**
Osobní číslo: **E150039**
Studijní program: **N6209 Systémové inženýrství a informatika**
Studijní obor: **Informatika ve veřejné správě**
Název tématu: **Identifikace vodních ploch v obrazových datech**
Zadávací katedra: **Ústav systémového inženýrství a informatiky**

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

Cílem práce je porovnat klasifikační metody pro klasifikaci vodních ploch v obrazových datech. Práce bude zaměřena na malé vodní plochy, především na určení jejich břehové linie a plochy, z dostupných dat získaných metodami DPZ. Pro porovnání klasifikačních metod budou využity metody vícekriteriálního rozhodování. Budou porovnány klasifikační metody v rámci jednoho zvoleného programového prostředí.

Osnova:

- Dálkový průzkum Země
- Vymezení zájmového území
- Charakteristika vybraných klasifikačních metod
- Porovnání vybraných klasifikačních metod
- Vizualizace výsledků

Rozsah grafických prací:

Rozsah pracovní zprávy: **cca 50 stran**

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

Seznam odborné literatury:

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

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

LILLESAND, T. M., KIEFER, R. W., CHIPMAN, J. W. Remote sensing and image interpretation. 6th ed. New York: John Wiley & Sons, c2008. ISBN 978-0-470-05245-7.

PAVELKA, K. Zpracování obrazových záznamů DPZ. Praha: Vydavatelství ČVUT, 1999. ISBN 80-01-02031-2.

Vedoucí diplomové práce:


doc. Ing. Jitka Komárková, Ph.D.

Ústav systémového inženýrství a informatiky

Datum zadání diplomové práce: **4. září 2016**

Termín odevzdání diplomové práce: **28. dubna 2017**


doc. Ing. Romana Provozničková, Ph.D.

děkanka

L.S.


doc. Ing. Pavel Petr, Ph.D.

vedoucí ústavu

V Pardubicích dne 4. září 2016

PROHLÁŠENÍ

Prohlašuji:

Tuto práci 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., autorský zákon, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

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

V Pardubicích dne 15. 8. 2017

Bc. Radek Pešek

PODĚKOVÁNÍ:

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

ANOTACE

Diplomová práce se zabývá identifikací vodních ploch v obrazových datech. V úvodní části jsou vymezeny základní pojmy z oblasti dálkového průzkumu země včetně oblastí využití a dostupných družicových dat. Druhá část se věnuje podobným případovým studiím na toto téma s identifikací nejlepších metod a nejvyužívanějších družicových dat. Třetí část se zabývá aplikací klasifikačních metod na případovou studii s multikriteriálním vyhodnocením výsledků.

KLÍČOVÁ SLOVA

dálkový průzkum země, Sentinel, Landsat, klasifikace vodních ploch

TITLE

Identification of water surfaces in the image data

ANNOTATION

The diploma thesis deals with the identification of water surfaces in the image data. In the first part defines the basic concepts of remote sensing of the country, including areas of utilization and available satellite data. The second part deals with similar case studies on the subject with identification the best methods and the most widely used satellite data. The third part deals with the application of classification methods to a case study with a multi-criteria evaluation of the results.

KEYWORDS

remote sensing, Sentinel, Landsat, classification of water bodies

OBSAH

ÚVOD.....	12
1 DÁLKOVÝ PRŮZKUM ZEMĚ.....	13
1.1 DEFINICE DÁLKOVÉHO PRŮZKUMU ZEMĚ.....	13
1.2 OBLASTI VYUŽITÍ DÁLKOVÉHO PRŮZKUMU ZEMĚ	14
1.2.1 Meteorologie a klimatologie.....	14
1.2.2 Mapování	14
1.2.3 Hydrologie	15
1.2.4 Geologie a půdy	15
1.2.5 Monitorování vegetace	16
1.3 DRUHY DAT DPZ	16
1.4 KLASIFIKACE OBRAZU	17
1.4.1 Řízená klasifikace.....	17
1.4.2 Neřízená klasifikace	18
1.4.3 Hodnocení přesnosti klasifikace	20
2 DRUŽICOVÁ DATA	22
2.1 NÍZKÉ A STŘEDNÍ ROZLIŠENÍ.....	22
2.2 VYSOKÉ ROZLIŠENÍ	23
2.3 VELMI VYSOKÉ ROZLIŠENÍ.....	24
3 STÁVAJÍCÍ STAV ŘEŠENÉ PROBLEMATIKY	26
3.1 STUDIE Č. 1	26
3.2 STUDIE Č. 2	26
3.3 STUDIE Č. 3	27
3.4 STUDIE Č. 4	28
3.5 STUDIE Č. 5	29
3.6 STUDIE Č. 6	29
3.7 STUDIE Č. 7	30
3.8 STUDIE Č. 8	31
3.9 STUDIE Č. 9	31
3.10 STUDIE Č. 10.....	32
3.11 SHRnutí PŘÍPADOVÝCH STUDÍ	33
3.12 NEJLEPŠÍ A NEJVÍCE POUŽÍVANÉ METODY	36
3.13 NEJPOUŽÍVANĚJŠÍ DRUŽICE	37
4 PŘÍPADOVÁ STUDIE	38
4.1 POSTUP ZPRACOVÁNÍ.....	38
4.2 VYMEZENÍ ZÁJMOVÉHO ÚZEMÍ	38
4.3 VÝBĚR A SBĚR DAT	40
4.4 ZPRACOVÁNÍ A KLASIFIKACE DAT.....	44
4.4.1 <i>Iso Cluster</i>	45
4.4.2 <i>Maximum Likelihood</i>	51
4.4.3 <i>Class Probability</i>	54
4.4.4 <i>Principal Components</i>	57
4.4.5 <i>NDWI – Normalized difference water index</i>	62
4.4.6 <i>Porovnání jednotlivých klasifikačních metod z hlediska přesnosti</i>	64
4.5 POROVNÁNÍ METOD – MULTIKRITERIÁLNÍ ROZHODOVÁNÍ.....	64
4.5.1 <i>Kritéria hodnocení</i>	66
4.5.2 <i>Alternativy řešení</i>	71
4.5.3 <i>Výsledky multikriteriálního rozhodování</i>	71
4.6 VIZUALIZACE VÝSLEDKŮ.....	72
ZÁVĚR	75
POUŽITÁ LITERATURA.....	76
SEZNAM PŘÍLOH	80

SEZNAM TABULEK

Tabulka 1: Příklad klasifikační chybové matice.....	21
Tabulka 2: Družice s nízkým a středním prostorovým rozlišením.....	23
Tabulka 3: Družice s vysokým prostorovým rozlišením.....	24
Tabulka 4: Družice s velmi vysokým prostorovým rozlišením.....	25
Tabulka 5: Shrnutí případových studií	33
Tabulka 6: Přehled nejlepších a nejpoužívanějších metod.....	37
Tabulka 7: Klasifikační matice z klasifikace metodou Iso Cluster (5 tříd) z dat Landsat 8.....	47
Tabulka 8: Klasifikační matice z klasifikace metodou Iso Cluster (20 tříd) z dat Landsat 8...	48
Tabulka 9: Klasifikační matice z klasifikace metodou Iso Cluster (5 tříd) z dat Sentinel 2	49
Tabulka 10: Klasifikační matice z klasifikace metodou Iso Cluster (20 tříd) z dat Sentinel 2	50
Tabulka 11: Klasifikační matice z klasifikace metodou Maximum Likelihood z dat Landsat 8	53
Tabulka 12: Klasifikační matice z klasifikace metodou Maximum Likelihood z dat Sentinel 2	54
Tabulka 13: Klasifikační matice z klasifikace metodou Class Probability z dat Landsat 8.....	55
Tabulka 14: Klasifikační matice z klasifikace metodou Class Probability z dat Sentinel 2	56
Tabulka 15: Klasifikační matice z klasifikace metodou Principal Components (3) a Iso Cluster z dat Landsat 8.....	58
Tabulka 16: Klasifikační matice z klasifikace metodou Principal Components (8) a Iso Cluster z dat Landsat 8.....	59
Tabulka 17: Klasifikační matice z klasifikace metodou Principal Components (3) a Iso Cluster z dat Sentinel 2	60
Tabulka 18: Klasifikační matice z klasifikace metodou Principal Components (10) a Iso Cluster z dat Sentinel 2.....	61
Tabulka 19: Klasifikační matice z klasifikace pomocí NDWI z dat Sentinel 2	63
Tabulka 20: Porovnání jednotlivých klasifikačních metod z hlediska přesnosti.....	64
Tabulka 21: Saatyho stupnice relativních důležitostí	65
Tabulka 22: Důležitost a váha kritérií hodnocení.....	66
Tabulka 23: Porovnání klasifikačních algoritmů podle špatně klasifikovaných bodů.....	67
Tabulka 24: Porovnání klasifikačních algoritmů podle odchylky z vybraných referenčních ploch	68
Tabulka 25: Porovnání klasifikačních algoritmů podle náročnosti	69
Tabulka 26: Porovnání klasifikačních algoritmů podle odchylky z celkové výměry vodních ploch	70
Tabulka 27: Porovnání klasifikačních algoritmů podle času trvání	71
Tabulka 28: Alternativy multikriteriálního rozhodování.....	71
Tabulka 29: Výsledky z multikriteriálního rozhodování.....	72
Tabulka 30: Spektrální pásma družice Landsat 8.....	86
Tabulka 31: Spektrální pásma družice Sentinel 2	87

SEZNAM OBRÁZKŮ

Obrázek 1: Oblačnost a srážky nad ČR z družice NOAA.....	14
Obrázek 2: Aplikace mapy.cz nad leteckými snímky	15
Obrázek 3: Detekce ropného znečištění	15
Obrázek 4: Evidence kontaminovaných míst ve městě Pardubice	16
Obrázek 5: Monitorování stavu vegetace	16
Obrázek 6: Základní kroky v řízené klasifikaci.....	18
Obrázek 7: Identifikace seskupení v neřízené klasifikaci	19

Obrázek 8: Postup zpracování příkladové studie	38
Obrázek 9: Vymezení zájmového území	39
Obrázek 10: Přehled pásem a jejich parametrů družic Landsat 7 a Landsat 8	41
Obrázek 11: Přehled pásem a jejich parametrů družice Sentinel 2	42
Obrázek 12: Záběr scény snímané družicí Landsat 8	43
Obrázek 13: Záběr scény snímané družicí Sentinel 2.....	44
Obrázek 14: Klasifikace metodou Iso Cluster (5 tříd) z dat Landsat 8	46
Obrázek 15: Klasifikace metodou Iso Cluster (20 tříd) z dat Landsat 8	47
Obrázek 16: Klasifikace metodou Iso Cluster (5 tříd) z dat Sentinel 2.....	49
Obrázek 17: Klasifikace metodou Iso Cluster (20 tříd) z dat Sentinel 2.....	50
Obrázek 18: Trénovací plochy pro řízenou klasifikaci	51
Obrázek 19: Klasifikace metodou Maximum Likelihood z dat Landsat 8.....	52
Obrázek 20: Klasifikace metodou Maximum Likelihood z dat Sentinel 2	53
Obrázek 21: Klasifikace metodou Class Probability z dat Landsat 8.....	55
Obrázek 22: Klasifikace metodou Class Probability z dat Sentinel 2	56
Obrázek 23: Klasifikace metodou Principal Components (3) a Iso Cluster z dat Landsat 8 ...	58
Obrázek 24: Klasifikace metodou Principal Components (8) a Iso Cluster z dat Landsat 8 ...	59
Obrázek 25: Klasifikace metodou Principal Components (3) a Iso Cluster z dat Sentinel 2 ...	60
Obrázek 26: Klasifikace metodou Principal Components (10) a Iso Cluster z dat Sentinel 2 .	61
Obrázek 27: Klasifikace pomocí NDWI z dat Sentinel 2.....	63
Obrázek 28: Tříúrovňová hierarchická struktura.....	65
Obrázek 29: Standardní hodnoty průměrného indexu náhodné konzistence RI	66
Obrázek 30: Ruční klasifikace dvou vodních ploch.....	68
Obrázek 31: Výsledek klasifikace metodou Iso Cluster (5 tříd) z dat Sentinel 2 na podkladové topografické mapě	73
Obrázek 32: Výsledek klasifikace metodou Iso Cluster (5 tříd) z dat Sentinel 2 na podkladu pásma 8A	73
Obrázek 33: Srovnání klasifikace pomocí NDWI – vlevo a klasifikace metodou Iso Cluster (5 tříd) – vpravo z dat Sentinel 2	74
Obrázek 34: Výběr dat krok 1-4	82
Obrázek 35: Výběr dat krok 5-8	83
Obrázek 36: Výběr dat krok 9-10	84
Obrázek 37: Výběr dat krok 11-12	85
Obrázek 38: výsledek klasifikace metodou Class Probability (4 třídy) z dat Sentinel 2 na podkladové topografické mapě.....	89
Obrázek 39: Výsledek klasifikace metodou Class Probability (4 třídy) z dat Sentinel 2 na podkladu pásma 8A	89

SEZNAM ZKRATEK A ZNAČEK

AHP	Analytic hierarchy process
AMERL	Automated method for extracting rivers and lakes
ASWM	Automatic subpixel water mapping method
AUWEM	Automatic urban water extraction method
AWEI	Automated water extraction index
AWEInsh	Automated water extraction index with no shadow
AWEIsh	Automated water extraction index with shadow
CEM	Constrained energy minimization
CI	Consistency index
CR	Consistency ratio
ČR	Česká republika
DPZ	Dálkový průzkum Země
ELM	Extreme learning machine
ETM+	Enhanced thematic mapper plus
FCLS	Fully constrained least squares
FPC	First principal component
GIS	Geografický informační systém
LORSAL	Logistic regression via variable splitting and augmented lagrangian
LSWI	Land surface water index
LSWI	Land surface water index
MESMA	Multiple endmember spectral mixture analysis
ML	Maximum likelihood
MNDWI	Modified normalized difference water index
MRSB	Most related single band
MS	Microsoft
MSG	Meteosat second generation
MSI	Multi spectral instrument
NDVI	Normalized difference vegetation index
NDWI	Normalized difference water index
NDWI-PC	Normalized difference water index of principal components
NIKM	Národní inventarizace kontaminovaných míst

NIR	Near Infrared
NNDWI	New normalized difference water Indexes
NOAA	National oceanic and atmospheric administration
NPR	Národní přírodní rezervace
OLI	Operational Land Image
RF	Random forest
RI	Random index
SMA	Spectral mixture analysis
SVM	Support vector machines
SWIR	Short-wave infrared
TB	Tree bagger
TCW	Tasseled cap wetness index
TIR	Thermal infrared
TIRS	Thermal Infrared Sensor
TM	Thematic Mapper
UTM	Univerzální transverzální Mercatorův systém souřadnic
WGS	World geodetic system
WI	Water index
WRI	Water Ratio Index

ÚVOD

Diplomová práce se věnuje identifikaci vodních ploch v obrazových datech pomocí klasifikačních metod, které jsou součástí zvoleného programového prostředí.

V dnešní době se dálkový průzkum země (DPZ) rozšiřuje do všech oblastí lidské činnosti. Využití dat z DPZ v mnoha oborech je velkou výhodou. Data z DPZ jsou nejrozšířenější k těmto účelům: sledování stavu vegetace, k předpovědi počasí, k mapování zemského povrchu, k monitorování vodních ploch v různých měřítkách, atd. Tato diplomová práce je zaměřena na vodní plochy v lokálním měřítku. Klasifikace vodních ploch v lokálním měřítku může být využita k detekci změn výměry vodních ploch rybníku, řek a jezer. Dále může být využita k detekci změn břehové linie atd.

Cílem této diplomové práce je porovnat všechny klasifikační metody pro klasifikaci vodních ploch v obrazových datech v rámci zvoleného programového prostředí. Práce je zaměřena na malé vodní plochy v okolí Pardubického kraje. Toto zájmové území bylo vybráno z hlediska znalosti zpracovatele této oblasti a také s ohledem návaznosti dalších prací na Univerzitě Pardubice. Pro porovnání a vyhodnocení klasifikačních metod bude využita metoda multikriteriálního rozhodování a to konkrétně metoda AHP – Analytic Hierarchy Process.

1 DÁLKOVÝ PRŮZKUM ZEMĚ

Dálkový průzkum Země (DPZ) je moderní a neustále se rozvíjející metoda, kterou získáváme informace o objektech a jevech na zemi. Jedná se vlastně o zkoumání zemského povrchu (vody a souše), dolních vrstev atmosféry, ale i vrstev sedimentů či vodního sloupce a dalších jevů a objektů, které zde probíhají na dálku. DPZ v posledních letech dosahuje obrovského rozmachu v nejrůznějších oborech lidské činnosti. Data pořízená metodou DPZ využívá stále více aplikací a využívá je mnoha oblastí. Data jsou využívána stále více, jelikož dnešní výpočetní technologie značně usnadnily zpracovávat potřebná data a dostávat z nich potřebné informace. Velkou předností dat z DPZ je použití v různých odvětvích lidské činnosti. Mezi nejznámější patří např. předpověď počasí, vyhledávání nerostných surovin, mapování oblastí, sledování stavu vegetace atd. [3][20][8]

1.1 Definice dálkového průzkumu Země

Pro metodu dálkového průzkumu Země existuje mnoho definic. Vymezením tohoto pojmu se zabývala celá řada zahraničních i českých autorů. Zde je uvedeno jen pár nejvíce používaných konvenčních, ale i nekonvenčních definic, z kterých také lze můžeme získat určitou představu o DPZ. [3][17]

Konvenční definice

- *Dálkový průzkum je věda umění získávat užitečné informace o objektech, plochách či jevech prostřednictvím dat měřených na zařízeních, která s těmito zkoumanými objekty, plochami či jevy nejsou v přímém kontaktu.* [3]
- *Dálkový průzkum je shromažďování informací o přírodních zdrojích s využitím snímků pořízených senzory umístěnými na palubách letadel nebo družic.* [3]

Nekonvenční definice

- *Dálkový průzkum je nejdražší způsob, jak vytvořit obrázek.* [3]
- *Dálkový průzkum je umění rozdělit svět na množství malých barevných čtverečků, se kterými si lze hrát na počítači s cílem odhalení jejich neuvěřitelného potenciálu.* [3]


1.2 Oblasti využití dálkového průzkumu Země

Výčet oblastí, kde je možné využít data z DPZ je velmi rozsáhlý a není jej možné celý vypsat. Vedle klasických oblastí jako je meteorologie, mapování, hydrologie atd. se objevují stále nové a nové oblasti využití. Níže jsou popsány základní oblasti využití dat z DPZ.

Velkou výhodou DPZ je pořízení dat z rozsáhlého a mnohdy nepřístupného území v jednom okamžiku. Další výhodou je získání informace z celého elektromagnetického spektra, díky kterému můžeme sledovat jevy, který jsou okem neviditelné (např. teplota povrchu). Naopak odrazující může být vysoká cena pořízení snímku nebo speciálního programu na jeho zpracování. Ovšem dnes už je možné získat mnoho družicových dat zdarma a také existují různé volně dostupné programy na základní zpracování družicových dat. [23]

1.2.1 Meteorologie a klimatologie

Typickým příkladem využití družicových dat s nízkým prostorovým rozlišením je v obor meteorologie a klimatologie. Tyto data poskytují např. družice NOAA nebo MSG a využívají se zejména k předpovědi počasí a k monitoringu atmosférických jevů. Déle jsou využívány k sledování znečištění ovzduší, sledování povrchové teploty Země, sledování skleníkových plynů v atmosféře atd. Na obrázku 1 je vidět oblačnost a srážky nad ČR z družice NOAA. [23]



Obrázek 1: Oblačnost a srážky nad ČR z družice NOAA

Zdroj: upraveno podle [1]

1.2.2 Mapování

Data DPZ se často využívají pro vytváření map různých měřítek. Od velmi podrobných map až po mapy středních a velkých měřítek. Výhodou je rychlé pořízení dat z velkých ploch

či špatně přístupné oblasti. Na obrázku 2 je znázorněna aplikace mapy.cz nad leteckými snímky. [23]




Obrázek 2: Aplikace mapy.cz nad leteckými snímky

Zdroj: upraveno podle [19]

1.2.3 Hydrologie

Pomocí dat z DPZ je možné monitorovat vody jak v globálním, regionálním tak i lokálním měřítku. Je možné sledovat znečištění vod např. ropnými haváriemi nebo sinicemi a dalšími látkami či mikroorganismy. Další použití je v případě monitorování povodní, tání ledovců, mořských proudů, teploty vod, stanovování vodních dopravních cest, detekce tsunami atd. Na obrázku 3 je ukázka z detekce ropného znečištění pobřeží. [23]



Obrázek 3: Detekce ropného znečištění

Zdroj: vlastní zpracování

1.2.4 Geologie a půdy

Dalším příkladem využití dat z DPZ je zjišťování geologického složení půdy a k sledování kontaminace půdy. Zde jsou vhodná zejména hyperspektrální data. Příkladem je projekt

NIKM, který slouží pro evidenci kontaminovaných míst, kde byla využity letecká data i družicová multispektrální a hyperspektrální data. Na obrázku 4 můžeme vidět ukázkou kontaminovaných míst ve městě Pardubice z projektu NIKM. [23]



Obrázek 4: Evidence kontaminovaných míst ve městě Pardubice

Zdroj: upraveno podle [22]

1.2.5 Monitorování vegetace

Velmi populární použití dat z DPZ je k monitorování stavu vegetace (např. obsahu chlorofylu nebo vody v rostlinách). DPZ umožňuje pravidelně a dlouhodobě monitorovat a zjišťovat zdravotní stav vegetace rozsáhlých území. [23]



Obrázek 5: Monitorování stavu vegetace

Zdroj: vlastní zpracování

1.3 Druhy dat DPZ

Pořízená data z měření lze rozdělit podle několika hledisek. [8]

- 1) Podle výsledku měření

- Obrazová data – nejčastějším typem dat v DPZ jsou letecké či družicové fotografie
- Neobrazová data – tento typ dat je zobrazen např. pomocí grafů, tabulek

2) Podle nosiče měřící aparatury

- Letecká data – hlavním typem a tradičním nosičem záznamových zařízení vzdušného typu jsou letadla, vrtulníky ale i balóny
- Družicová data – stále větší aktuálnosti nabývají snímky z kosmických nosičů neboli družic

3) Podle druhu záznamu

- Analogová data – data jsou pořizována na filmový materiál
- Digitální data – data jsou pořizována v číselné podobě

1.4 Klasifikace obrazu

Jednou z nejčastějších cílovou částí zpracování dat z DPZ je klasifikace. Obecným cílem klasifikace je rozřadit všechny obrazové body (pixely) do jednotlivých informačních tříd za použití určitých rozhodovacích pravidel (tzv. klasifikátorů). Tyto třídy mohou představovat například jednotlivé druhy povrchů na zemi (land cover) nebo využití země (land use), ale i mohou představovat i jiná témata, záleží na zaměření projektu. Klasifikátory mohou být založeny na různých vlastnostech objektů a jevů v obraze (např. na prostorovém, časovém či spektrálním chování objektů). Ovšem v současné době se ke klasifikaci obrazu nejvíce využívají klasifikátory založené na spektrálním chování objektů.

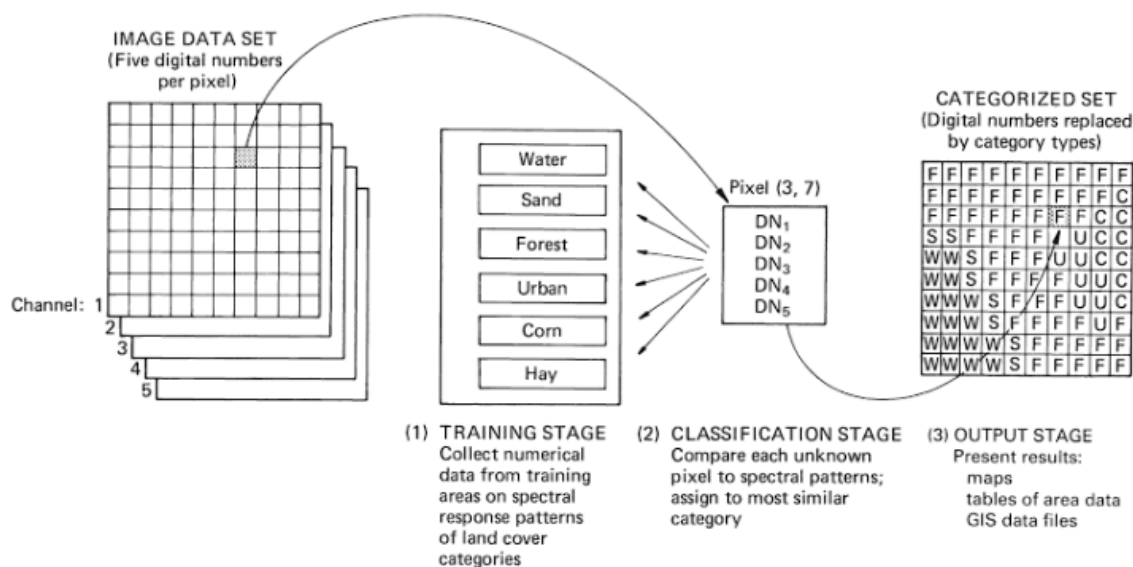
Klasifikace se dělí na řízenou a neřízenou. Dělí se podle toho, jakým způsobem a v kterém okamžiku zpracovatel zasahuje do procesu klasifikace. [3][17]

1.4.1 Řízená klasifikace

Při použití řízené klasifikace zpracovatel definuje algoritmu povrchy tzv. trénovací plochy, které chce v daném obraze hledat. Algoritmus poté bude hledat dané povrchy v obraze, podle předložených vzorů. Trénovací plocha je část obrazu, o které může zpracovatel na základě různých podpurných dat např. mapy, letecké snímky, terénní průzkumy prohlásit, že je představitelem daného povrchu. [3][11]

Na obrázku 6 jsou zobrazeny tři základní kroky v řízené klasifikaci. Vstupem jsou digitální data v několika pásmech. Při výstupu jsou digitální data nahrazeny kategorií. [17]

- 1) tréninková etapa – nasbírání statistických charakteristik (tzv. spektrálních vlastností) jednotlivých trénovacích ploch (např. land cover – druhy povrchů)
- 2) klasifikační etapa – porovnání každého pixelu se spektrálními vzory a přiřazení do nejpodobnější kategorie
- 3) výstupní etapa – prezentace výsledků (např. mapy, tabulky, GIS data)



Obrázek 6: Základní kroky v řízené klasifikaci

Zdroj: [17]


Celý postup řízené klasifikace obsahuje následující kroky. [3][17]

- 1) definování reprezentativních trénovacích ploch
- 2) výpočet statistických charakteristik (tzv. spektrálních vlastností) jednotlivých trénovacích ploch, které reprezentují jednotlivé třídy v obraze
- 3) zvolení vhodného klasifikátoru, který zařadí jednotlivé pixely obrazu do jednotlivých tříd, kterým se nejvíce podobají
- 4) zatřídění všech pixelů obrazu do definovaných tříd
- 5) úprava, zhodnocení a prezentace výsledků klasifikace

1.4.2 Neřízená klasifikace

V případě použití neřízené klasifikace její algoritmy nevyužívají tréninková data jako základ pro klasifikaci. V prvním kroku jsou zatříděny všechny pixely v obraze do určitých tříd na základě přírodních seskupení např. metodou shlukové analýzy. Poté zpracovatel přiřazuje jednotlivým třídám informační význam.

Pro ilustraci na obrázku 7 jsou použita data ze dvou pásem. Vynesemím dat od bodového diagram je zde viditelné přírodní spektrální seskupení. Data jsou získána ze zalesněných oblastí. Tři seskupení jsou viditelná z bodového diagramu. Při bližším zkoumání na základně referenčních údajů je zjištěno, že jedno seskupení odpovídá listnatým stromům – D, další seskupení odpovídá jehličnatým stromům – C, a poslední seskupení odpovídá obou druhům stromů – S. V neřízené klasifikaci nemusíme identifikovat trénovací plochy, což ukazuje na jednu z hlavních výhod. Klasifikátor identifikuje zřejmé spektrální třídy, které jsou v obrazových datech. Mnoho těchto tříd nemusí analytik při řízené klasifikaci zpočátku objevit. Stejně tak může být spektrálních tříd být tolik, že není možné, aby je analytik zpočátku všechny určil. V neřízené klasifikaci se všechny tyto spektrální třídy nalézají automaticky. [3][17][11]



Obrázek 7: Identifikace seskupení v neřízené klasifikaci

Zdroj: [17]

Celý postup řízené klasifikace obsahuje následující kroky. [3][17]

- 1) určení přibližného počtu shluků (např. určením maximální a minimálního počtu shluků)

- 2) vygenerování počáteční polohy centroidu pro každý shluk
- 3) postupné zařazení každého pixelu do shluku, ke kterému má v příznakové prostoru nejbližší
- 4) výpočet nového centroidu pro každý shluk na základě přiřazených pixelů
- 5) opakování kroku 3 a 4 do té doby, dokud se poloha shluku či počet pixelů zařazených do shluku výrazně nemění
- 6) přiřazení významu každému shluku (tzv. stabilnímu shluku)
- 7) vytváření informačních tříd spojováním tříd spektrálních

1.4.3 Hodnocení přesnosti klasifikace

Schopnost vytváření digitálních klasifikací povrchů země výrazně předčila schopnost vyčíslit jejich přesnost. Ve skutečnosti tento problém někdy vylučuje použití automatizovaných technik klasifikace povrchů země, i když jejich náklady jsou příznivě srovnatelné s tradičnějšími prostředky sběru dat. Zde platí toto spojení "Klasifikace není úplná, dokud není posouzena její přesnost." Zde jsou uvedeny dvě základní možnosti zhodnocení úspěšnosti klasifikace. [17]

- **klasifikační chybová matice**

- přesnost klasifikace se většinou hodnotí podle tzv. klasifikační chybové matice znázorněná na obrázku 1, který vyjadřuje vztah mezi výsledky klasifikace a skutečností
- matice je čtvercová o rozměrech $n \times n$, kde n je počet kategorií
- hodnoty v matici reprezentují počet pixelů nebo také jejich procentní část
- každý sloupec reprezentuje hodnoty získané klasifikací a každý řádek hodnoty ve skutečnosti (někdy to může být naopak, záleží na interpretaci)
- matice dává informaci o tom, jak klasifikované hodnoty odpovídají hodnotám skutečným
- chyby v klasifikaci představují hodnoty mimo hlavní diagonálu
- matice je nástrojem, který umožňuje posoudit, jak klasifikátor data zpracovává, například jestli nějakou třídu neklasifikuje jako jinou [31]

Tabulka 1: Příklad klasifikační chybové matice

Klasifikace	Les	Voda	Pole	Celkem řádky
Skutečnost				
Les	11	5	0	16
Voda	3	5	1	9
Pole	0	2	13	15
Celkem sloupce	14	12	14	40

Zdroj: upraveno podle [31]

V klasifikační chybové matici je 16 pixelů lesa, z toho klasifikátor 5 z nich zařadil jako vodu. V matici je 9 pixelů vody, z toho klasifikátor 3 z nich zařadil jako les a 1 pixel jako pole. V matici je také 15 pixelů pole, z toho klasifikátor zařadil 2 pixely jako vodu.

Z této klasifikační chybové matice můžeme vyvodit že:

- klasifikátor nedokáže dobře rozlišit les a vodu
- klasifikátor celkem dobře dokáže rozlišit pole od ostatních ploch [31]

- **kappa koeficient**

- nejpoužívanější index pro vyjádření přesnosti klasifikace
- koeficient porovnává výsledek klasifikace s náhodným zařazováním pixelů do jednotlivých tříd
- výpočet koeficientu je založen na tom, že i při náhodném zařazování pixelů do jednotlivých tříd bude určité procento pixelů zařazeno správně
- výsledné hodnoty koeficientu kappa se pohybuje v rozmezí od 0 do 1 (1 – perfektní shoda, 0 – náhodný výsledek), někdy může být i záporný a to pokud je podíl shodných pixelů nízký [31]

$$K = \frac{O - E}{1 - E}, \quad (1)$$

kde: O – pozorovaná přesnost, tj. zjištěný podíl správných výsledků

E – dosažená přesnost náhodným zařazením pixelů do jednotlivých tříd

Například výsledná hodnota $K = 0,67$ znamená, že klasifikace je o 67% lepší než náhodné zařazení pixelů do jednotlivých tříd. Pokud by vyšlo $K = 0$, tak by to znamenalo, že výsledná klasifikace není lepší než náhodné zařazení pixelů. [31]

2 DRUŽICOVÁ DATA

Družicové snímky se v posledních letech začali využívat více a více v různých oborech lidské činnosti. Toto rozšíření do různých oblastí lidských činností bylo umožněno zejména velkým technologickým vývojem v oblasti DPZ a proto se tento obor z oblasti výzkumné a vojenské do oblasti komerční sféry. V dnešní době už prakticky neexistuje žádné omezení v dostupnosti družicových dat, jelikož počet družic pořizujících data pro komerční účely dosahuje několika desítek a dále se objevují nové. Díky lepší dostupnosti družicových dat jsou stále více využívány. Každý uživatel si dnes může vybrat data vhodná pro jeho potřebu a využití. Uživatel má i možnost si definovat přesné území, vhodně časové období, množství oblačnosti a další parametry pořizovaných družicových dat. Ceny už nejsou tak vysoké jako v předešlých letech, ale přizpůsobily se konkurenčnímu prostředí a jsou vhodnou alternativou k ostatním postupům pořizování dat (letecké snímkování, pozemní mapování, atd.). [7]

Nejvýznamnější pokrok během posledních let přišel zejména v prostorovém rozlišení, kde nejnovější družice mohou pořizovat snímky v prostorovém rozlišení lepší než 1 m. Tyto data jsou vhodná pro mapování v měřítku až cca 1 : 5 000. [7]

2.1 Nízké a střední rozlišení

Družicová data nízkého rozlišení jsou pořizována v prostorovém rozlišení v řádech 1 km. Jsou označována zkratkou LR – z anglického low resolution. U družicových dat středního rozlišení se prostorové rozlišení pohybuje v řádech 100 m. Tato data jsou označována zkratkou MR – medium resolution. Data nízkého a středního prostorového rozlišení jsou zpravidla pořizována v multispektrálním režimu s viditelnou a infračervenou částí optického spektra. Vzhledem k šířce záběru jsou data snímána až s několikadenní frekvencí. [7]

Data jsou vhodná pro mapování v měřítku cca 1 : 1 000 000.

Přehled aplikací:

- globální a kontinentální mapování
- sledování stavu a vývoje vegetace
- modelování vývoje zemědělských plodin a předpovídání výnosů
- monitorování rozsáhlých přírodních katastrof
- sledování stavu a vývoje sněhového pokryvu a ledovců
- sledování stavu a vývoje atmosféry a oceánů [7]

V následující tabulce 2 je zobrazen přehled nejznámějších družic, které poskytují družicová data nízkého a středního rozlišení.

Tabulka 2: Družice s nízkým a středním prostorovým rozlišením

Družice	Senzor	Počet pásem	Prostorové rozlišení [m]	Archiv od
Sentinel-3 A	OLCI	21	300	2016
Sentinel-3 A	SLSTR	9	500, 1000	2016
Landsat 8	TIRS	2	100	2013
Meteosat MSG	GERB	7	40000	2002
Meteosat MSG	SEVIRI	12	1000, 3000	2002
SPOT 5	VEGETATION	4	1000	2002
TERRA	MODIS	36	250, 500, 1000	2000
SPOT 4	VEGETATION	4	1000	1998
OrbView-2	SeaWiFS	8	1130	1997

Zdroj: upraveno podle [7]

2.2 Vysoké rozlišení

Družicová data vysokého rozlišení jsou pořizována v prostorovém rozlišení v řádu 10 m. Tyto data se také označují jako HR – z anglického high resolution. Data z družic s vysokým prostorovým rozlišením jsou pořizována v multispektrálním i panchromatickém režimu viditelného a také se značným podílem jednotlivých částí infračerveného optického spektra. Pořizování těchto dat probíhá v několikátýdenních intervalech. [7]

Data jsou vhodná pro mapování v měřítku cca 1 : 50 000.

Přehled aplikací:

- regionální mapování/plánování
- mapování stavu, vývoje a změn v krajině (land cover/land use)
- sledování stavu a vývoje vegetace
- mapování zemědělských ploch a klasifikace zemědělských plodin
- sledování stavu lesních porostů a klasifikace lesních ekosystémů
- monitorování rozvoje měst
- sledování lesní těžby
- geologické mapování
- geomorfologické mapování
- mapování důsledků přírodních katastrof
- tvorba digitálního modelu terénu [7]

V tabulce 3 jsou vypsány nejvyžívanější družice s vysokým prostorovým rozlišením.

Tabulka 3: Družice s vysokým prostorovým rozlišením

Družice	Senzor	Počet pásem	Prostorové rozlišení [m]	Archiv od
Sentinel-2 A	MSI	13	10, 20, 60	2015
WorldView-3	CAVIS	12	30	2014
WorldView-3	SWIR	8	3,7	2014
Landsat 8	OLI	9	15, 30	2013
SPOT 5	HRG_MS	4	10, 20	2002
SPOT 5	HRG_PAN	1	5	2002
SPOT 5	HRS	1	10	2002
TERRA	ASTER	14	15, 30, 90	2000
Landsat 7	ETM+	8	15, 30, 60	1999
SPOT 4	HRVIR_MS	4	20	1998
SPOT 4	HRVIR_PAN	1	10	1998
SPOT 3	HRV_MS	3	20	1993
SPOT 3	HRV_PAN	1	10	1993
SPOT 2	HRV_MS	3	20	1990
SPOT 2	HRV_PAN	1	10	1990
SPOT 1	HRV_MS	3	20	1986
SPOT 1	HRV_PAN	1	10	1986
Landsat 5	MSS	4	80	1985
Landsat 5	TM	7	30, 120	1985
Landsat 4	MSS	4	80	1982
Landsat 4	TM	7	30, 120	1982
Landsat 3	MSS	4	80	1978
Landsat 3	RBV	1	30	1978
Landsat 2	MSS	4	80	1975
Landsat 2	RBV	3	80	1975
Landsat 1	MSS	4	80	1972
Landsat 1	RBV	3	80	1972

Zdroj: upraveno podle [7]

2.3 Velmi vysoké rozlišení

Družicová data s velmi vysokým rozlišením se pořizují v rozlišení v řádech 1 m. Data ve velmi vysokého rozlišení se také označují jako VHR – z anglického very high resolution. Tyto data mohou být pořizována jak v pouze panchromatickém tak v kombinaci s multispektrálním režimem, což je častější variantou. Tento sektor se stal nejvíce rozvíjejícím se sektorem v DPZ. Většina družic z tohoto sektoru patří k nejmodernějším družicovým systémům v DPZ, které se mohou přizpůsobovat přáním zákazníka. [7]

Data jsou vhodná pro mapování v měřítku cca 1 : 10 000.

Přehled aplikací:

- plánování a projektování liniových staveb
- mapování dopravních sítí
- inventarizace lesních porostů
- mapování rozptýlené vegetace
- monitorování povrchových dolů, skládek a rekultivace
- mapování půdní eroze
- plánování a organizace humanitární pomoci
- pojišťovnictví
- tvorba digitálního modelu terénu
- 3D modely měst
- kontrola zemědělských aktivit
- precizní zemědělství [7]

V tabulce 4 jsou zobrazeny nejvyužívanější a nejmodernější družice poskytující data velmi vysokého prostorového rozlišení.

Tabulka 4: Družice s velmi vysokým prostorovým rozlišením

Družice	Senzor	Počet pásem	Prostorové rozlišení [m]	Archiv od
WorldView-4	MS	4	1.24	2017
WorldView-4	PAN	1	0.31	2017
SPOT 7 - Azersky	NAOMI MS	4	6.0	2014
SPOT 7 - Azersky	NAOMI PAN	1	1.5	2014
WorldView-3	MS	8	1.24	2014
WorldView-3	PAN	1	0.31	2014
Pléiades 1B	MS - HiRI	4	2.8	2013
Pléiades 1B	PAN - HiRI	1	0.5	2013
SPOT 6	NAOMI MS	4	6.0	2013
SPOT 6	NAOMI PAN	1	1.5	2013
Pléiades 1A	MS - HiRI	4	2.8	2012
Pléiades 1A	PAN - HiRI	1	0.5	2012
WorldView-2	MS	8	1.84	2009
WorldView-2	PAN	1	0.5	2009
GeoEye-1	MS	4	2.0	2008
GeoEye-1	PAN	1	0.5	2008
WorldView-1	PAN	1	0.5	2007
OrbView-3	MS	4	4.0	2003
OrbView-3	PAN	1	1.0	2003
QuickBird	MS	4	2.4	2001
QuickBird	PAN	1	0.6	2001
Ikonos	MS	4	4.0	1999
Ikonos	PAN	1	1.0	1999

Zdroj: upraveno podle [7]

3 STÁVAJÍCÍ STAV ŘEŠENÉ PROBLEMATIKY

3.1 Studie č. 1

Název studie: Kombinace pixel-objekt založeného strojového učení pro identifikaci vodních těles z městských částí pomocí dálkového snímání s vysokým rozlišením [9]

Zájmové území: Dvě typická velká města Číny, Shenzhen a Wuhan, jsou vybrána jako testovací místa v této studii. Shenzhen je jedním z několika nejvíce rozvinutých měst v Číně. Jeho sladkovodní zdroje jsou však velmi omezené a vlastnictví vodních zdrojů na obyvatele pro Shenzhen je jen jedna třetina národního průměru. Obecně platí, že Shenzhen je město s nedostatkem vody. Řízení a sledování vodních zdrojů je tudíž nezbytné pro územní plánování a rozhodování. Další studijní místo, Wuhan City, však ukazuje zcela jiný scénář. Wuhan se nazývá "město na řekách", což je největší vnitrozemský přístav na středním toku řeky Yangtze. Má bohaté vodní zdroje s řadou různých jezer, řek, rybníků a kanálů. Její plocha pokrývá 25% celého města a jeho hrubé množství vodních zdrojů zaujímá v Číně vysoké místo. [9]

Cíl: V této studii je navržena nová dvouúrovňová struktura strojového učení pro identifikaci typů vody z městských snímků s vysokým rozlišením s pomocí dálkového snímání. Rámec se skládá ze dvou úrovní interpretace: 1) vodní útvary jsou extrahovány na úrovni pixelů, kde jsou zvažovány vodní / stínové / vegetační indexy a 2) vodní typy jsou dále identifikovány na úrovni objektu. Obě úrovně využívají strojové učení pro interpretaci obrazu. Navrhovaný rámec je validován pomocí obrazů GeoEye-1 a WorldView-2, ve dvou velkých městech v Číně, tj. Wuhan a Shenzhen. [9]

Zjištění: Experimentální výsledky ukazují, že navrhovaná metoda dosáhla uspokojivé přesnosti jak pro extrakci vody (Shenzhen - 95,4%, Wuhan - 96,2%), tak pro klasifikaci typu vody (Shenzhen - 94,1%, Wuhan - 95,9%) v komplexních městských oblastech. [9]

3.2 Studie č. 2

Název studie: Mapování inundace v heterogenních mokřadech lužních lesů Macquarie Marshes, používající tematický mapovač Landsat. [28]

Zájmové území: Macquarie Marshes jsou v nízkém ústí povodí řeky Macquarie-Bogan (74 700 km²) Murray-Darlingské pánve v polosuché Austrálii. Jedná se o jednu z velkých sladkovodních mokřadů v Murray-Darlingské pánvi. [28]

Cíl: Zmapovali jsme inundaci v Macquarie Marshes pomocí snímků Landsat 5 TM a Landsat 7 ETM + (1989-2010). Klasifikovali jsme tři třídy inundace: voda, smíšené obrazové body (voda, vegetace, půda) a vegetace (vznikající makrofyty zakrývající inundaci), sloučené k mapování zaplavených oblastí z neindukovaných oblastí (suchá půda). Použili jsme index normalizovaného rozdílu vody (NDWIB2 / B5), maskovaný součtem pásem 4, 5 a 7 (sum457), abychom detekovali vodu a smíšené pixely. Vegetace byla klasifikována pomocí neupravené klasifikace kompozitního obrazu, který se skládá ze dvou dat reprezentujících vegetaci, transformovaný na dva kontrastní vegetační indexy, NDVI a NDVIB7 / B4. My posoudili přesnost pomocí georeferencovaných šikmých leteckých snímků, které se shodují se snímky Landsat. [28]

Zjištění: Hodnotili jsme přesnost pomocí georeferencovaných šikmých leteckých snímků, které se shodují se snímky Landsat pro malou a velkou povodňovou hladinu, čímž vznikla celková přesnost zaplavené plochy 93% a 95%. Zmatek mezi záplavovými třídami existovaly, ale třídy byly spektrálně odlišné od sebe navzájem a od souše. [28]

3.3 Studie č. 3

Název studie: Automatizovaná extrakce městských vodních útvarů z multi-spektrálních snímků ZY-3. [33]

Zájmové území: Bylo vybráno pět snímků představujících různé oblasti s různými prostředími včetně jezer a řek na území Číny. Vybrané oblasti jsou Peking, Guangzhou, Suzhou a Wuhan. Co se týče města Wuhan, město je ideálním místem pro experiment, protože má velké množství řek a jezer, stejně jako bohatou rozmanitost vodních útvarů, takže pro experiment jsme zvolili dvě oblasti pokrytí. [33]

Cíl: Navrhnutí nové metody pro získávání městské vody z dálkového snímání s vysokým rozlišením. Za účelem zlepšení přesnosti identifikace vody zlepšujeme algoritmus NDWI a navrhujeme dva nové vodní indexy, jmenovitě NNDWI1, který je citlivý na zakalenou vodu, a NNDWI2, který je citlivý na vodní útvary, jejichž spektrální informace je ovlivňována vegetací. Nadřazujeme výsledky segmentace obrázků NNDWI1 a NNDWI2 a pomocí objektově orientované technologie zjišťujeme a odstraňujeme stíny v malých oblastech, abychom získali konečné výsledky městské vodní extrakce. [33]

Zjištění: Podle výsledků má algoritmus AUWEM větší přesnost při extrakci vody ve srovnání s NDWI a MaxLike, s průměrným koeficientem Kappa 93% a průměrnou celkovou chybovostí kolem 11,9%. Naproti tomu průměrný koeficient Kappa a míra chyb MaxLike

jsou přibližně 88,6% a 18,2%; Průměrný Kappa koeficient a míra chyb NDWI je přibližně 86,2% a 22,1%. AUWEM navíc vykazuje větší přesnost při zjišťování vodního okraje a malých řek. Dokáže efektivně rozlišit stíny vysokých budov z vodních útvarů, aby se zlepšila celková přesnost. Ještě důležitější je, že AUWEM má stabilnější detekční přesnost než NDWI při změně prahu. To může být také užitečné pro extrakci vodních prvků a může být aplikováno pro sledování a studium změn vodních útvarů na jiných místech. [33]

3.4 Studie č. 4

Název studie: Automatizované mapování povrchových vod z heterogenního městského prostředí pomocí obrazů Landsat 8 OLI. [32]

Zájmové území: Jako studijní oblasti byly vybrány čtyři různá města v Číně, aby zahrnovala různorodé typy vodních útvarů a komplexní pozemní vlastnosti. Vybranými městy byly Peking, Šanghaj, Hangzhou a Guangzhou. [32]

Studijní oblast 1 - Peking se nachází v centru Peking. Povrchové vodní útvary v této oblasti jsou převážně čirou vodou přítomnou jako umělé jezera, rybníky a malé řeky.

Studijní oblast 2 - Šanghaj se nachází v centru Šanghaje, kde je řeka Huangpu a její malé přítoky. V této oblasti je obtížné rozlišit vodní útvary v důsledku stínů způsobených vysokými budovami.

Studijní oblast 3 – Hangzhou se nachází na předměstí města, kde jsou bohaté vodní útvary, včetně řeky Qiantang a jejích přítoků a mnoha malých rybníků.

Studijní oblast 4 – Guangzhou je obklopena řekou Perl a jejími přítoky. Vodní útvary v této oblasti jsou velice rozmanité.

Cíl: Cílem této studie je vyvinout automatické mapování povrchových vod (ASWM), která může dosáhnout vysoké přesnosti v městských oblastech. Konkrétně nejdříve používáme vodní index pro automatickou extrakci smíšených pixelů pozemní vody a pixely čisté vody. Za druhé, technika SMA se aplikuje na smíšené pixely země-voda pro odhad výskytu vody. Jedna metoda klasického vodního indexu (modifikovaný normalizovaný rozdílový vodní index (MNDWI)), metodu detekce cíle na úrovni pixelu (omezená minimalizace energie (CEM)) a dvě široce používané metody SMA (plně omezené nejmenší čtverce (FCLS) Analýza spektrální směsi (MESMA)) byla použita pro porovnání vodního mapování v experimentech. [32]

Zjištění: Výsledky naznačují, že navržený systém ASWM byl schopen detekovat vodní obrazové body mnohem účinněji než jiné metody. Metoda ASWM ukazuje nejlepší výkonnost ve vodním mapování s průměrným koeficientem kappa 0,862. [32]

3.5 Studie č. 5

Název studie: Automatizovaná metoda pro extrahování řek a jezer z obrazů Landsat. [10]

Zájmové území: Zahrnuje tři studijní oblasti. [10]

Studijní oblast 1 se nachází v provincii Hebei v severní Číně a zahrnuje nádrž Panjiakou a pět řek (Luanhe, Liuhe, Baohe, Heihe a Sahe).

Studijní oblast 2 se nachází na jihovýchodním jezeře Poyang, což je největší čínské sladkovodní jezero v provincii Jiangxi v jižní Číně. Tato oblast má bohaté vodní zdroje, které zahrnují osm vodních nádrží, tři řeky (Leanjiang, Xinjiang a Wannianhe) a několik přítoků.

Studijní oblast 3 se nachází v autonomní oblasti Ningxia Hui severozápadní Číny. The Yellow River, která je druhou nejdelší řekou v Číně a je známá svou zakalenou vodou, a protéká studijní oblastí.

Cíl: Vzhledem k tomu, že pixely smíšené vody se obvykle vyskytují v úzkých řekách nebo mělkých vodách na okrajích jezer nebo širokých řek, tak cílem je navržení automatizované metody pro extrakci řek a jezer spojením WI s technikami DPZ k řešení výše uvedených problémů. [10]

Zjištění: Vzhledem k tomu, že pixely smíšené vody se obvykle vyskytují v úzkých řekách nebo podél okrajů jezer nebo širokých řek, je navržena automatizovaná metoda pro extrakci řek a jezer (AMERL) pro extrakci pixelů se smíšenou vodou zvážením nejen jejich spektrálních vlastností, ale i jejich topologických připojení. AMERL překonala optimální prahovou metodu pro většinu WI ve všech studijních oblastech. AMERL podstatně zlepšila úplnost úzkých řek pro všechny čtyři WI. Modifikovaný normalizovaný diferencovaný vodní index (MNDWI) a automatizovaný index extrakce vody (AWEIsh - s přítomností stínu) vykazovaly větší zlepšení než u normalizovaného diferencovaného vodního indexu (NDWI) a u automatizovaného indexu extrakce vody (AWEInsh - bez přítomnosti stínu) v každé ze tří studijních oblastí. [10]

3.6 Studie č. 6

Název studie: Extrakce vodních prvků a detekce změn pomocí multitemporálních snímků Landsat. [24]

Zájmové území: Jezero Urmia, které se nachází na severozápade Íránu. [24]

Cíl: Cílem této studie bylo namodelovat prostorotemporální změny jezera Urmia v období 2000-2013 pomocí multi-temporálních snímků Landsat 5 TM, Landsat 7 ETM a Landsat 8 OLI. Pro zkoumání extrakce povrchové vody z údajů Landsat lze uplatnit různé indexy například normalizovaného diferencovaného vodního indexu (NDWI), modifikovaného indexu NDWI (MNDWI), index normalizovaného diferencované rozdílu vlhkosti (NDMI), vodního indexu (WRI), index normalizovaného diferencovaného vegetace (NDVI) a automatizovaný index extrakce vody (AWEI). Celkově byl NDWI nalezen jako nejvhodnější a proto byl použit k modelování prostorotemporálních změn jezera. Navíc byl navržen a zhodnocen nový přístup založený na hlavních komponentech NDWI (NDWI-PC) pro zjišťování změny povrchové vody. [24]

Zjištění: Výsledky naznačují silný klesající trend v oblasti povrchu jezera Urmia v období 2000-2013, zejména mezi lety 2010 a 2013, kdy jezero ztratilo přibližně jednu třetinu jeho plochy v porovnání s rokem 2000. Výsledky vykazují účinnost NDWI-PC k detekci změn povrchové vody, zejména při detekci změn mezi dvěma a třemi různými časy současně. Pouze metody NDWI a NDWI-PC poskytovaly přesnost detekce změny povrchové vody vyšší než 90%. WRI, AWEI a MNDWI nedosáhli lepších výsledků ve srovnání s NDWI-PC, NDWI a NDVI při zjišťování změn povrchové vody v jezeře Urmia. Celkově NDWI zaznamenaly o něco lepší výsledky než NDWI-PC při detekci změn povrchové vody. Nicméně NDWI-PC mají výhodu nad NDWI tím, že detekují změny povrchové vody ve dvou a třech různých časech současně aplikací jediného prahu na vybraných komponentech. Naproti tomu NDWI vyžaduje, aby pro každou dobu byla použita prahová hodnota pro extrakci povrchové vody, a poté odečtením statistik pro odhad změn. [24]

3.7 Studie č. 7

Název studie: Detekce a vymezení vodních ploch ze snímků Landsat TM. [26]

Zájmové území: Kanál a záplavová oblast řeky Murrumbidgee poblíž města Wagga Wagga v Austrálii. [26]

Cíl: Cílem tohoto projektu bylo zjistit správnost použití jednoduchých technik DPZ pro mapování říčních vodních útvarů ze snímků Landsat 5 TM. Tato studie také vyčísluje přesnost klasifikace v jednotlivých pásech dat Landsat 5 TM vymezují vodní plochy. Výsledky těchto analýz jsou poté srovnávány s 6-pásmovou klasifikací. [26]

Zjištění: Z této studie je zřejmé, že údaje Landsat TM lze použít k mapování vodních útvarů spojených s řekou Murrumbidgee a její nivou v oblasti Wagga Wagga. Multispektrální klasifikace maximální pravděpodobnosti dokázala vytvořit celkovou přesnost klasifikace 97,4%. Výsledky také ukazují, že klasifikace pomocí středního infračerveného pásma 5 se ukázala jako úspěšná stejně jako klasifikace v multispektru, která dosáhla celkové přesnosti 96,9%. [26]

3.8 Studie č. 8

Název: Automatizovaný index extrakce vody: nová technika pro mapování povrchové vody pomocí snímků Landsat. [6]

Zájmové území: Vodní plochy v Dánsku, Švýcarsku, Etiopii, Jižní Africe a Novém Zélandu. [6]

Cíl: Hlavním cílem této studie bylo navrhnout metodu, které vylepší přesnost extrakce vody mezi vodními a nevodními povrchy zejména v oblastech se stíny a městskou zástavbou. Tyto důvody jsou nejčastější příčinou nízké přesnosti klasifikace. Pomocí snímků z Landsat 5 TM byla vytvořena nová metoda automatizované extrakce vody (AWEI). Přesnost této klasifikace porovnali s modification of normalized difference water index MNDWI a Maximum Likelihood (ML). AWEI výrazně zlepšila přesnost v oblastech, kde zdrojem klasifikace byly stínové a jiné temné povrchy. [6]

Zjištění: Bylo zjištěno, že klasifikátor AWEI byl relativně přesnější při klasifikaci okrajových pixelů ve srovnání s klasifikačními metodami MNDWI a ML. AWEI je proto navržen jako alternativní a vylepšený vodní index, zejména při získávání informací o vodě z oblastí, kde se očekávají hlučné výsledky z důvodu přítomnosti stínů a zastavěných ploch. Tato nová metoda by byla také vhodná pro studie detekce změny povrchové vody, protože klasifikuje okrajové pixely s vysokou přesností a také stabilním prahem. [6]

3.9 Studie č. 9

Název: Mapování otevřených povrchových vod algoritmy: srovnání spektrálních indexů a senzorů souvisejících s vodou. [35]

Zájmové území: Pro tuto studii byla vybrána oblast povodí Poyangského jezera. Jezero Poyang je největší sladkovodní jezero v Číně a nachází se na severu provincie Jiangxi a jihozápadní hranice provincie Anhui. Oblast studie byla vybrána záměrně, aby bylo zajištěno, že hladina vody zůstane stejná po celý rok. [35]

Cíl: Cílem této studie bylo přezkoumání a porovnání existujících přístupů mapování otevřených povrchových vod. Bylo využito šest nejvíce používaných ukazatelů vody, včetně indexu vlhkosti částic (TCW), normalizovaného diferencovaného vodního indexu (NDWI), modifikovaného normalizovaného diferencovaného vodního indexu (MNDWI), součet infračervených a dvou krátkovlnných infračervených pásem (Sum457), automatického indexu extrakce vody (AWEI), indexu povrchové vody (LSWI) za použití tří snímačů středního rozlišení (Landsat 7 ETM +, Landsat 8 OLI a Sentinel-2 MSI). [35]

Zjištění: Výsledky ukázaly, že obecně všechny algoritmy měly relativně vysokou přesnost s kappa koeficientem v rozmezí od 0,77 do 0,92. Algoritmy založené na NDWI byly mírně lepší než algoritmy založené na dalších vodních indexech ve studované oblasti, které by mohly souviset s dominancí čistého vodního tělesa v regionu, zatímco citlivosti vodních indexů se mohou lišit v různých podmínkách vodních těles. Nejhorší dvě přesnosti byly z kombinací algoritmu TCW a údajů Landsat 7 ETM + a MNDWI + Landsat 7 ETM +. Zatímco dvě nejvyšší přesnosti byly z kombinací NDWI + Landsat 8 OLI a NDWI plus VI + Landsat 8 OLI. Zde byl malý rozdíl v kappa koeficientech těchto dvou metod, jelikož kombinace NDWI + Landsat 8 OLI měla kappa koeficient 0,915, zatímco kombinace NDWI plus VI + Landsat 8 OLI měla mírně nižší koeficient kappa 0,913. Výsledné mapy z údajů Landsat 8 a Sentinel-2 měly vyšší celkovou přesnost než u Landsat 7. Tato studie demonstruje vylepšený výkon Landsatu 8 a Sentinelu-2 pro mapování povrchových vod. [35]

3.10 Studie č. 10

Název: Mapování městské povrchové vody ze snímků Sentinel-2 MSI v rozlišení 10 m prostřednictvím ostření obrazu na bázi NDWI. [34]

Zájmové území: Studijní oblasti obsahovaly dvě samostatná města v Číně, konkrétně Peking, který se nachází ve vnitrozemí a Yantai, který se nachází na pobřežní. [34]

Studijní oblast 1 zahrnoval okres v centru města a okolní příměstské oblasti, ve kterých vodní útvary zahrnují několik řídké rozptýlených rybníků, řek a jezírek. Tyto vodní útvary jsou poměrně malé a jsou obklopeny zastavěnými plochami a vegetací. Obzvláště rozsáhlý výskyt výškových budov a pouličních stromů tvořil množství zastíněných oblastí.

Studijní oblast 2 se nachází podél severního pobřeží poloostrova Shandong a jižně od Bohaiského moře. Jeho vodní útvary zahrnují řeky, jezera a rozpoznatelné pobřeží.

Cíl: Tato studie provádí průzkumné vyhodnocení výkonu nových snímků Sentinel-2A MSI pro mapování vodních útvarů za použití metody ostření obrazu. Sentinel-2 MSI

poskytuje spektrální pásma s různými rozlišeními, včetně pásem RGB a NIR v rozlišení 10 m a pásmem SWIR v rozlišení 20 m, které úzce souvisejí s informacemi o povrchové vodě. Tato studie, zaměřená na extrakci městské povrchové vody, využívala NDWI při rozlišení 10 m jako obrázek s vysokou rozlišovací schopností pro ostrost pásem SWIR s rozlišením 20 m. [34]

Zjištění: Naostřené vodní mapy založené na MNDWI výrazně zlepšily koeficient kappa o téměř 0,3 v centru Pekingů ve srovnání s konvenčními přístupy založenými na NDWI (10 m) a MNDWI (20 m). Pro pobřežní studijní oblast Yantai dosáhla klasická NDWI (10 m) dobré přesnosti klasifikace, zatímco MNDWI (20 m), FPC a MRSB přinesly nízkou přesnost. Nicméně navrhovaná metoda NDWII také získala nejlepší výsledek extrakce vody, který používal NDWI jako pan-like pásmo pro zvýšení prostorových informací pásma SWIR. Výsledky ukazují, že navrhovaná metoda NDWII může zlepšit extrakci vody pro snímky ze Sentinelu-2 MSI. [34]

3.11 Shrnutí případových studií

V tabulce 5 je zobrazeno shrnutí jednotlivých případových studií, které se zabývají klasifikací povrchových vod. V přehledu je číslo studie, použité družice, rozsah ploch, pro který byla klasifikace použita. Dále také přehled referenčních dat a výsledný kappa koeficient.

Tabulka 5: Shrnutí případových studií

Číslo studie	Družice	Metody	Rozsah ploch	Referenční data	Kappa koeficient
1.	GeoEye-1 WorldView-2	Linear-SVM, RBF-SVM, C4.5, CART, TB, RF, ELM, LORSAL	Řeky, jezera, kanály, rybníky	Vizuální intepretace	Linear-SVM (94,6%;84,9%) RBF-SVM (65,5%;83,7%) C4.5 (95%;90%) CART (95,9%;81,5%) TB (95,7%;94,1%) RF (95,4%;93,9%) ELM (87,9%;70,6%)

Číslo studie	Družice	Metody	Rozsah ploch	Referenční data	Kappa koeficient
					LORSAL (79,8%;77,4%) *první GeoEye-1 Wuhan, druhé WorldView-2 Shenzhen
2.	Landsat 5 TM Landsat 7 ETM+	NDWI	Bažiny a mokřady (max 478 000 ha) – kanály a potoky, řeka Macquarie (povodí 7 400 000 ha)	Letecká fotografie	MaxLike (97,4%)
3.	ZY-3	AUWEM, NDWI, MaxLike	Řeky, znečištěná jezera, čistá jezera, rybníky, velká znečištěná jezera, velká čistá jezera	Vizuální interpretace	AUWEM (93%) NDWI (86,2%) MaxLike (88,6%)
4.	Landsat 8 OLI	ASWM, MNDWI, FCLS, MESMA, CEM	Malá a čistá jezera (20 – 40 ha) a malé a čisté řeky, mírně zakalená řeka (38 a 761 ha), mírně zakalená a zakalená řeka (2875 ha), jasná	Google Earth	ASWM (86,2%) MNDWI (79%) FCLS (57,8%) MESMA (63%) CEM (58,3%)

Číslo studie	Družice	Metody	Rozsah ploch	Referenční data	Kappa koeficient
			a mírně zakalená řeka (747 ha)		
5.	Landsat 5 TM, Landsat 7 ETM+	NDWI, MNDWI, AWEI _{sh} , AWEI _{nsh}	Nádrž (6700 ha), řeky	Vizuální interpretace (doplňk Google Earth)	NDWI (98,4%) MNDWI (99,2%) AWEI _{sh} (99%) AWEI _{nsh} (99%)
6.	Landsat 5 TM, Landsat 7 ETM + Landsat 8 OLI	NDWI, MNDWI, WRI, NDVI, AWEI, NDWI-PCs	Jezero (610 000 ha)	Vizuální interpretace	NDWI (91%) MNDWI (86%) WRI (86%) NDVI (87%) AWEI (89%) NDWI-PCs (91%)
7.	Landsat 5 TM	MaxLike	Řeka (50 – 100 m široká), laguny (50 – 100 m široké, 6 – 18 ha), malé vodní plochy (variabilní tvar, 0,005 – 3,2 ha), kanalizační rybníky (variabilní tvar, 2,8 – 14,5 ha)	Letecká fotografie	Není
8.	Landsat 5	AWEI, MNDWI,	Jezera (106 –	Google	AWEI (96,2%)

Číslo studie	Družice	Metody	Rozsah ploch	Referenční data	Kappa koeficient
	TM	MaxLike	6495 ha)	Earth	MNDWI (92%) MaxLike (84,4%)
9.	Landsat 8 OLI Landsat 7 ETM + Sentinel-2 MSI	TCW, NDWI, MNDWI, SNN, AWEI _{sh} , AWEI _{nsh} , NDWI+VI MNDWI+ VI, LSWI+VI	Jezero (270 000 ha)	VHR snímky	TCW (83,6%) NDWI (90,1%) MNDWI (86,8%) SNN (87,7%) AWEI _{sh} (88,5%) AWEI _{nsh} (88,3%) NDWI+VI (90%) MNDWI+VI (88%) LSWI+VI (86,7%)
10.	Sentinel-2 MSI	NDWII, FPC, MRSB, MNDWI, NDWI	Řeky, rybníky, jezírka	Vizuální interpretace (doplňk Google Earth)	NDWII (89,4%) FPC (89,2%) MRSB (87,5%) MNDWI (74,2%) NDWI (83,9%)

Zdroj: upraveno podle [9][28][33][32][10][24][26][6][35][34]

3.12 Nejlepší a nejvíce používané metody

V následující tabulce 6 jsou zobrazeny nejčastější a nejlepší používané metody pro klasifikaci povrchových vod. Jak vidíme, tak nejlepší výsledky má metoda AWEI. Hned za touto metodou následují metody NDWI a MNDWI. Jako další velmi používaná s velmi dobrými výsledky je metoda Maximum Likelihood.

Tabulka 6: Přehled nejlepších a nejpoužívanějších metod

Metoda	Použité pro	Průměrné výsledky
AWEI	Malá a velká jezera, nádrže, malé řeky	Vynikající (93,15%)
Maximum Likelihood	Malá a velká jezera, malé a velké řeky rybníky, laguny	Velmi dobré (90,13%)
NDWI	Malá a velká jezera, nádrže, malé a velké řeky, rybníky, bažiny, mokřady, kanály, potoky, jezírka	Velmi dobré (89,92%)
MNDWI	Malá a velká jezera, nádrže, malé a velké řeky, rybníky, jezírka	Dobré (86,2%)

Zdroj: upraveno podle [9][28][33][32][10][24][26][6][35][34]

3.13 Nejpoužívanější družice

Všeobecně mezi nejpoužívanější družice se řadí družice z programu Landsat. Družice programu Landsat patří k nejznámějším družicím a jejich historie sahá až do roku 1972, kdy na oběžnou dráhu byla vypuštěna první družice z dnes již osmidílné sady. Tyto družice pořizují data středního prostorového rozlišení. V současnosti jsou v provozu dvě družice a to Landsat 7 a Landsat 8. [4][16]

V jichž zmíněných studiích se používají data z ukončeného Landsatu 5 a aktivních družic Landsat 7 a Landsat 8.

Další v poslední době velmi rozšířenou jsou družice z rodiny Sentinel, které se vyvíjí v rámci programu Copernicus. Družice Sentinel celkem tvoří 5 řad, tzv. Sentinely 1-5. První tři řady každou tvoří dvě družice, které se označují A a B, které jsou navrženy tak, aby svým časovým i prostorovým rozlišením zajistily kvalitní základ pro služby programu Copernicus. V současnosti jsou v provozu první tři řady družic. [5]

V předchozích dvou studiích byly využity data právě z druhé řady družic Sentinelu a to Sentinel 2.

4 PŘÍPADOVÁ STUDIE

Případová studie se týká okolí Pardubického kraje a konkrétně severozápadně od města Pardubic. Cílem této studie bude provést klasifikaci vodních ploch ve vybraném zájmovém území, tudíž proběhne klasifikace do dvou tříd: vodní plochy a ostatní plochy. Klasifikace dat proběhne v rámci vybraného programového prostředí a to v ArcGIS 10.2 for Desktop. Tato klasifikace bude provedena všemi algoritmy, co programové prostředí nabízí a jednotlivé výsledky budou následně porovnány a vizualizovány. V této případové studii budou využity družicová data z družice Landsat 8 a družice Sentinel 2.

4.1 Postup zpracování

Na obrázku číslo 8 je zobrazen postup zpracování dané případové studie. Nejprve bylo nutné vymezit vhodně zájmové území. Poté následoval výběr a následný sběr vhodných dat k následnému zpracování. Pak už proběhlo zpracování vybraných dat a potom už následná klasifikace ve vybraném programovém prostředí. Nakonec je nutné provést porovnání a vizualizaci výsledků provedených algoritmů pro klasifikaci.



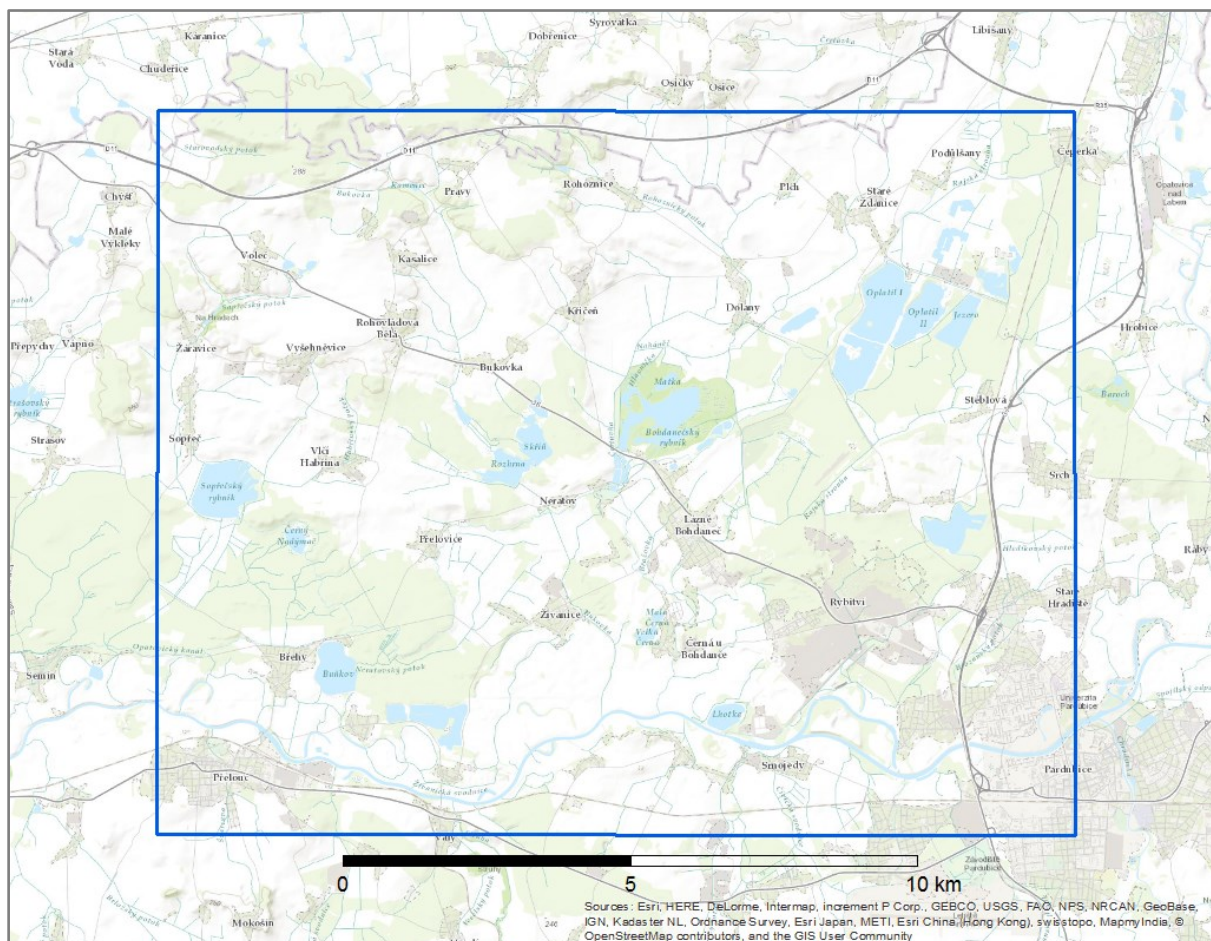
Obrázek 8: Postup zpracování příkladové studie

Zdroj: vlastní zpracování

4.2 Vymezení zájmového území

Zájmové území bylo vybráno z mnoha hledisek a faktorů. Jedním z těchto faktorů je zpracovatel této diplomové práce pochází z Pardubického kraje, tudíž má povědomí, jaké

významné vodní plochy tu jsou a kde se nachází. Dalším důležitým faktorem pro výběr zájmového území bylo, že se na vybrané zájmové území budou zpracovávat na Univerzitě Pardubice další studie. Horní okraj zájmového území lemuje dálnice D1. V levém dolním rohu zájmového území se nachází město Přelouč. Pravý dolní roh zájmového území obsahuje část města Pardubic. Ve vybraném zájmovém území se nachází mnoho významných vodních ploch například řeka Labe, Bohdanečský rybník, rybník Matka, Sopřečský rybník atd. Přibližná velikost zájmového území je 12,6 km (sever-jih) x 16 km (východ-západ), to znamená zhruba 201,6 km². Vymezení zájmového území je zobrazeno na obrázku 9.



Obrázek 9: Vymezení zájmového území

Zdroj: vlastní zpracování

Řeka Labe je jednou z největších řek v Evropě. Pramení v Krkonoších (v Čechách), dále protéká Německem a poté ústí do Severního moře. Délka řeky Labe je 1094,3 km dlouhá (v Čechách 367,7 km). Její rozloha povodí je 148 268 km² (v Čechách 49 937 km²). V tomto zájmovém území se řeka Labe nachází od města Pardubic po město Přelouč. [13]

Bohdanečský rybník je největší rybník v Pardubickém kraji s rozlohou vodní hladiny 90 ha a katastrální výměrou 158 ha. Vedle se nachází rybník Matka s rozlohou vodní hladiny 7 ha

a katastrální výměrou 14 ha. Bohdanečský rybník spolu s rybníkem Matka jsou od roku 2005 součástí národní přírodní rezervace (NPR). Rozloha NPR dosahuje 247,8 ha a ochranné pásmo má 60,2 ha. Bohdanečský rybník spolu s rybníkem Matka se nachází ve středu zájmového území kousek od města Lázně Bohdaneč. [2]

Sopřečský rybník má celkovou výměru vodní plochy cca 80 ha. Jak z názvu vyplývá, tak se nachází jižním směrem u obce Sopřeč. Tento rybník je každý rok na podzim vypouštěn a probíhá zde výlov ryb. [27]

Dalšími vodními plochami v okolí jsou rybník Černý Nadýmač, který se nachází jihovýchodně od Sopřečského rybníka. Dále pak rybník Buňkov, který je východně od obce Břehy. Severně od obce Mělice se rozléhá velmi oblíbené přírodní koupaliště písňík Mělice. Severozápadně od obce Černá u Bohdanče jsou rybníky Malá Černa a Velká Černá. U obce Lány na Důlku je severovýchodně rybník Lhotka. Další významný rybník v této zájmové oblasti je Pohránovský rybník, který je jižně od obce Pohránov. Jihovýchodně od obce Staré Žďánice je rozsáhlý písňík Oplatil. Severozápadně od obce Neratov se nachází komplex rybníku a to rybník Rozhrna, Skříň, Trhoňka, Udržal, Tichý rybník, rybník Horní Jílovky a Dolní Jílovky.

4.3 Výběr a sběr dat

V této případové studii byly použity družicová data z družice Landsat 8 a z družice Sentinel 2. Všeobecně se nejvíce v těchto typech studií používají družice z rodiny Landsat, například v jichž zmíněných studiích se používají data z ukončeného Landsatu 5 a aktivních družic Landsat 7 a Landsat 8. Ovšem také v poslední době došlo k rozšíření použití dat z družic rodiny Sentinel, například v předchozích dvou studiích byly využity data právě z druhé řady družic Sentinelu a to Sentinel 2. Proto v této studii byly využity obě nejvyužívanější družice pro tento typ studií a to družice Landsat 8 a Sentinel 2.

Družice Landsat 8 byla spuštěna 11. února 2013. Satelit shromažďuje družicové snímky s 16-ti denním opakovacím cyklem. Družice Landsat 8 má na sobě dva senzory a OLI (Operational Land Image) a TIRS (Thermal Infrared Sensor). Spektrální pásma senzoru OLI jsou podobná jako u družice Landsat 7 a senzoru ETM +, ovšem jsou dvě nová pásma: hluboké modré viditelné pásmo (pásmo 1), které je speciálně navrženo pro zkoumání vodních zdrojů a pobřežních zón; nové infračervené pásmo (pásmo 9), které slouží pro detekci cirrusových mraků. Senzor TIRS obsahuje dvě tepelná infračervená pásma: TIR-1 (pásmo 10); TIR-2 (pásmo 11). Tyto dva senzory poskytují data v prostorovém rozlišení 30 m

(viditelná, NIR, SWIR pásma), dále v prostorovém rozlišení 100 m (tepelná pásma) a v prostorovém rozlišení 15 m (panchromatické pásmo). Přehled pásem a jejich prostorových rozlišení včetně vlnové délky družic Landsat 7 a Landsat 8 je znázorněn na následujícím obrázku 10. [15][14]

Landsat-7 ETM+ Bands (μm)			Landsat-8 OLI and TIRS Bands (μm)		
			30 m Coastal/Aerosol	0.435 - 0.451	Band 1
Band 1	30 m Blue	0.441 - 0.514	30 m Blue	0.452 - 0.512	Band 2
Band 2	30 m Green	0.519 - 0.601	30 m Green	0.533 - 0.590	Band 3
Band 3	30 m Red	0.631 - 0.692	30 m Red	0.636 - 0.673	Band 4
Band 4	30 m NIR	0.772 - 0.898	30 m NIR	0.851 - 0.879	Band 5
Band 5	30 m SWIR-1	1.547 - 1.749	30 m SWIR-1	1.566 - 1.651	Band 6
Band 6	60 m TIR	10.31 - 12.36	100 m TIR-1	10.60 - 11.19	Band 10
			100 m TIR-2	11.50 - 12.51	Band 11
Band 7	30 m SWIR-2	2.064 - 2.345	30 m SWIR-2	2.107 - 2.294	Band 7
Band 8	15 m Pan	0.515 - 0.896	15 m Pan	0.503 - 0.676	Band 8
			30 m Cirrus	1.363 - 1.384	Band 9

Obrázek 10: Přehled pásem a jejich parametrů družic Landsat 7 a Landsat 8

Zdroj: [15]

Družice Sentinel 2 byla spuštěna 23. června 2015. Sentinel-2A může samostatně snímat jedno území jednou za 10 dní. Pokud snímá společně s identickou sesterskou družicí Sentinel-2B, tak může snímat jedno území za 5 dní (pro území na rovníku), jednou za 3 dny (pro území v zeměpisných šířkách odpovídající Evropě), až téměř každý den pro území Skandinávie nebo Kanady. Družice Sentinel 2 má na sobě senzor MSI (Multi Spectral Instrument) neboli multispektrální, který snímá ve 13 spektrálních pásmech v prostorovém rozlišení 10 m, 20 m a 60 m. Přehled pásem a jejich prostorových rozlišení včetně vlnové délky družice Sentinel 2 je zobrazen na následujícím obrázku 11. [7]

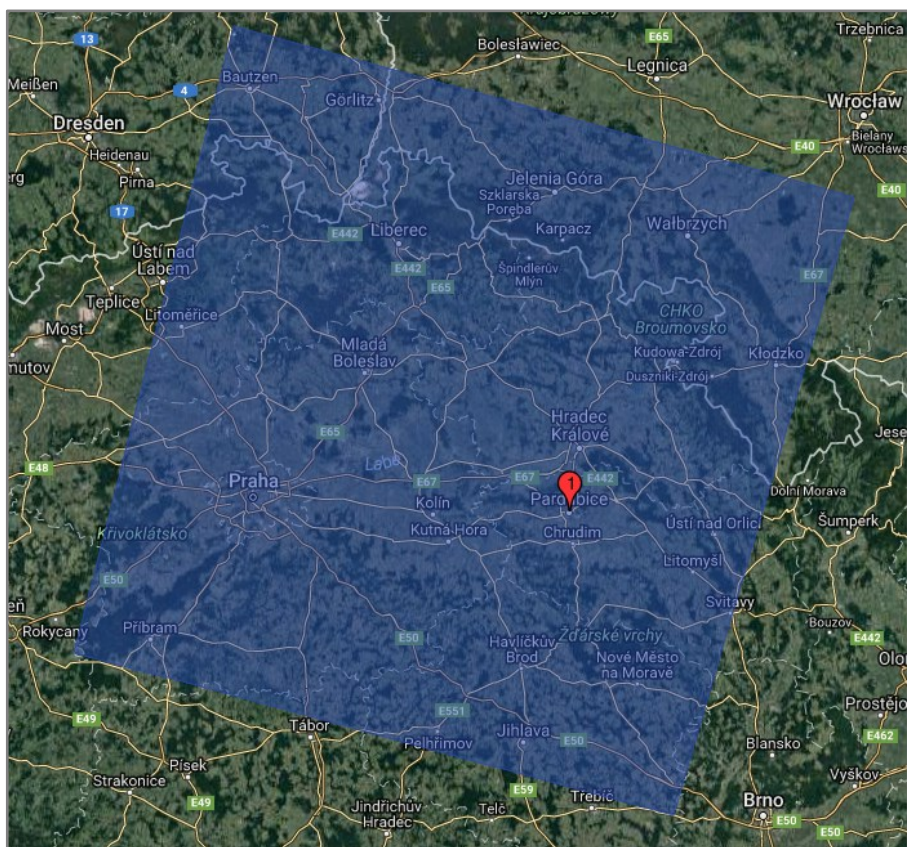
Označení pásma	Rozsah od [μm]	Rozsah do [μm]	Kódování spektrál. pásma	Prostorové rozlišení [m]
2	0.4575	0.5225	BLUE	10.0
3	0.5425	0.5775	GREEN	10.0
4	0.65	0.68	RED	10.0
8	0.7845	0.8995	NIR	10.0
5	0.6978	0.7125	RED EDGE	20.0
6	0.7325	0.7475	NIR	20.0
7	0.773	0.793	NIR	20.0
8b	0.855	0.875	NIR	20.0
11	1.565	1.655	SWIR	20.0
12	2.1	2.28	SWIR	20.0
1	0.433	0.453	COASTAL	60.0
9	0.935	0.955	NIR	60.0
10	1.365	1.395	NIR	60.0

Obrázek 11: Přehled pásem a jejich parametrů družice Sentinel 2

Zdroj: upraveno podle [7]

Data jsou volně ke stažení na webových stránkách <https://earthexplorer.usgs.gov/>, kde po registraci je možné stahovat různá data z různých družic včetně Landsat 8 a Sentinel 2. Detailní návod na stažení těchto dat je znázorněn v příloze A.


Na obrázku 12 je znázorněný záběr scény vybrané datové sady nasnímané družicí Landsat 8. Záběr scény je z jihu ohraničený od Pelhřimova až na sever za hranice s Polskem. Ze západu je scéna ohraničená od Ústí nad Labem až na východ ke Svitavám. Přibližná velikost scény je 195 km (sever-jih) x 191 km (východ-západ). Data byla nasnímaná 1. 4. 2017 v souřadnicovém systému WGS 1984 UTM Zone 33N.



Obrázek 12: Záběr scény snímané družicí Landsat 8

Zdroj: [29]

Na obrázku 13 je vyobrazený záběr scény vybrané datové sady nasnímané družicí Sentinel 2. Záběr scény je z jihu ohraničený Humpolcem a Novým Městem na Moravě až na sever k Trutnovu a Turnovu. Ze západu je scéna ohraničená Mladou Boleslaví až na východ k České Třebové. Přibližná velikost scény je 110 km (sever-jih) x 110 km (východ-západ). Data byla nasníмана 1. 4. 2017 v souřadnicovém systému WGS 1984 UTM Zone 33N.



Obrázek 13: Záběr scény snímané družicí Sentinel 2

Zdroj: [29]

4.4 Zpracování a klasifikace dat

U těchto snímků nebylo nutné provádět žádné korekce, jelikož snímky byly pořízeny za absolutně bezoblačného počasí. Procentuální podíl zastínění země a snímané scény z Landsat 8 oblačností bylo jen 0,01% a u Sentinel 2 bylo zastínění oblačností 0% a proto není nutné provádět atmosférické korekce. Geometrické a radiometrické korekce byly u obou družic provedeny už od poskytovatele dat.

Nejprve bylo nutné vytvořit si nový shapefile s polygonem zájmového území v programu ArcGIS 10.2 for Desktop. Poté pomocí funkce Clip ořezat jednotlivé snímky pásem ze stáhnuté datové sady podle vytyčeného zájmového území. Po ořezání jednotlivých snímků pásem bylo nutné si tyto nové ořezaná pásma uložit k následné klasifikaci.

Pro další klasifikaci z pořízené datové sady Landsat 8 bylo použito 8 pásem. Vyřazeno bylo nové infračervené pásmo (pásmo 9), které slouží pro detekci cirrusových mraků a je v této práci je toto pásmo nepoužitelné. Dále byla vyřazena dvě tepelná pásma (pásmo 10, pásmo 11), jelikož jejich velké prostorové rozlišení (100 m) oproti ostatním pásmům


s prostorovým rozlišením (30 m) narušuje klasifikaci. Všechna tato pásma z družice Landsat 8 ořezaná se zájmovým územím jsou v příloze B.

Pro klasifikaci z pořízené datové sady Sentinel 2 bylo použito 10 pásem. Vyřazena byla tři pásma (pásma 1, pásmo 9, pásmo 10). Pásma slouží pro detekci aerosolu, vodních par a cirrusových mraků, tudíž jsou v této práci nepoužitelné. Tyto pásma byla vyřazena hlavně z hlediska jejich velkého prostorového rozlišení (60 m) oproti ostatním pásmům (10 m a 20 m). Zmíněné velké prostorové rozlišení narušuje klasifikaci. Všechna tato pásma z družice Sentinel 2 ořezaná se zájmovým územím jsou vidět v příloze B.

4.4.1 Iso Cluster

Nejprve byla provedena Iso Cluster, která je jedinou metodou z neřízených klasifikací v programu ArcGIS 10.2 for Desktop. Tato metoda je velmi jednoduchá z hlediska uživatelského použití. Nejprve je nutné přidat pásma, podle kterých chce uživatel klasifikovat. Použitá pásma jednotlivých družic byla v této studii, již zmíněna. Poté se muselo zadat požadovaný počet tříd, do kterých má klasifikátor jednotlivé pixely rozdělit. V této studii bylo použito 5 a 20 tříd, které se následně sjednocovaly do hlavních dvou tříd (vodní plochy a ostatní plochy). Zvolení těchto použitých tříd proběhlo experimentálním způsobem. Pak už proběhne výběr místa uložení daného klasifikovaného souboru. Ostatní parametry byly ponechány v defaultním nastavení, jelikož nejsou pro tuto klasifikaci důležité.

Při první klasifikaci pro data z družice Landsat 8 metodou Iso Cluster bylo zvoleno 5 tříd, které se následně sjednotily pouze do dvou a to na vodní plochy a ostatní plochy. Klasifikace byla provedena velice rychle a trvala pouhé 3,98 sekundy. Algoritmus provedl klasifikaci do 5 tříd a poté pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní plochy – 4 třídy). Pro žádné klasifikace nebylo možné použít různé druhy postklasifikačních úprav, jelikož velmi měnily výsledky. Největší problém s těmito úpravami byl z řekou Labe, jelikož po použití různých postklasifikačních úprav řeka Labe byla velmi pozměněna až zcela zneviditelněna. Proto nejsou postklasifikační úpravy v této práci použity. Výstup z dané klasifikace je vidět na obrázku 14.



Obrázek 14: Klasifikace metodou Iso Cluster (5 tříd) z dat Landsat 8

Zdroj: vlastní zpracování, data [29]

Pro zjištění přesnosti klasifikace byla vytvořena klasifikační chybová matice. Vytvoření proběhlo tím způsobem, že klasifikovaný obraz byl převeden funkcí Raster to Polygon na jednotlivé polygony. Tyto polygony byly poté sjednoceny do dvou velkých skupin polygonů a to do skupiny vodní plochy a ostatní plochy. Pak byla použita funkce Create Random Points, která náhodně rozmístila body do určené skupiny. Proto byly vytvořeny dvě skupiny polygonů (vodní plochy, ostatní plochy), aby do každé skupiny bylo rozmístěno stejný počet náhodných bodů a výsledek nebyl zešikměný. Do každé skupiny bylo náhodně rozmístěno 50 bodů. Každý bod bylo nutné ohodnotit podle skutečnosti, neboli jestli skutečně podle referenčních dat patří do vodních ploch či ostatních ploch a zadat do atributové tabulky. Do atributové tabulky bylo také nutné zadat klasifikovanou hodnotu každého bodu, ovšem to se dalo udělat pomocí Raster to Point. Poté už jen stačilo vygenerovat pomocí funkce Frequency počty klasifikovaných bodů a z těchto počtu vytvořit klasifikační chybovou matici.


Z následující tabulky 7 je zřejmé, že tento klasifikátor klasifikoval všechny body správně. Všechny 50 bodů, které ve skutečnosti byly vodními plochy, klasifikoval taky jako vodní plochy a všechny 50 bodů, které ve skutečnosti byly ostatními plochy, klasifikoval jako ostatní plochy.

Tabulka 7: Klasifikační matice z klasifikace metodou Iso Cluster (5 tříd) z dat Landsat 8

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	50	0	50
Ostatní plochy	0	50	50
Celkem sloupce	50	50	100

Zdroj: vlastní zpracování

Při druhé klasifikaci pro data z družice Landsat 8 metodou Iso Cluster bylo zvoleno 20 tříd, které se následně sjednotily pouze do dvou a to na vodní plochy a ostatní plochy. Klasifikace byla provedena o něco pomaleji než u předchozí klasifikace, ovšem se zanedbatelným rozdílem trvala pouhé 4,74 sekundy. Algoritmus provedl klasifikaci do 20 tříd a poté pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní plochy – 19 tříd). Výstup z dané klasifikace je vidět na obrázku 15.



Obrázek 15: Klasifikace metodou Iso Cluster (20 tříd) z dat Landsat 8

Zdroj: vlastní zpracování, data [29]

Z tabulky 8 je znatelné, že některé body klasifikátor klasifikoval špatně. Konkrétně 46 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy,

ovšem 4 body, které ve skutečnosti jsou vodní plochy, klasifikoval jako ostatní plochy. Dále všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.


Tabulka 8: Klasifikační matice z klasifikace metodou Iso Cluster (20 tříd) z dat Landsat 8

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	46	4	50
Ostatní plochy	0	50	50
Celkem sloupce	46	54	100

Zdroj: vlastní zpracování

Z klasifikace metodou Iso Cluster pro data Landsat 8 je patrné, jak po vizuální stránce, tak podle klasifikační chybové matice, že klasifikace metodou Iso Cluster se zvolením 5 tříd je přesnější než se zvolením 20 tříd.

Při první klasifikaci pro data z družice Sentinel 2 metodou Iso Cluster bylo zvoleno 5 tříd, které se následně sjednotily pouze do dvou a to na vodní plochy a ostatní plochy. Klasifikace z družice Sentinel 2 byla provedena o něco pomaleji než u předchozích klasifikací z družice Landsat 8, ovšem zase se zanedbatelným rozdílem tato klasifikace trvala pouhé 7,04 sekundy. Algoritmus provedl klasifikaci do 5 tříd a poté pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní plochy – 4 třídy). Výstup z dané klasifikace je vidět na obrázku 16.



Obrázek 16: Klasifikace metodou Iso Cluster (5 tříd) z dat Sentinel 2

Zdroj: vlastní zpracování, data [29]

Z následující tabulky 9 je znatelné, že tento klasifikátor klasifikoval všechny body správně. Všech 50 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy a všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.

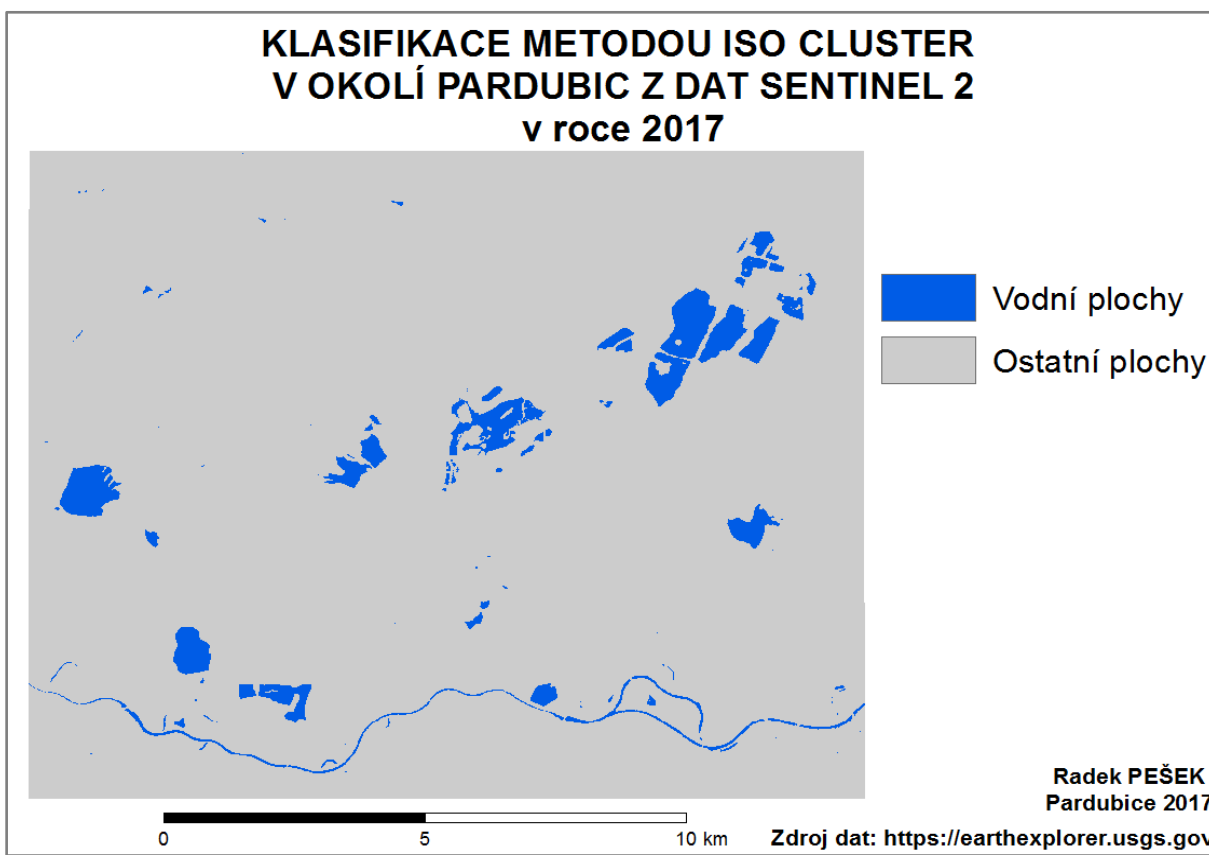
Tabulka 9: Klasifikační matice z klasifikace metodou Iso Cluster (5 tříd) z dat Sentinel 2

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	50	0	50
Ostatní plochy	0	50	50
Celkem sloupce	50	50	100

Zdroj: vlastní zpracování

Při další klasifikaci pro data z družice Sentinel 2 metodou Iso Cluster bylo zvoleno 20 tříd, které se následně sjednotily pouze do dvou a to na vodní plochy a ostatní plochy. Jak už bylo zmíněno, tak klasifikace z družice Sentinel 2 byla provedena o něco pomaleji než u předchozích klasifikací z družice Landsat 8, ovšem zase se zanedbatelným rozdílem tato klasifikace trvala pouhé 11,83 sekundy. Algoritmus provedl klasifikaci do 20 tříd a poté

pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní plochy – 19 tříd). Výstup z dané klasifikace je vidět na obrázku 17.



Obrázek 17: Klasifikace metodou Iso Cluster (20 tříd) z dat Sentinel 2

Zdroj: vlastní zpracování, data [29]

Z tabulky 10 je znatelné, že některé body klasifikátor klasifikoval špatně. Konkrétně 46 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy, ovšem 4 body, které ve skutečnosti jsou vodní plochy, klasifikoval jako ostatní plochy. Dále všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.

Tabulka 10: Klasifikační matice z klasifikace metodou Iso Cluster (20 tříd) z dat Sentinel 2

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	46	4	50
Ostatní plochy	0	50	50
Celkem sloupce	46	54	100

Zdroj: vlastní zpracování

Z klasifikace metodou Iso Cluster pro data Landsat 8 a Sentinel 2 je patrné, jak po vizuální stránce, tak podle klasifikační chybové matice, že klasifikace metodou Iso Cluster se zvolením 5 tříd je přesnější než se zvolením 20 tříd.

Zde ovšem nelze určit, jaká data jsou lepší, jelikož klasifikátor z obou datových souborů klasifikoval stejně.

4.4.2 Maximum Likelihood

Jako druhá byla provedena metoda Maximum Likelihood, která je jednou z metod z řízených klasifikací v programu ArcGIS 10.2 for Desktop. Tato metoda je náročnější, jelikož nejprve je nutné vytvořit trénovací plochy. Pro řízenou klasifikaci byly zvoleny 4 třídy, které jsou nejvíce využívány pro rozlišení zemských povrchů a to vodní plochy, vegetace, zástavba, holá půda. Výběr a vytvoření trénovacích ploch pro jednotlivé třídy je vyobrazen na obrázku 18.




Obrázek 18: Trénovací plochy pro řízenou klasifikaci

Zdroj: vlastní zpracování, data [29]

Při neřízené klasifikaci metodou Maximum Likelihood je nejprve nutné přidat pásma, podle kterých chce uživatel klasifikovat. Použitá pásma jednotlivých družic byla v této studii, již zmíněna. Poté je nutné vložit soubor s vytvořenými trénovacími plochami. Pak už

proběhne výběr místa uložení daného klasifikovaného souboru. Ostatní parametry byly ponechány v defaultním nastavení, jelikož nejsou pro tuto klasifikaci důležité.

Klasifikace z dat Landsat 8 byla provedena velice rychle a trvala pouhé 2,03 sekundy. Algoritmus provedl klasifikaci do 4 zvolených tříd a poté pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní plochy – 3 třídy). Na obrázku 19 je zobrazena klasifikace z dat Landsat 8.



Obrázek 19: Klasifikace metodou Maximum Likelihood z dat Landsat 8

Zdroj: vlastní zpracování, data [29]

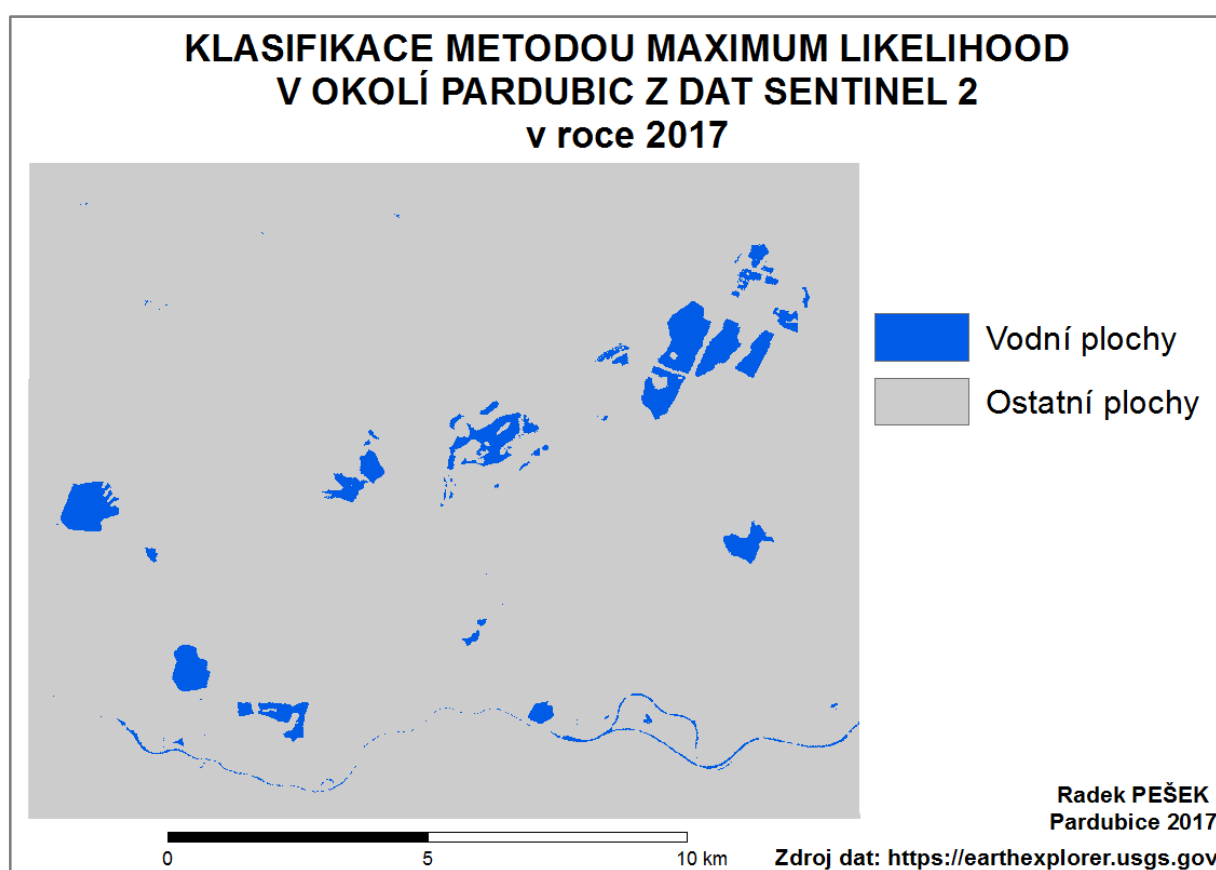
Z tabulky 11 je patrné, že zde klasifikátor neklasifikoval dobře a některé body klasifikoval špatně. Jeden z hlavních objektů, který nedokázal dobře vyklasifikovat je řeka Labe. Konkrétně 38 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy, ovšem 12 bodů, které ve skutečnosti jsou vodní plochy, klasifikoval jako ostatní plochy. Ovšem všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.

Tabulka 11: Klasifikační matice z klasifikace metodou Maximum Likelihood z dat Landsat 8

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	38	12	50
Ostatní plochy	0	50	50
Celkem sloupce	38	62	100

Zdroj: vlastní zpracování

Dále byla provedena klasifikace z dat Sentinel 2, která je znázorněna na obrázku 20. Klasifikace byla provedena také velice rychle a trvala pouhé 4,54 sekundy. Algoritmus provedl klasifikaci do 4 zvolených tříd a poté pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní plochy – 3 třídy). Výstup z dané klasifikace je vidět na obrázku 14.



Obrázek 20: Klasifikace metodou Maximum Likelihood z dat Sentinel 2

Zdroj: vlastní zpracování, data [29]

Z tabulky 12 je patrné, že zde klasifikátor neklasifikoval dobře a některé body klasifikoval špatně. Jeden z hlavních objektů, který nedokázal dobře vyklasifikovat je řeka Labe. Konkrétně 38 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy, ovšem 12 bodů, které ve skutečnosti jsou vodní plochy, klasifikoval jako ostatní

plochy. Ovšem všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.

Tabulka 12: Klasifikační matice z klasifikace metodou Maximum Likelihood z dat Sentinel 2

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	38	12	50
Ostatní plochy	0	50	50
Celkem sloupce	38	62	100


Zdroj: vlastní zpracování

Z klasifikace metodou Maximum Likelihood z dat Landsat 8 a Sentinel 2 nelze určit, jak po vizuální stránce, tak podle klasifikační chybové matice, která data byla pro tuto klasifikaci lepší.

4.4.3 Class Probability

Další metodou z řízených klasifikací v programu ArcGIS 10.2 for Desktop je metoda Class Probability. Pro tuto metodu byly použity vytvořené trénovací plochy z předchozí metody Maximum Likelihood. Při použité metody Class Probability je nejprve nutné přidat pásma, podle kterých chce uživatel klasifikovat. Použitá pásma jednotlivých družic byla v této studii, již zmíněna. Poté je nutné vložit soubor s vytvořenými trénovacími plochami. Pak už proběhne výběr místa uložení daného klasifikovaného souboru. Ostatní parametry byly ponechány v defaultním nastavení, jelikož nejsou pro tuto klasifikaci důležité.

První klasifikace této metody z dat Landsat 8 byla provedena velice rychle a trvala pouhé 3,83 sekundy. Algoritmus provedl klasifikaci do 4 zvolených tříd a poté pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní plochy – 3 třídy). Na obrázku 21 je zobrazena klasifikace z dat Landsat 8.



Obrázek 21: Klasifikace metodou Class Probability z dat Landsat 8

Zdroj: vlastní zpracování, data [29]

Z tabulky 13 je patrné, že zde klasifikátor neklasifikoval dobře a některé body klasifikoval špatně. Jeden z hlavních objektů, který nedokázal dobře vyklasifikovat je řeka Labe. Konkrétně 38 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy, ovšem 12 bodů, které ve skutečnosti jsou vodní plochy, klasifikoval jako ostatní plochy. Ovšem všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.

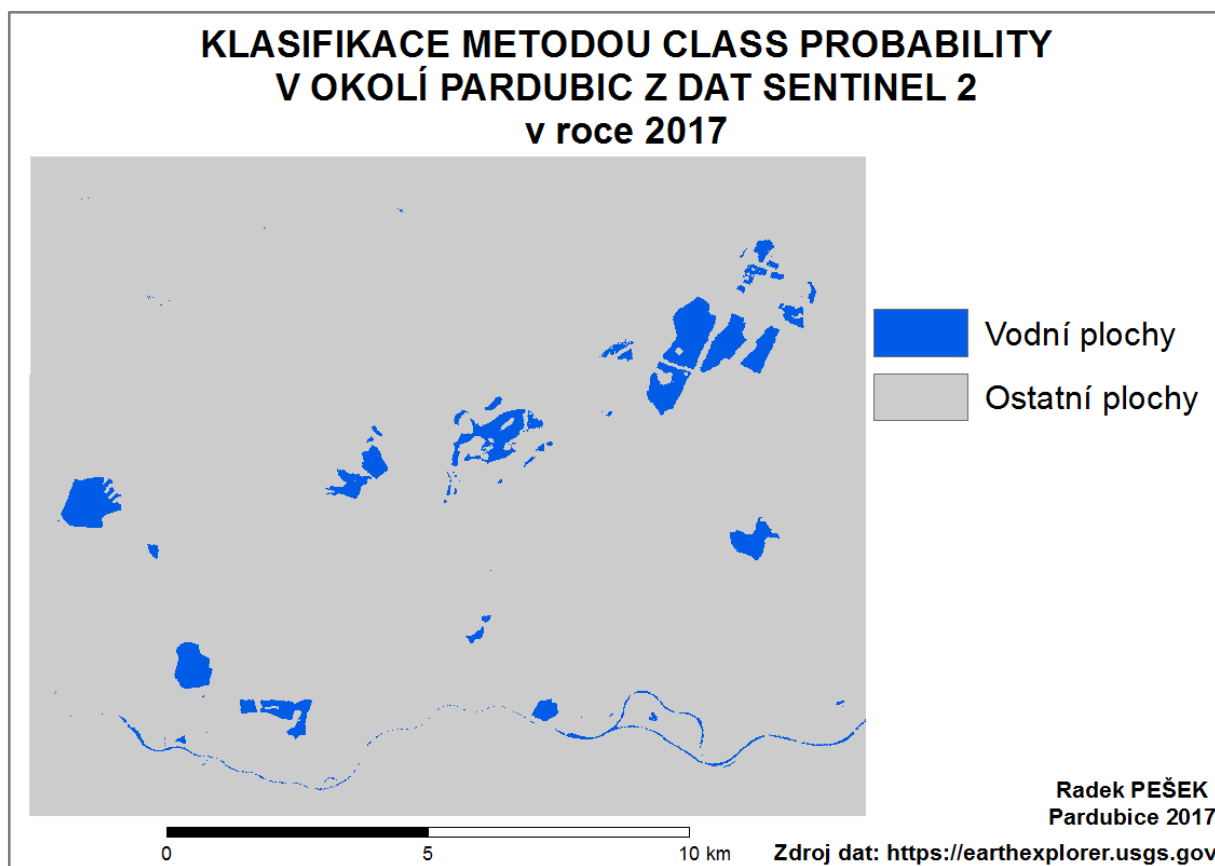
Tabulka 13: Klasifikační matice z klasifikace metodou Class Probability z dat Landsat 8

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	38	12	50
Ostatní plochy	0	50	50
Celkem sloupce	38	62	100

Zdroj: vlastní zpracování

Druhá klasifikace této metody z dat Sentinel byla provedena nepatrně pomaleji než s daty Landsat 8 a trvala 6,64 sekundy. Algoritmus provedl klasifikaci do 4 zvolených tříd a poté

pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní plochy – 3 třídy). Na obrázku 22 je zobrazena klasifikace z dat Sentinel 2.



Obrázek 22: Klasifikace metodou Class Probability z dat Sentinel 2

Zdroj: vlastní zpracování, data [29]

Z tabulky 14 je patrné, že zde také klasifikátor některé body klasifikoval špatně, stejně jako s daty Landsat 8. Jeden z hlavních objektů, který nedokázal dobře vyklasifikovat je řeka Labe. Konkrétně 38 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy, ovšem 12 bodů, které ve skutečnosti jsou vodní plochy, klasifikoval jako ostatní plochy. Ovšem všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.

Tabulka 14: Klasifikační matice z klasifikace metodou Class Probability z dat Sentinel 2

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	38	12	50
Ostatní plochy	0	50	50
Celkem sloupce	38	62	100

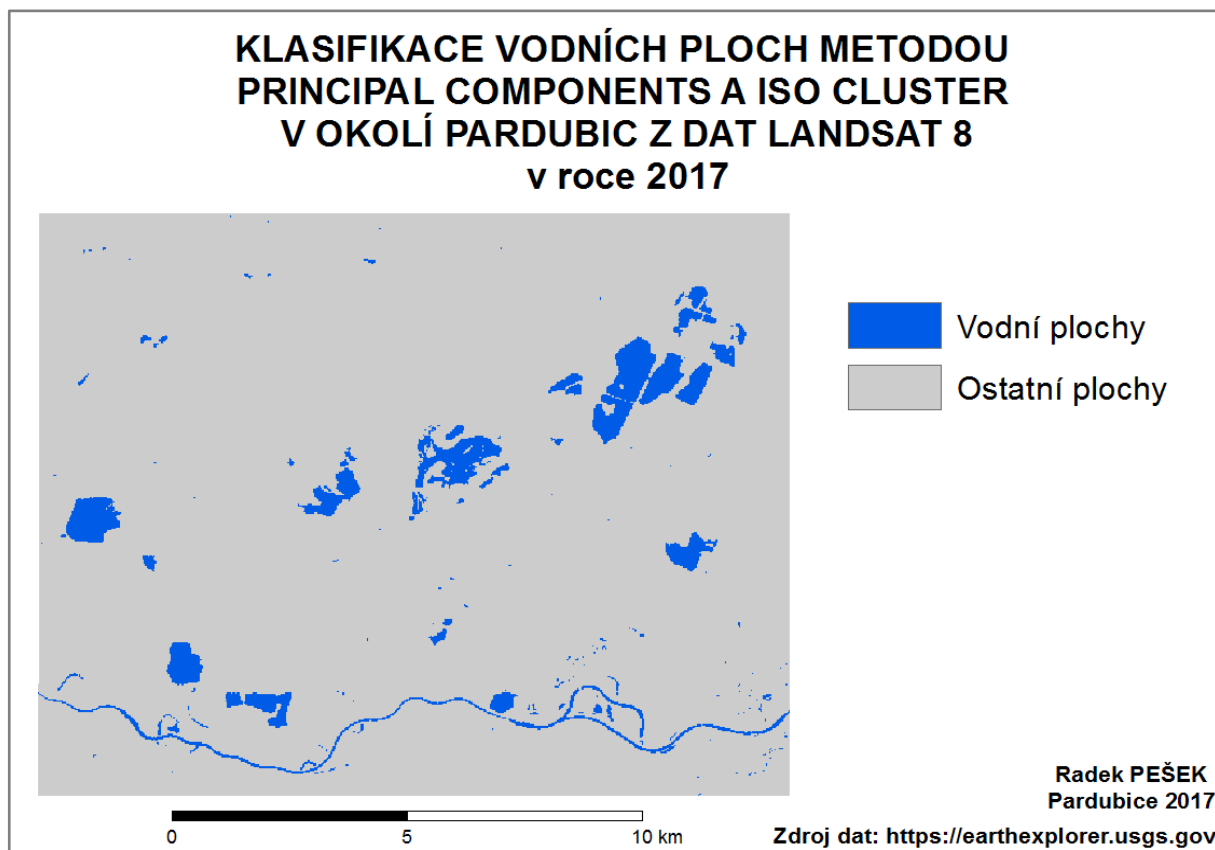
Zdroj: vlastní zpracování

Z klasifikace metodou Class Probability z dat Landsat 8 a Sentinel 2 nelze určit, jak po vizuální stránce, tak podle klasifikační chybové matice, která data byla pro tuto klasifikaci lepší.

4.4.4 Principal Components

Poslední klasifikační metodou v programu ArcGIS 10.2 for Desktop je metoda Principal Components. Tato metoda je specifická, jelikož její výstup slouží jaké vstup do ostatních klasifikací. Výstup z této metody byl použit jako vstup nejlepší metody v této práci a to Iso Cluster (5 tříd). Pro použitou metodu Principal Components je nejprve nutné přidat pásma, podle kterých chce uživatel klasifikovat. Použitá pásma jednotlivých družic byla v této studii, již zmíněna. Dále je potřebné vybrat počet hlavních komponent. V této klasifikaci bylo nejprve nastaveno 10 hlavních komponent pro data Sentinel 2 a 8 hlavních komponent pro data Landsat 8. Počty hlavních komponent byly stanoveny na základně počtu použitých pásem. Výstupy z těchto klasifikací napověděly, že 98% rozptylu vysvětlují 3 hlavní komponenty. Proto pro druhou klasifikaci z dat Landsat 8 a Sentinel 2 byly nastaveny 3 hlavní komponenty. Pak už proběhne výběr místa uložení daného výstupu z klasifikace. Ostatní parametry byly ponechány v defaultním nastavení, jelikož nejsou pro tuto klasifikaci důležité.

První klasifikace metody Principal Components (3 hlavní komponenty) s metodou Iso Cluster (5 tříd) z dat Landsat 8 byla provedena rychle a trvala pouhé 7,38 sekundy. Výstup z metody Principal Components byl vstupem do metody Iso Cluster, který provedl klasifikaci do 5 zvolených tříd a poté pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní plochy – 4 třídy). Na obrázku 23 je zobrazena klasifikace z dat Landsat 8 s využitím 3 hlavních komponent.



Obrázek 23: Klasifikace metodou Principal Components (3) a Iso Cluster z dat Landsat 8

Zdroj: vlastní zpracování, data [29]

Z následující tabulky 15 je zřejmé, že tento klasifikátor klasifikoval všechny body správně. Všech 50 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy a všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.

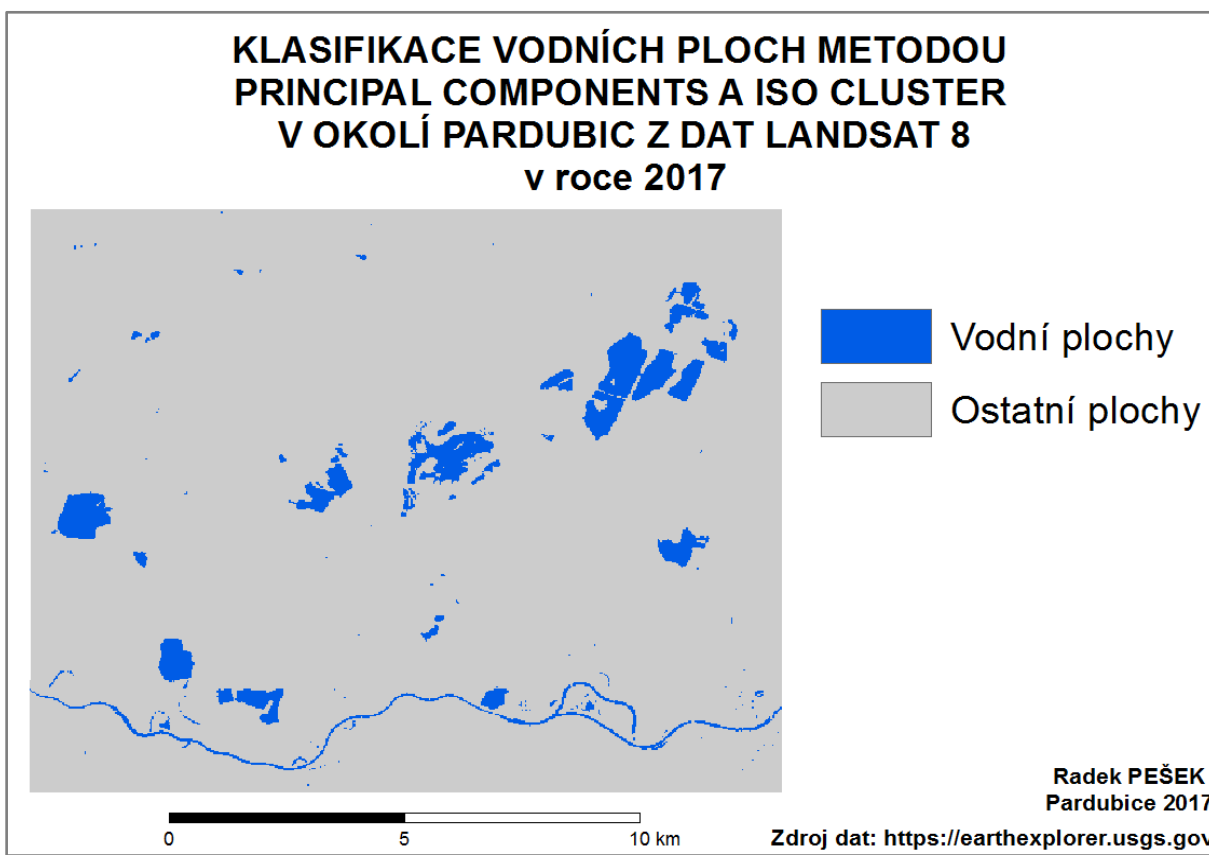
Tabulka 15: Klasifikační matice z klasifikace metodou Principal Components (3) a Iso Cluster z dat Landsat 8

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	50	0	50
Ostatní plochy	0	50	50
Celkem sloupce	50	50	100

Zdroj: vlastní zpracování

Druhá klasifikace metody Principal Components (8 hlavních komponent) s metodou Iso Cluster (5 tříd) z dat Landsat 8 byla provedena nepatrně pomaleji, než s použitím 3 hlavních komponent a trvala 11,88 sekundy. Výstup z metody Principal Components byl vstupem do metody Iso Cluster, který provedl klasifikaci do 5 zvolených tříd a poté pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní

plochy – 4 třídy). Na obrázku 24 je zobrazena klasifikace z dat Landsat 8 využitým 8 hlavních komponent.



Obrázek 24: Klasifikace metodou Principal Components (8) a Iso Cluster z dat Landsat 8

Zdroj: vlastní zpracování, data [29]

Z následující tabulky 16 je zřejmé, že tento klasifikátor klasifikoval všechny body správně. Všech 50 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy a všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.

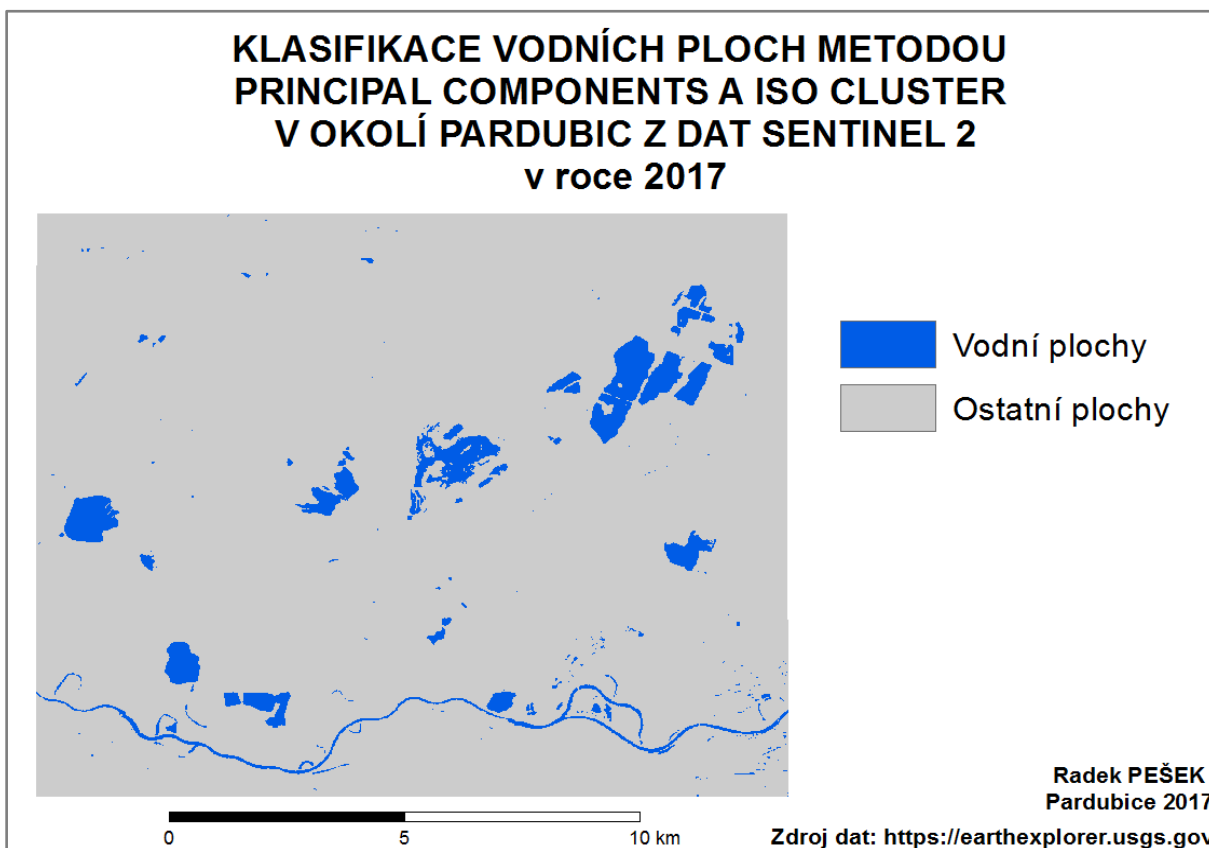
Tabulka 16: Klasifikační matice z klasifikace metodou Principal Components (8) a Iso Cluster z dat Landsat 8

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	50	0	50
Ostatní plochy	0	50	50
Celkem sloupce	50	50	100

Zdroj: vlastní zpracování

První klasifikace metody Principal Components (3 hlavní komponenty) s metodou Iso Cluster (5 tříd) z dat Sentinel 2 byla provedena o dost pomaleji než z dat Landsat 8 a trvala 30,44 sekund. Výstup z metody Principal Components byl vstupem do metody Iso Cluster,

který provedl klasifikaci do 5 zvolených tříd a poté pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní plochy – 4 třídy). Na obrázku 25 je zobrazena klasifikace z dat Sentinel 2 s využitím 3 hlavních komponent.



Obrázek 25: Klasifikace metodou Principal Components (3) a Iso Cluster z dat Sentinel 2

Zdroj: vlastní zpracování, data [29]

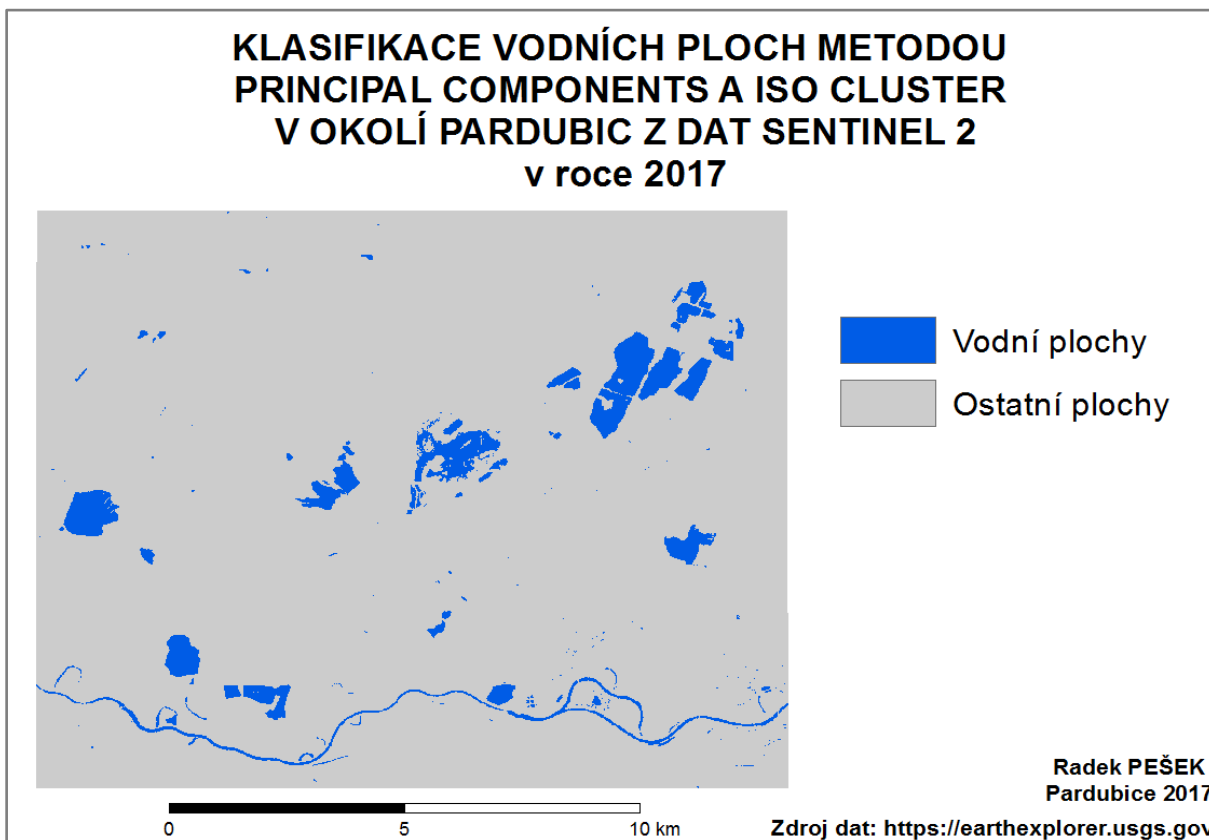
Z následující tabulky 17 je zřejmé, že tento klasifikátor neklasifikoval všechny body správně. Jeden bod, které ve skutečnosti je součástí vodní plochy byl klasifikován jako bod ostatní plochy. Dalších 49 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy a všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.

Tabulka 17: Klasifikační matice z klasifikace metodou Principal Components (3) a Iso Cluster z dat Sentinel 2

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	49	1	50
Ostatní plochy	0	50	50
Celkem sloupce	49	51	100

Zdroj: vlastní zpracování

Druhá klasifikace metody Principal Components (10 hlavních komponent) s metodou Iso Cluster (5 tříd) z dat Sentinel 2 byla provedena o dost pomaleji než předchozí a trvala 84,52 sekund. Výstup z metody Principal Components byl vstupem do metody Iso Cluster, který provedl klasifikaci do 5 zvolených tříd a poté pomocí funkce Reclassify došlo ke sjednocení do již zmíněných dvou tříd (vodní plochy – 1 třída a ostatní plochy – 4 třídy). Na obrázku 26 je zobrazena klasifikace z dat Sentinel 2 s využitím 10 hlavních komponent.



Obrázek 26: Klasifikace metodou Principal Components (10) a Iso Cluster z dat Sentinel 2

Zdroj: vlastní zpracování, data [29]

Z následující tabulky 18 je zřejmé, že tento klasifikátor klasifikoval všechny body správně. Všech 50 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy a všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.

Tabulka 18: Klasifikační matice z klasifikace metodou Principal Components (10) a Iso Cluster z dat Sentinel 2

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	50	0	50
Ostatní plochy	0	50	50
Celkem sloupce	50	50	100

Zdroj: vlastní zpracování

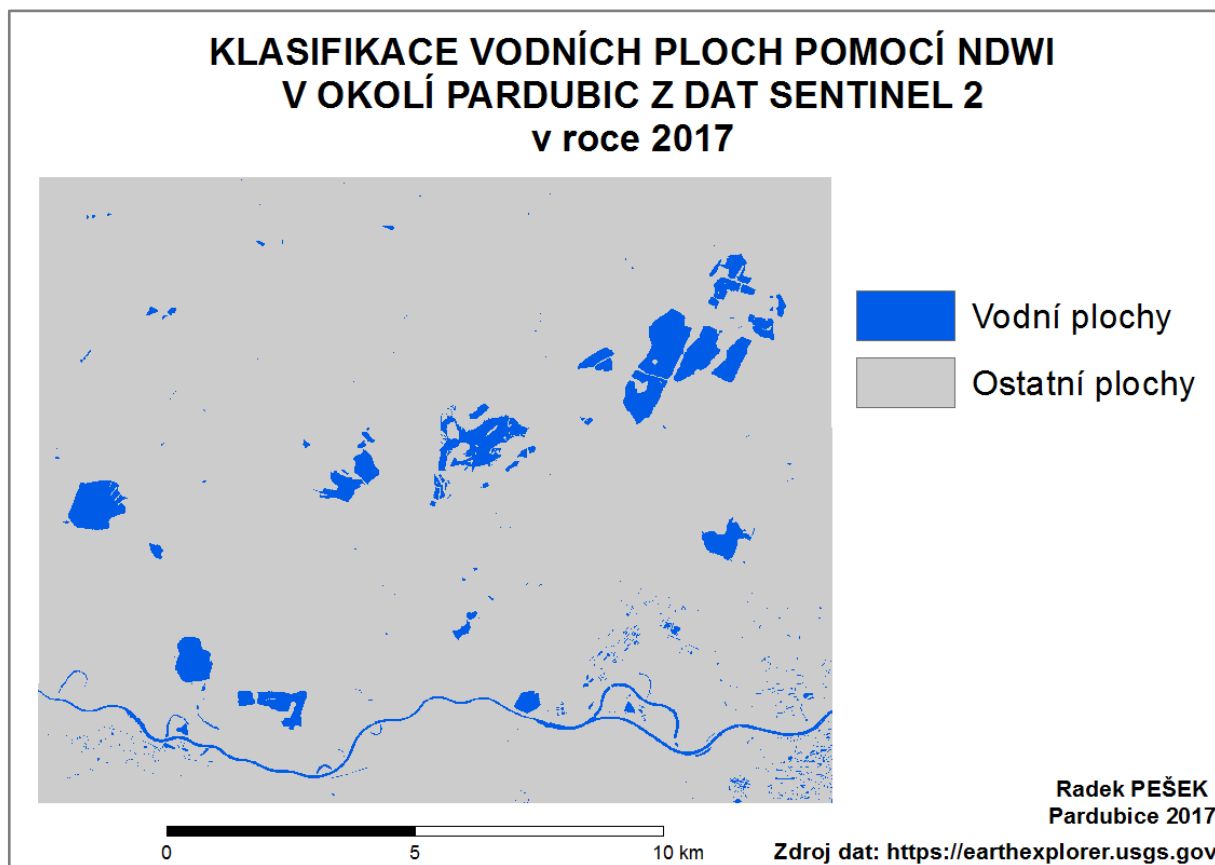
Z klasifikace metodou Principal Components s metodou Iso Cluster z dat Landsat 8 a Sentinel 2 nelze určit, jak po vizuální stránce, tak podle klasifikační chybové matice, která data byla pro tuto klasifikaci lepší. Ovšem podle klasifikačních matic jsou o něco málo lepší data z Landsat 8, jelikož u první klasifikace z dat Sentinel 2 s použitím 3 hlavních komponent byl jeden bod zařazen špatně.

4.4.5 NDWI – Normalized difference water index

Z předchozích zkoumaných studií vyplynulo, že NDWI fungovalo velice spolehlivě. Index NDWI je jedním z nejvhodnějších pro mapování vodních ploch a ve většině případů může zlepšit informace o vodních plochách. NDWI využívá zelené a blízké infračervené pásmo. Proto byl v této práci použit tento index pro porovnání s klasifikačními metodami, které poskytuje ArcGIS for Desktop 10.2. Ovšem klasifikace pomocí NDWI nebude použita v porovnání metod. [21]

$$NDWI = \frac{Band_{green} - Band_{nir}}{Band_{green} + Band_{nir}}, \quad (2)$$

Poslední byla provedena klasifikace pomocí indexu NDWI, který je vhodný pro mapování vodních ploch a také přinášel v již zmíněných studiích velmi dobré výsledky. Tento index byl použit proto, jelikož je pro mapování vodních ploch ověřený. Tudíž klasifikace pomocí indexu NDWI je v této práci použita ke srovnání, jestli nejlepší klasifikační metoda ve zvoleném programovém prostředí je také použitelná pro klasifikaci vodních ploch. Ovšem srovnání bude pouze vizuální s nejlepším výsledkem z klasifikačních metod. Klasifikace podle NDWI nebude použita v multikriteriálním rozhodování. Použití indexu je velmi jednoduché. V programové prostředí ArcGIS for Desktop 10.2 se zvolí funkce „Raster Calculator“ a zde se vloží pásma podle výše uvedeného vzorce (2).



Obrázek 27: Klasifikace pomocí NDWI z dat Sentinel 2

Zdroj: vlastní zpracování, data [29]

Z tabulky 19 je patrné, že zde klasifikátor některé body klasifikoval špatně. Konkrétně 48 bodů, které ve skutečnosti byly vodních plochy, klasifikoval taky jako vodní plochy, ovšem 2 body, které ve skutečnosti jsou vodní plochy, klasifikoval jako ostatní plochy. Dále všech 50 bodů, které ve skutečnosti byly ostatní plochy, klasifikoval jako ostatní plochy.

Tabulka 19: Klasifikační matice z klasifikace pomocí NDWI z dat Sentinel 2

Klasifikace	Vodní plochy	Ostatní plochy	Celkem řádky
Skutečnost			
Vodní plochy	48	2	50
Ostatní plochy	0	50	50
Celkem sloupce	48	52	100

Zdroj: vlastní zpracování

4.4.6 Porovnání jednotlivých klasifikačních metod z hlediska přesnosti

V klasifikacích je obecně nejdůležitější přesnost, tudíž i v této studii je přesnost nejdůležitějším kritériem. V následující tabulce 20 jsou znázorněny a následně seřazeny (od nejlepší po nejhorší) všechny klasifikační algoritmy, včetně ověřené klasifikace podle indexu NDWI. Tyto metody jsou seřazeny podle špatně klasifikovaných bodů z klasifikační chybové matice.

Z tabulky 20 nelze vyčíst, jestli jsou lepší data z družice Landsat 8 nebo Sentinel 2. Ovšem je jasné, že nejlepší klasifikační metoda, podle špatně klasifikovaných z klasifikační chybové matice, je metoda Iso Cluster. Tento algoritmus obsadil z 6 použití hned prvních 6 míst. Klasifikační metoda Iso Cluster skončila i nad ověřenou klasifikací pomocí NDWI, z čehož vyplývá, že je vhodná pro klasifikaci vodních ploch z hlediska přesnosti.

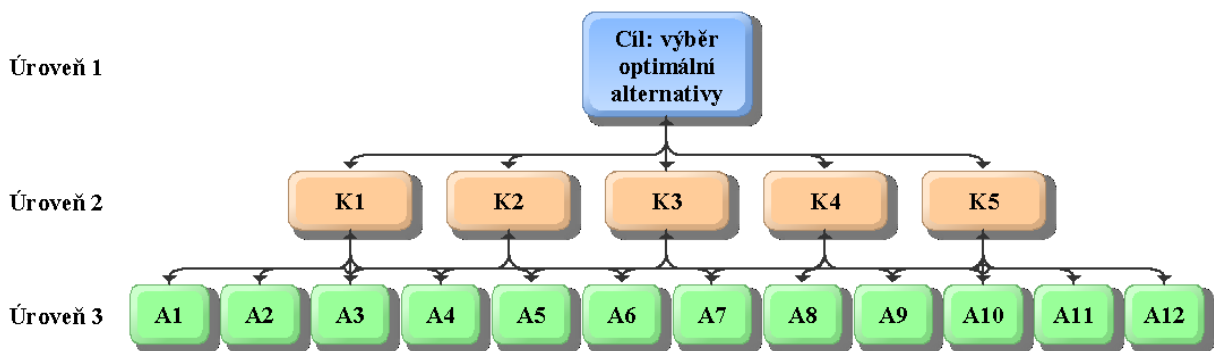
Tabulka 20: Porovnání jednotlivých klasifikačních metod z hlediska přesnosti

Klasifikační metoda	Datová sada	Počet tříd	Špatně klasifikované body	Vodní plochy [ha]
Iso Cluster	Sentinel	5	0	970
Iso Cluster	Landsat	5	0	987
Principal Components + Iso	Sentinel	10 + 5	0	950
Principal Components + Iso	Landsat	3 + 5	0	950
Principal Components + Iso	Landsat	8 + 5	0	933
Principal Components + Iso	Sentinel	3 + 5	1	979
NDWI	Sentinel	-	2	952
Iso Cluster	Sentinel	20	4	792
Iso Cluster	Landsat	20	4	751
Maximum Likelihood	Sentinel	4	12	656
Class Probability	Sentinel	4	12	653
Class Probability	Landsat	4	12	639
Maximum Likelihood	Landsat	4	12	638

Zdroj: vlastní zpracování

4.5 Porovnání metod – multikriteriální rozhodování

Pro porovnání klasifikačních metod byla použita metoda AHP (Analytic Hierarchy Process). Metodu AHP vyvinul Thomas L. Saaty. Tato metoda je z oblasti multikriteriálního rozhodování. Základním rysem této metody je využití dekompozice řešeného problému na víceúrovňovou hierarchickou strukturu. Tato struktura pro řešený problém výběru optimální klasifikační metody je znázorněna na obrázku 28, kde úroveň 1 – cíl: výběr optimální varianty, úroveň 2 – kritéria hodnocení, úroveň 3 – alternativy. [12][30]



Obrázek 28: Tříúrovňová hierarchická struktura

Zdroj: vlastní zpracování

Pro stanovení vah kritérií a stanovení vah alternativ pro jednotlivá kritéria metoda AHP využívá Saatyho matice. Při definování Saatyho matice se využívá stupnice od 1-9 a je to stupnice relativních důležitostí, která je viditelná v tabulce 21. [12][25][30]

Tabulka 21: Saatyho stupnice relativních důležitostí

Intenzita relativních důležitostí	Definice důležitostí
1	Stejná
3	Slabá
5	Silná
7	Prvotřídní
9	Absolutní
2, 4, 6, 8	Hodnoty mezi 1, 3, 5, 7, 9 (mezihodnoty)

Zdroj: [12][25][30]

Pro výpočet Saatyho matic je možné využít v MS Excel funkci GEOMEAN (geometrický průměr), který spočítá hodnotu R_i , a pomocí této hodnoty se vypočítají normované váhy v_i . V této práci bylo nutné vytvořit celkem 6 Saatyho matic. Jedna matice pro stanovení vah kritérií a 5 matic pro stanovení vah alternativ pro jednotlivá kritéria. Nalezení optimální varianty lze spočítat podle následujícího vzorce.

$$\text{„Optimální“ alternativa} = (H^j)_{max}, \text{ jestliže platí, že } H^j = \sum_{i=1}^m (v_i * h_i^j), \quad (3)$$

kde: v_i je váha (důležitost) i -tého kritéria pro $i=1,2,\dots,m$; h_i^j je ohodnocení j -té alternativy pro i -té kritérium.

U jednotlivých Saatyho matic bylo nutné zajistit jejich konzistentnost. Ovšem dokonalá konzistence se vyskytuje jenom zřídka. U metody AHP jsou považovány za konzistentní matice, je-li odpovídající koeficient CR menší než 10%. V této práci všechny Saatyho matice splňují konzistentnost. Pro výpočet koeficientu CR je nutný náhodný index RI, který je možné

získat z následujícího tabulky standardních hodnot průměrného indexu náhodné konzistence RI. Tato tabulka je zobrazena na následujícím obrázku 29. [25][30][18]

Matrix order number	1	2	3	4	5	6	7	8
RI	0	0.52	0.90	1.12	1.25	1.35	1.42	
Matrix order number	9	10	11	12	13	14	15	
RI	1.46	1.49	1.52	1.54	1.56	1.58	1.59	

Obrázek 29: Standardní hodnoty průměrného indexu náhodné konzistence RI

Zdroj: [18]

Dále je nutné vypočítat index konzistence (CI) a poté už se vypočítá hodnota poměru konzistence (CR). Tyto koeficienty se vypočítají pomocí následujících vzorců (4). [25][30][18]

$$CI = (\lambda_{\max} - n) / (n - 1), CR = RI / CI, \quad (4)$$

kde: λ_{\max} – maximální vlastní číslo; n – rozměr matice; CR – poměr konzistence, RI – náhodný index, CI – index konzistence.

4.5.1 Kritéria hodnocení

Nejprve je nutné stanovit si kritéria hodnocení a seřadit je podle stupnice důležitosti. V tabulce 22 jsou seřazeny definované kritéria podle důležitosti. Kritérium K1 – klasifikační chybová matice bylo zvoleno jako nejdůležitější, jelikož přesnost klasifikace je pro tuto studii nejvíce důležitá. Jako nejméně důležité kritérium bylo určeno kritérium K5 – čas trvání klasifikační metody, jelikož s dnešní výpočetní technikou a pro tento řešený problém jsou rozdíly trvání klasifikace zanedbatelné. Ačkoli při použití těchto klasifikačních metod pro rozsáhlejší území by toto kritérium nabíralo na váze.

Tabulka 22: Důležitost a váha kritérií hodnocení

	Stupnice důležitosti
K1	nejvíce důležité
K2	více důležité
K3	důležité
K4	méně důležité
K5	nejméně důležité

Zdroj: vlastní zpracování

Kritérium 1 – klasifikační chybová matice

Prvním kritériem je klasifikační chybová matice, která vyjadřuje přesnost klasifikace a ta je v práci a klasifikaci nejdůležitější. V následující tabulce 23 jsou porovnány klasifikační algoritmy podle počtu špatně klasifikovaných bodů.

Tabulka 23: Porovnání klasifikačních algoritmů podle špatně klasifikovaných bodů

Alternativy	Klasifikační metoda	Datová sada	Počet tříd	Špatně klasifikované body
A2	Iso Cluster	Sentinel	5	0
A1	Iso Cluster	Landsat	5	0
A12	Principal Components + Iso Cluster	Sentinel	10 + 5	0
A9	Principal Components + Iso Cluster	Landsat	3 + 5	0
A11	Principal Components + Iso Cluster	Landsat	8 + 5	0
A10	Principal Components + Iso Cluster	Sentinel	3 + 5	1
A4	Iso Cluster	Sentinel	20	4
A3	Iso Cluster	Landsat	20	4
A6	Maximum Likelihood	Sentinel	4	12
A8	Class Probability	Sentinel	4	12
A7	Class Probability	Landsat	4	12
A5	Maximum Likelihood	Landsat	4	12

Zdroj: vlastní zpracování

Kritérium 2 – výměry vybraných referenčních vodních ploch

Dalším kritériem jsou výměry vybraných referenčních vodních ploch, které byly ručně vytvořeny. Referenční plochy vznikly vytvořením polygonů dvou vodních ploch podle dat z družic Landsat 8 a Sentinel 2. První vybranou vodní plochou je Sopřečský rybník, který se na nachází na obrázku 30 vlevo. Výměra Sopřečského rybníku po ruční klasifikaci je 85,6 ha. Druhou zvolenou vodní plochou je Pohránovský rybník, který je znázorněn na obrázku 30 vpravo. Výměra Pohránovského rybníku po ruční klasifikaci je 45,48 ha. Ručně klasifikované vodní plochy jsou znázorněny na obrázku 30, které se pro porovnání stávají jako referenční plochy.



Obrázek 30: Ruční klasifikace dvou vodních ploch

Zdroj: vlastní zpracování, data [29]

Tyto výměry z ručně klasifikovaných (referenčních) vodních ploch jsou poté porovnány s výsledkem klasifikační metody a je vypočtena odchylka. Čím menší odchylka, tím lépe klasifikační metoda klasifikovala tyto vodní plochy. Výsledky jsou zobrazeny v tabulce 24 a jsou seřazeny od nejmenší po největší odchylky.

Tabulka 24: Porovnání klasifikačních algoritmů podle odchylky z vybraných referenčních ploch

Alternativa	Klasifikační metoda	Datová sada	Počet tříd	Sopřečský rybník [ha]	Pohránovský rybník [ha]	Odchylka [ha]
A2	Iso Cluster	Sentinel	5	86,55	44,49	0,04
A1	Iso Cluster	Landsat	5	86,00	44,08	1,00
A4	Iso Cluster	Sentinel	20	85,79	44,13	1,17
A6	Maximum Likelihood	Sentinel	4	85,89	44,02	1,18
A10	Principal Components + Iso Cluster	Sentinel	3 + 5	85,15	44,57	1,37

Alternativa	Klasifikační metoda	Datová sada	Počet tříd	Sopřečský rybník [ha]	Pohránovský rybník [ha]	Odchylka [ha]
A9	Principal Components + Iso Cluster	Landsat	3 + 5	87,30	45,46	1,68
A3	Iso Cluster	Landsat	20	81,13	38,20	11,75
A12	Principal Components + Iso Cluster	Sentinel	10 + 5	79,96	37,84	13,28
A7	Class Probability	Landsat	4	76,37	34,99	19,72
A8	Class Probability	Sentinel	4	76,31	34,91	19,86
A11	Principal Components + Iso Cluster	Landsat	8 + 5	75,57	34,05	21,46
A5	Maximum Likelihood	Landsat	4	75,57	34,05	21,46

Zdroj: vlastní zpracování

Kritérium 3 – náročnost klasifikační metody

Dalším kritériem je náročnost klasifikačních metod. Tato náročnost je podle toho, kolik kroků se v dané klasifikační metodě musí udělat. Zde byla určena stupnice se třemi náročnostmi. Náročnost 1 znamená, že daná metoda je nejméně náročná a není nutné před ní dělat žádný krok, ale může se hned spustit algoritmus. U náročnosti 2 je nutné udělat jeden důležitý krok před klasifikační metodu a to vytvoření trénovacích plochy. A u náročnosti 3 je zapotřebí vytvořit trénovací plochy a ještě ke klasifikaci jsou potřeba dva algoritmy, tudíž je nejvíce náročná. Náročnost jednotlivých klasifikačních metod je vypsána v tabulce 25.

Tabulka 25: Porovnání klasifikačních algoritmů podle náročnosti

Alternativy	Klasifikační metoda	Datová sada	Počet tříd	Náročnost
A1	Iso Cluster	Landsat	5	1
A2	Iso Cluster	Sentinel	5	1
A3	Iso Cluster	Landsat	20	1
A4	Iso Cluster	Sentinel	20	1
A5	Maximum Likelihood	Landsat	4	2
A6	Maximum Likelihood	Sentinel	4	2
A7	Class Probability	Landsat	4	2
A8	Class Probability	Sentinel	4	2
A9	Principal Components + Iso Cluster	Landsat	3 + 5	3
A10	Principal Components + Iso Cluster	Sentinel	3 + 5	3
A11	Principal Components + Iso Cluster	Landsat	8 + 5	3
A12	Principal Components + Iso Cluster	Sentinel	10 + 5	3

Zdroj: vlastní zpracování

Kritérium 4 – celková výměra vodních ploch

Dalším kritériem je celková výměra vodních ploch v zájmové oblasti. Ovšem zde nejsou k získání referenční data, tudíž není možné zjistit skutečnou výměru všech vodních ploch v zájmovém území. V tomto případě byly referenční data vybrány podle nejlepšího klasifikačního algoritmu (alternativa A2) z kritéria 2. Zde se předpokládá, že pokud algoritmus nejlépe klasifikoval vybrané vodní plochy, tak bude nejlépe klasifikovat i celkové vodní plochy. V následující tabulce 26 jsou celkové výměry vodních ploch jednotlivých klasifikačních metod včetně vypočítané odchylky.

Tabulka 26: Porovnání klasifikačních algoritmů podle odchylky z celkové výměry vodních ploch

Alternativa	Klasifikační metoda	Datová sada	Počet tříd	Vodní plochy [ha]	Odchylka [ha]
A2	Iso Cluster	Sentinel	5	970	0
A10	Principal Components + Iso Cluster	Sentinel	3 + 5	979	9
A1	Iso Cluster	Landsat	5	987	17
A12	Principal Components + Iso Cluster	Sentinel	10 + 5	950	20
A9	Principal Components + Iso Cluster	Landsat	3 + 5	950	20
A11	Principal Components + Iso Cluster	Landsat	8 + 5	933	37
A4	Iso Cluster	Sentinel	20	792	177
A3	Iso Cluster	Landsat	20	751	219
A6	Maximum Likelihood	Sentinel	4	656	314
A8	Class Probability	Sentinel	4	653	316
A7	Class Probability	Landsat	4	639	331
A5	Maximum Likelihood	Landsat	4	638	331

Zdroj: vlastní zpracování

Kritérium 5 – čas trvání klasifikační metody

Posledním kritériem je porovnání všech provedených metod z hlediska celkové doby trvání klasifikační metody. V současné době je výpočetní technika tak vyspělá, že čas trvání klasifikace není nijak časově náročný. V této práci se časové rozpětí trvání klasifikace pohybovalo od 1 do 12 sekund, ale jsou zde i dva algoritmy, které trvaly desítky sekund. Pokud by se zpracovávalo větší množství dat, tak poté by toto kritérium nabíralo na důležitosti. Jednotlivé časy trvání klasifikačních metod jsou v následující tabulce 27.

Tabulka 27: Porovnání klasifikačních algoritmů podle času trvání

Alternativa	Klasifikační metoda	Datová sada	Počet tříd	Čas trvání [s]
A5	Maximum Likelihood	Landsat	4	2,03
A7	Class Probability	Landsat	4	3,83
A1	Iso Cluster	Landsat	5	3,98
A6	Maximum Likelihood	Sentinel	4	4,54
A3	Iso Cluster	Landsat	20	4,74
A8	Class Probability	Sentinel	4	6,64
A2	Iso Cluster	Sentinel	5	7,04
A9	Principal Components + Iso Cluster	Landsat	3 + 5	7,38
A4	Iso Cluster	Sentinel	20	11,83
A11	Principal Components + Iso Cluster	Landsat	8 + 5	11,88
A10	Principal Components + Iso Cluster	Sentinel	3 + 5	30,44
A12	Principal Components + Iso Cluster	Sentinel	10 + 5	84,52

Zdroj: vlastní zpracování

4.5.2 Alternativy řešení

V dalším kroku bylo potřeba si stavit alternativy řešení. V této práci je stanovení alternativ jednoduché, jelikož to jsou všechny provedené klasifikační metody v rámci programového prostředí a celkově jich je 12. V následující tabulce 28 jsou jednotlivé alternativy popsány.

Tabulka 28: Alternativy multikriteriálního rozhodování

Alternativy	Klasifikační metoda	Datová sada	Počet tříd
Alternativa 1 – A1	Iso Cluster	Landsat	5
Alternativa 2 – A2	Iso Cluster	Sentinel	5
Alternativa 3 – A3	Iso Cluster	Landsat	20
Alternativa 4 – A4	Iso Cluster	Sentinel	20
Alternativa 5 – A5	Maximum Likelihood	Landsat	4
Alternativa 6 – A6	Maximum Likelihood	Sentinel	4
Alternativa 7 – A7	Class Probability	Landsat	4
Alternativa 8 – A8	Class Probability	Sentinel	4
Alternativa 9 – A9	Principal Components + Iso Cluster	Landsat	3 + 5
Alternativa 10 – A10	Principal Components + Iso Cluster	Sentinel	3 + 5
Alternativa 11 – A11	Principal Components + Iso Cluster	Landsat	8 + 5
Alternativa 12 – A12	Principal Components + Iso Cluster	Sentinel	10 + 5

Zdroj: vlastní zpracování

4.5.3 Výsledky multikriteriálního rozhodování

V následující tabulce 29 jsou výsledky z multikriteriálního rozhodování. Z této tabulky vyplývá, že nejlepší alternativa byla A2 a poté následovala alternativa A1. Tyto dvě alternativy byly provedeny klasifikační metodou Iso Cluster s použitím klasifikace do 5 tříd. Ovšem u alternativy A2 byly použita data z družice Sentinel 2 a u alternativy A1 byly použity data z družice Landsat 8.

Z toho vyplývá, že jak data z družice Sentinel 2, tak z družice Landsat 8 jsou stejně vhodná pro klasifikaci vodních ploch. Ačkoli pokud je možnost si vybrat mezi těmito druhy dat, tak je lepší sáhnout po datové sadě z družice Sentinel 2, jelikož přináší o něco málo lepší výsledky a má lepší prostorové rozlišení než družice Landsat 8. Z těchto výsledků dále vyplývá, že nejlepší klasifikační metoda pro vodní plochy, podle různých kritérií je metoda Iso Cluster s použitím klasifikace do 5 tříd. Srovnání jednotlivých klasifikačních metod je znázorněno v tabulce 28 seřazených od nejlepší po nejhorší.

Tabulka 29: Výsledky z multikriteriálního rozhodování

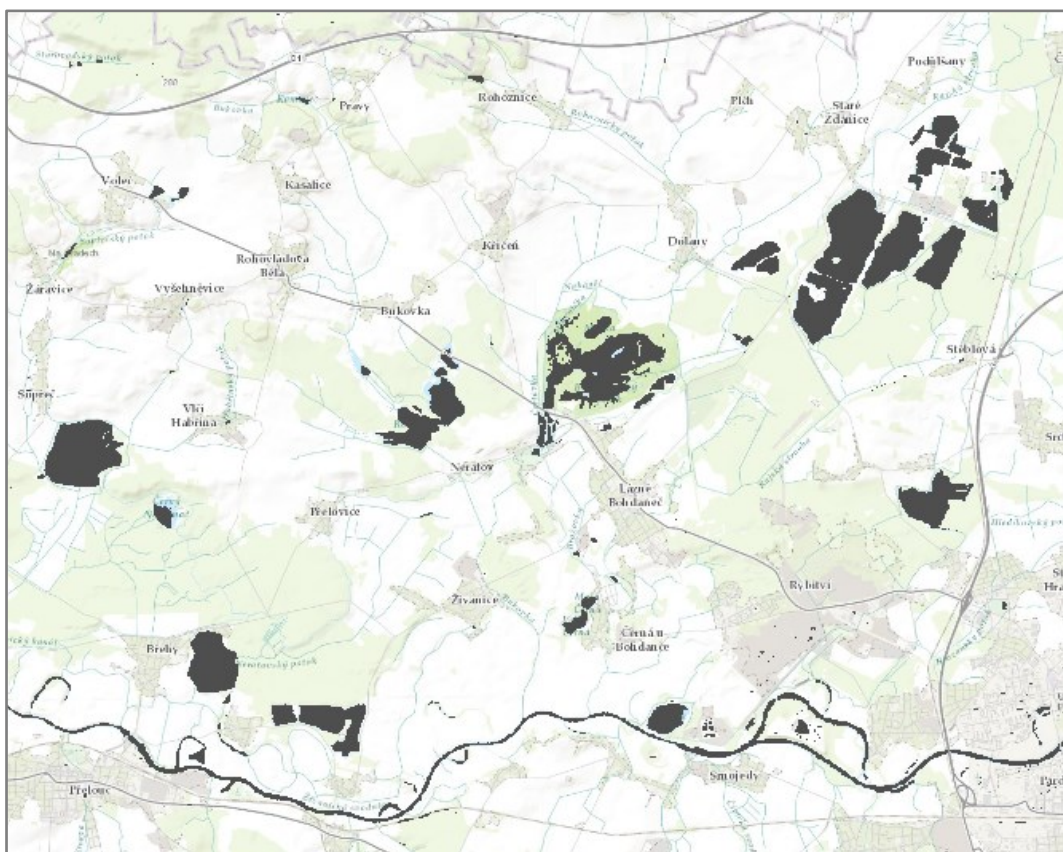
Alternativa	A2	A1	A9	A12	A10	A11	A4	A6	A3	A7	A5	A8
Výsledek	0,177	0,151	0,130	0,094	0,088	0,088	0,084	0,061	0,057	0,025	0,023	0,022

Zdroj: vlastní zpracování

4.6 Vizualizace výsledků

Nejlepší alternativa z multikriteriálního rozhodování je alternativa A2. Tato alternativa A2 byla provedena klasifikační metodu Iso Cluster s využitím klasifikace do 5 tříd z dat Sentinel 2. Tato klasifikační metoda je velice jednoduchá a nenáročná, jelikož je zde pouze jediný krok a to je samostatná metoda. To znamená, že se jen vyberou pásma, podle kterých má klasifikační metoda klasifikovat, vybere se počet tříd a klasifikace může proběhnout. Také tato klasifikace proběhla velmi rychle a to za pouhých 7,04 sekund. A samozřejmě také měla nejlepší přesnost, jak z hlediska klasifikační chybové matice, tak z hlediska vybraných referenčních ploch, tak z hlediska celkových ploch.


Na následujícím obrázku 31 je zobrazen výsledek této klasifikace na podkladové topografické mapě, která je dostupná v programovém prostředí ArcGIS for Desktop 10.2. Tmavě šedivá barva zvýrazňuje klasifikované plochy a je vybrána proto, aby byly vidět modré vodní plochy, které jsou na podkladové topografické mapě, a které algoritmus nedokázal rozpoznat.



Obrázek 31: Výsledek klasifikace metodou Iso Cluster (5 tříd) z dat Sentinel 2 na podkladové topografické mapě

Zdroj: vlastní zpracování


Na obrázku 32 je detailní záběr klasifikace na Sopřečský rybník. Zde je vizualizovaná klasifikace pouze na půlce rybníka, aby bylo vidět, jak klasifikační metoda dobře klasifikovala. Podkladem zde slouží blízko-infračervené pásmo 8A z družice Sentinel 2.



Obrázek 32: Výsledek klasifikace metodou Iso Cluster (5 tříd) z dat Sentinel 2 na podkladu pásma 8A

Zdroj: vlastní zpracování, data [29]

Na následujícím obrázku 33 je zobrazeno srovnání ověřené klasifikace pomocí NDWI z dat Sentinel 2 a nejlepší klasifikační metody z multikriteriálního rozhodování a to Iso Cluster (5 tříd) z dat Sentinel 2 – vpravo. Je patrné, že tyto dvě metody jsou srovnatelné, ovšem metoda Iso Cluster je o něco málo lepší, jelikož neklasifikovala množství malých bodů ve městě Pardubice a Přelouč, které klasifikovala metoda pomocí NDWI, ovšem tyto body nejsou vodní plochy. Dále je metoda Iso Cluster lepší, podle klasifikační matice, jelikož klasifikoval správně všech 100 bodů. Ovšem metoda pomocí NDWI zařadila 2 body špatně a zbylých 98 bodů správně. Vizuální porovnání těchto dvou metod je zobrazeno na obrázku 33.



Obrázek 33: Srovnání klasifikace pomocí NDWI – vlevo a klasifikace metodou Iso Cluster (5 tříd) – vpravo z dat Sentinel 2

Zdroj: vlastní zpracování, data [29]

Pomocí tohoto srovnání, lze říci, že klasifikace Iso Cluster (5 tříd) z dat Sentinel 2 z programového prostředí ArcGIS for Desktop 10.2 podle multikriteriálního rozhodování je použitelná a velice užitečná pro klasifikaci vodních ploch. Tento závěr vychází z předpokladu, že klasifikace pomocí NDWI je v mnoha studiích ověřená a velmi dobrá.

ZÁVĚR

Cílem této diplomové práce bylo porovnat všechny klasifikační metody pro klasifikaci vodních ploch v obrazových datech v rámci zvoleného programového prostředí. Pro porovnání a vyhodnocení klasifikačních metod byla využita metoda multikriteriálního rozhodování a to konkrétně metoda AHP – Analytic Hierarchy Process.

V úvodní části je vymezen a definován pojem dálkový průzkum Země. Dále jsou zde popsány nejrůznější základní oblasti využití DPZ včetně popisu konkrétního využití v dané oblasti. Poté jsou uvedeny druhy dat DPZ včetně jejich základních charakteristik. Pak už následuje popis využití klasifikace obrazu s rozdělením metod klasifikace včetně možností hodnocení klasifikace. Potom jsou vyjmenována dostupná družicová data podle jejich prostorového rozlišení.

Druhá část práce pojednává o případových studiích, které byly zpracovány na podobné téma jako tato diplomová práce. Součástí je zpracování informací těchto případových studií podle tohoto vzoru: název, zájmové území, cíl, zjištění. Poté už následuje sjednocení případových studií do jednotlivé tabulky, z které jsou pak vypsány nejlepší a nejvíce využívané klasifikační metody a nejpoužívanější družicová data.

Třetí část se zabývá vlastním porovnáním algoritmů v rámci případové studie. Bylo zvoleno zájmové území obsahující řadu malých vodních ploch a zároveň řeku Labe. V práci jsou využita data z družice Landsat 8 a družice Sentinel 2 a jsou použity 4 klasifikační algoritmy, které nabízí ArcGIS for Desktop 10.2. Celkově bylo provedeno 12 klasifikací, výpočet indexu NDWI a ruční klasifikace dvou zvolených vodních ploch. Výměry z ruční klasifikace slouží jako referenční plochy pro druhé kritérium v multikriteriálním rozhodování. Na závěr jsou výsledky porovnány a vyhodnoceny pomocí multikriteriálního rozhodování na základě 5 zvolených kritérií. Z multikriteriálního rozhodování je patrné, že pro klasifikaci vodních ploch je vhodné použít data z družice Sentinel 2, ale i Landsat 8. Ovšem pokud je možnost, tak je lepší sáhnout po datech z družice Sentinel 2, jelikož nabízí o něco málo lepší výsledky, jelikož má větší prostorové rozlišení. Nejlepší výsledek z multikriteriálního rozhodování je také vizualizován a porovnán, s již ověřeným klasifikátorem pomocí NDWI. Z výsledků vyplývá, že nejlepší klasifikační algoritmus pro vodní plochy v programovém prostředí ArcGIS for Desktop 10.2 je Iso Cluster (5 tříd) s použitím dat z družice Sentinel 2 a je vhodný pro klasifikaci malých vodních ploch.

POUŽITÁ LITERATURA

- [1] Aktuální data z polárních družic NOAA. Český hydrometeorologický ústav [online]. Praha: ČHMÚ, ©2010-2012 [cit. 2017-03-08]. Dostupné z: http://portal.chmi.cz/files/portal/docs/meteo/sat/data_jsavhrrview.html
- [2] Bohdanečský rybník (národní přírodní rezervace). Wikipedie [online]. San Francisco: Wikipedie, 2017 [cit. 2017-06-14]. Dostupné z: [https://cs.wikipedia.org/wiki/Bohdane%C4%8Dsk%C3%BD_rybn%C3%ADk_\(n%C3%A1rodn%C3%AD_p%C5%99%C3%ADrodn%C3%AD_rezervace\)](https://cs.wikipedia.org/wiki/Bohdane%C4%8Dsk%C3%BD_rybn%C3%ADk_(n%C3%A1rodn%C3%AD_p%C5%99%C3%ADrodn%C3%AD_rezervace))
- [3] DOBROVOLNÝ, Petr. Dálkový průzkum Země: digitální zpracování obrazu. Brno: Masarykova univerzita, 1998. ISBN 80-210-1812-7.
- [4] Družice LANDSAT. ARCDATA PRAHA [online]. Praha: ARCDATA PRAHA, 2017 [cit. 2017-05-24]. Dostupné z: <https://www.arcdata.cz/produkty/geograficka-data/druzicova-data/landsat>
- [5] Družice Sentinel. Geo/Copernicus v České republice [online]. CENIA, 2016 [cit. 2017-06-13]. Dostupné z: <http://copernicus.gov.cz/druzice-sentinel>
- [6] FEYISA, Gudina L., Henrik MEILBY, Rasmus FENSHOLT a Simon R. PROUD. Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. Remote Sensing of Environment [online]. 2014, 140(December), 23-35 [cit. 2017-06-07]. DOI: 10.1016/j.rse.2013.08.029. ISSN 00344257. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0034425713002873>
- [7] Gisat [online]. Praha: GISAT, 2001 [cit. 2017-04-09]. Dostupné z: <http://gisat.cz/content/cz>
- [8] HALOUNOVÁ, Lena a Karel PAVELKA. Dálkový průzkum Země. 1. Praha: ČVUT, 2005. ISBN 978-80-01-03124-7.
- [9] HUANG, Xin, Cong XIE, Xing FANG a Liangpei ZHANG. Combining Pixel- and Object-Based Machine Learning for Identification of Water-Body Types From Urban High-Resolution Remote-Sensing Imagery. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing [online]. 2015, 8(5), 2097-2110 [cit. 2017-06-07]. DOI: 10.1109/JSTARS.2015.2420713. ISSN 1939-1404. Dostupné z: <http://ieeexplore.ieee.org/document/7094223/>

- [10] JIANG, Hao, Min FENG, Yunqiang ZHU, Ning LU, Jianxi HUANG a Tong XIAO. An Automated Method for Extracting Rivers and Lakes from Landsat Imagery. *Remote Sensing* [online]. 2014, 6(6), 5067-5089 [cit. 2017-06-07]. DOI: 10.3390/rs6065067. ISSN 2072-4292. Dostupné z: <http://www.mdpi.com/2072-4292/6/6/5067/>
- [11] KOLÁŘ, Jan. *Dálkový průzkum země*. 1. Praha: Nakladatelství technické literatury, 1990. ISBN 80-03-00517-5.
- [12] KŘUPKA, Jiří, Miloslava KAŠPAROVÁ a Renáta MÁCHOVÁ. *Rozhodovací procesy*. Pardubice: Pardubice, 2012. ISBN 978-80-7395-478-9.
- [13] Labe. Mezinárodní komise pro ochranu Labe [online]. Magdeburg: MKOL, 2015 [cit. 2017-06-14]. Dostupné z: <http://www.ikse-mkol.org/cz/themen/labe/>
- [14] Landsat 8 OLI (Operational Land Imager) and TIRS (Thermal Infrared Sensor). USGS [online]. Reston: USGS, 2015 [cit. 2017-06-14]. Dostupné z: <https://lta.cr.usgs.gov/L8>
- [15] Landsat 8 Overview. Landsat Science [online]. Washington: NASA, 2017 [cit. 2017-06-14]. Dostupné z: <https://landsat.gsfc.nasa.gov/landsat-8/landsat-8-overview/>
- [16] Landsat program. Wikipedia [online]. Wikipedia, 2017 [cit. 2017-05-24]. Dostupné z: https://en.wikipedia.org/wiki/Landsat_program
- [17] LILLESAND, Thomas M., Ralph W. KIEFER a Jonathan W. CHIPMAN. *Remote sensing and image interpretation*. 6th ed. Hoboken, NJ: John Wiley, c2008. ISBN 978-0-470-05245-7.
- [18] LIU, Bin a Fanjun KONG. Research and application of sidewall stability prediction method based on analytic hierarchy process and fuzzy integrative evaluation method. *Natural Science* [online]. 2012, 04(02), 142-147 [cit. 2017-08-13]. DOI: 10.4236/ns.2012.42021. ISSN 2150-4091. Dostupné z: <http://www.scirp.org/journal/doi.aspx?DOI=10.4236/ns.2012.42021>
- [19] *Mapy.cz* [online]. Praha: Seznam.cz, 2017 [cit. 2017-03-08]. Dostupné z: <https://mapy.cz>
- [20] MURDYCH, Zdeněk. *Dálkový průzkum Země*. Praha: Academia, 1985.
- [21] NDWI (Normalized Difference Water Index). SENTIENL Hub [online]. Ljubljana: Laboratory for geographical information systems, 2017 [cit. 2017-08-12]. Dostupné z: <http://www.sentinel-hub.com/eoproducts/ndwi-normalized-difference-water-index>

- [22] NIKM - Národní inventarizace kontaminovaných míst [online]. Praha: CENIA, 2009 [cit. 2017-03-09]. Dostupné z: <http://kontaminace.cenia.cz/>
- [23] Oblasti využití DPZ. GEO/COPERNICUS V ČESKÉ REPUBLICE [online]. ©2016 [cit. 2017-03-08]. Dostupné z: <http://copernicus.gov.cz/oblasti-vyuziti-dpz#meteo>
- [24] ROKNI, Komeil, Anuar AHMAD, Ali SELAMAT, Sharifeh HAZINI, Jianxi HUANG a Tong XIAO. Water Feature Extraction and Change Detection Using Multitemporal Landsat Imagery. Remote Sensing [online]. 2014, 6(5), 4173-4189 [cit. 2017-06-07]. DOI: 10.3390/rs6054173. ISSN 2072-4292. Dostupné z: <http://www.mdpi.com/2072-4292/6/5/4173/>
- [25] SAATY, R.W. The analytic hierarchy process—what it is and how it is used. Mathematical Modelling [online]. 1987, 9(3-5), 161-176 [cit. 2017-08-12]. DOI: 10.1016/0270-0255(87)90473-8. ISSN 02700255. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0270025587904738>
- [26] SHANE FRAZIER, Paul a Kenneth JOHN PAGE. Water Body Detection and Delineation with Landsat TM Data. PHOTOGRAMMETRIC ENGINEERING & REMOTE SENSING [online]. 2000, 2000(December) [cit. 2017-06-07]. Dostupné z: http://web.pdx.edu/~nauna/resources/19-water2000_dec_1461-1467.pdf
- [27] Sopřečský rybník. Turistika.cz [online]. Praha: Turistika.cz, 2011 [cit. 2017-07-12]. Dostupné z: <https://www.turistika.cz/mista/soprecsky-rybnik/detail>
- [28] THOMAS, Rachael F., Richard T. KINGSFORD, Yi LU, Stephen J. COX, Neil C. SIMS a Simon J. HUNTER. Mapping inundation in the heterogeneous floodplain wetlands of the Macquarie Marshes, using Landsat Thematic Mapper. Journal of Hydrology [online]. 2015, 524, 194-213 [cit. 2017-06-07]. DOI: 10.1016/j.jhydrol.2015.02.029. ISSN 00221694. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0022169415001419>
- [29] USGS: EarthExplorer [online]. Reston: USGS, 2017 [cit. 2017-06-14]. Dostupné z: <https://earthexplorer.usgs.gov/>
- [30] USING THE ANALYTIC HIERARCHY PROCESS FOR DECISION MAKING IN ENGINEERING APPLICATIONS: SOME CHALLENGES. Inter'l Journal of Industrial Engineering: Applications and Practice [online]. 1995, 2(1), 1-11 [cit. 2017-08-12]. Dostupné z:

https://pdfs.semanticscholar.org/ea9f/45a87e91ebcaefd313c064638de4133af01f.pdf?_ga=2.69273686.778027238.1502571202-2034977994.1502571202

- [31] Využití GIS a DPZ pro krajinné inženýrství. Ústav hospodářské úpravy lesa a aplikované geoinformatiky [online]. Brno: Brno, 2014 [cit. 2017-05-23]. Dostupné z: <http://uhulag.mendelu.cz/cz/studium/vgdp>
- [32] XIE, Huan, Xin LUO, Xiong XU, Haiyan PAN a Xiaohua TONG. Automated Subpixel Surface Water Mapping from Heterogeneous Urban Environments Using Landsat 8 OLI Imagery. *Remote Sensing* [online]. 2016, 8(7), 584- [cit. 2017-06-07]. DOI: 10.3390/rs8070584. ISSN 2072-4292. Dostupné z: <http://www.mdpi.com/2072-4292/8/7/584>
- [33] YANG, Fan, Jianhua GUO, Hai TAN a Jingxue WANG. Automated Extraction of Urban Water Bodies from ZY-3 Multi-Spectral Imagery. *Water* [online]. 2017, 9(2), 144- [cit. 2017-06-07]. DOI: 10.3390/w9020144. ISSN 2073-4441. Dostupné z: <http://www.mdpi.com/2073-4441/9/2/144>
- [34] YANG, Xiucheng, Shanshan ZHAO, Xuebin QIN, Na ZHAO a Ligang LIANG. Mapping of Urban Surface Water Bodies from Sentinel-2 MSI Imagery at 10 m Resolution via NDWI-Based Image Sharpening. *Remote Sensing* [online]. 2017, 9(6), 596- [cit. 2017-06-13]. DOI: 10.3390/rs9060596. ISSN 2072-4292. Dostupné z: <http://www.mdpi.com/2072-4292/9/6/596>
- [35] ZHOU, Yan, Jinwei DONG, Xiangming XIAO, Tong XIAO, Zhiqi YANG, Guosong ZHAO, Zhenhua ZOU a Yuanwei QIN. Open Surface Water Mapping Algorithms: A Comparison of Water-Related Spectral Indices and Sensors. *Water* [online]. 2017, 9(4), 256- [cit. 2017-06-13]. DOI: 10.3390/w9040256. ISSN 2073-4441. Dostupné z: <http://www.mdpi.com/2073-4441/9/4/256>

SEZNAM PŘÍLOH

Příloha A – návod na stažení dat z družice Landsat 8 a Sentinel 2

Příloha B – spektrální pásma družice Landsat 8 a Sentinel 2

Příloha C – výsledek klasifikace metodou Class Probability (4 třídy) z dat Sentinel 2

Příloha D – multikriteriální rozhodování (CD)

Příloha E – data z družice a výsledky klasifikačních metod (CD)

Příloha A – návod na stažení dat z družice Landsat 8 a Sentinel 2

V 1. kroku nejprve do políčka „Address/Place“ (adresa/místo) bylo nutné napsat oblast, ze které se požaduje družicový snímek. Jelikož se příkladová studie zabývá okolí Pardubic, tak se do tohoto políčka vepsalo město Pardubice. V 2. kroku už stačilo jenom kliknout na tlačítko „Show“ (ukázat). Poté se zobrazilo vyhledávané místo, jelikož město Pardubice je v České republice jenom jedno, tak se ukázal jen jeden výsledek. Ve 3. kroku následovalo kliknutí na dané místo. Po kliknutí na dané místo (město Pardubice) se nám automaticky vyplní souřadnice, proto ve 4. kroku už stačí jen kliknout na tlačítko „Data Sets“ (datové sady). Zde je ještě možnost vybrat časové rozpětí pořizena družicových snímků, ovšem v této studii nezáleží na aktuálnosti dat, tudíž se zde nic nezadávalo. Tyto kroky jsou zobrazeny na následujícím obrázku 34.

Search Criteria | Data Sets | Additional Criteria | Results

1. Enter Search Criteria

To narrow your search area: type in an address or place name, enter coordinates or click the map to define your search area (for advanced map tools, view the [help documentation](#)), and/or choose a date range.

Address/Place | Path/Row | Feature | Circle

pardubice **1.**

2. Show Clear

Click on an Address/Place to show the location on the map and add coordinates to the Area of Interest Control.

Num	Address/Place	Latitude	Longitude
1	Pardubice, Česko 3.	50.0343	15.7812

Coordinates | Predefined Area | Shapefile | KML

Degree/Minute/Second | Decimal

i No coordinates selected.

Use Map | Add Coordinate | Clear Coordinates

Date Range | Result Options

Search from: mm/dd/yyyy to: mm/dd/yyyy

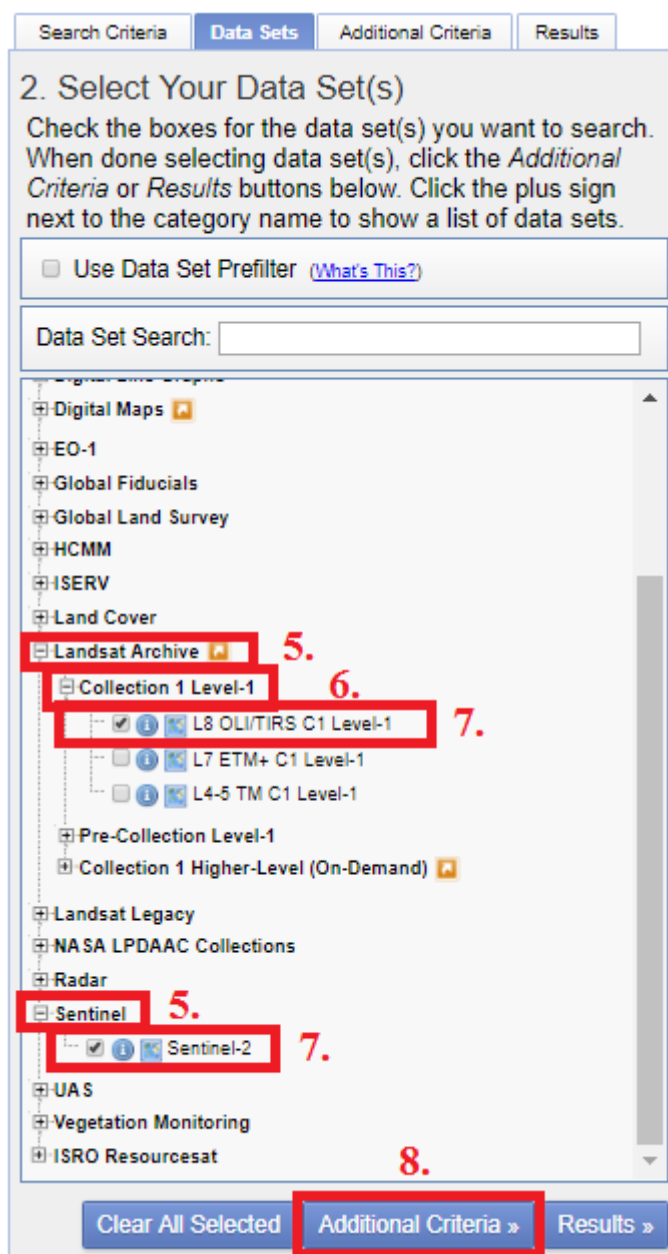
Search months: (all)

4. Data Sets » | Additional Criteria » | Results »

Obrázek 34: Výběr dat krok 1-4

Zdroj: upraveno podle [29]

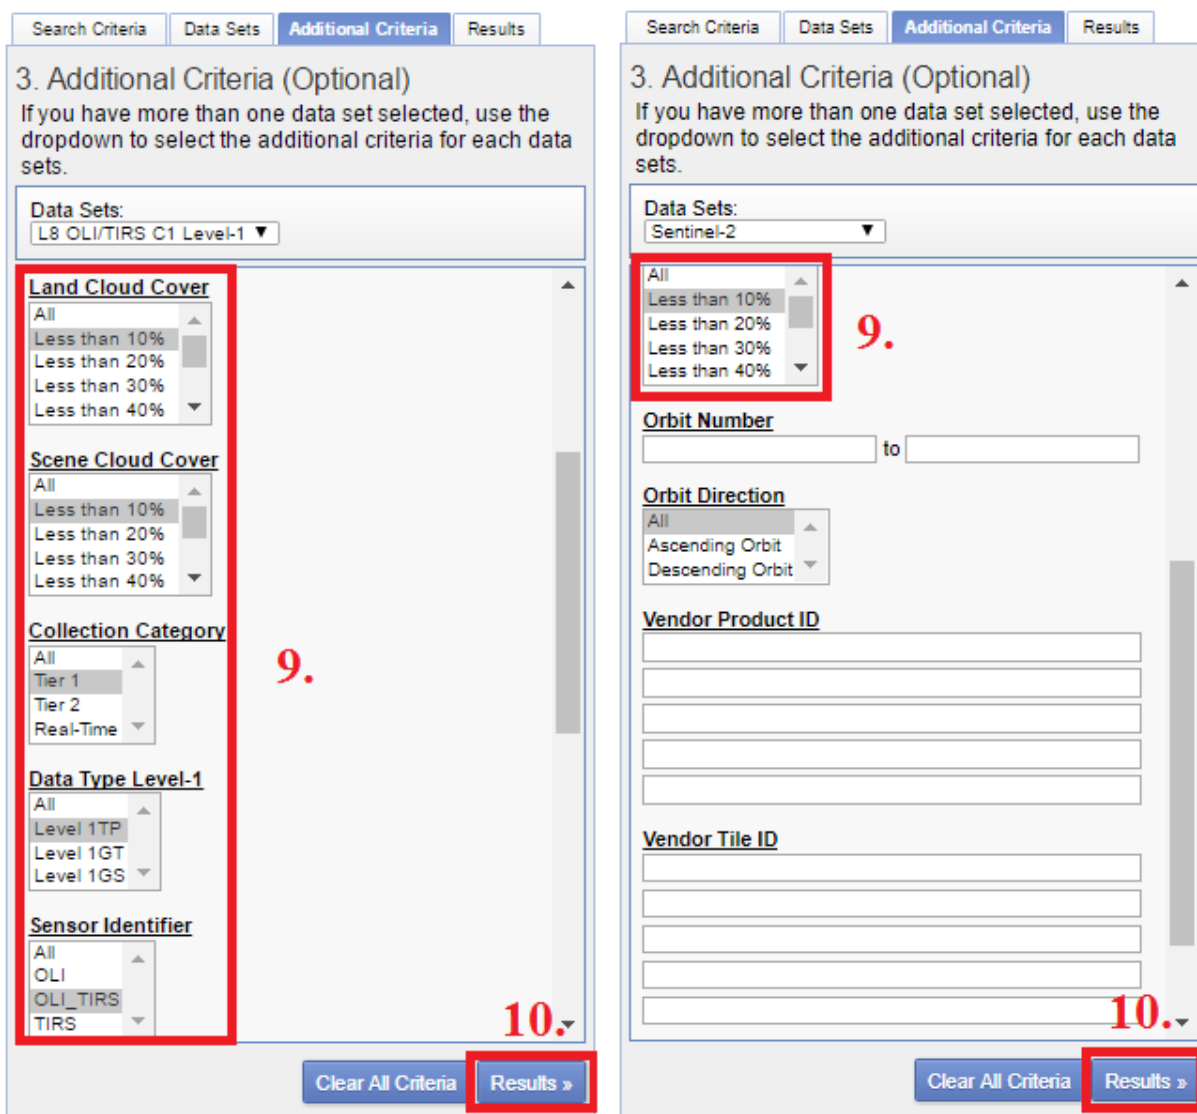
Po kliknutí na tlačítko „Data Sets“ (datové sady) se zobrazí karta Data Sets (datové sady). V 5. kroku se vybere požadovaná datová sada, v této příkladové studii byla vybrána datová sada „Landsat Archive“ a „Sentinel“. Následuje 6. krok, kde se vybere datová sada „Collection 1 Level-1“. Poté v 7. kroku už stačí vybrat družici, která pro tuto studii je Landsat 8 a Sentinel 2, tudíž se zaškrtně „L8 OLI/TIRS C1 Level-1“ a „Sentinel-2“. V 8 kroku je zapotřebí kliknout na tlačítko „Additional Criteria“ (další kritéria), kde se definují další kritéria na družicové snímky. Popsané kroky je zobrazeny na obrázku 35.



Obrázek 35: Výběr dat krok 5-8

Zdroj: upraveno podle [29]

Po kliknutí na tlačítko „Additional Criteria“ (další kritéria) se ukáže záložka „Additional Criteria“ (další kritéria), kde se nastavují kritéria pro zobrazení družicových snímků. V 9. kroku se nastavují různá kritéria pro zobrazení družicových snímků. V této příkladové studii se požaduje oblačnost menší než 10%, data nejvyšší kvality a použití obou senzorů v denní dobu, proto se podle toho nastavily kritéria. Poté už následuje 10. krok a to kliknutí na tlačítko „Results“ (výsledky). Tyto kroky jsou k nalezení na obrázku 36.



Obrázek 36: Výběr dat krok 9-10

Zdroj: upraveno podle [29]

Po 10. kroku se už zobrazí výsledky, podle zadaných kritérií. Zde v 11. kroku už stačí vybrat datový soubor a ve 12. kroku kliknout na tlačítko stáhnout. V této případové studii byl z družice Landsat 8 vybrán datový soubor pořízený 1. 4. 2017 a také neobsahuje téměř žádnou oblačnost (0,11 %). Z družice Sentinel 2 byl vybrán datový soubor také pořízený 1. 4. 2017 a také bez oblačnosti (0 %). U obou družic byl vybrán shodný čas pořízení, aby se mohly vzájemně porovnávat. Tento postup je k nahlédnutí na níže uvedeném obrázku 37.

Search Criteria Data Sets Additional Criteria **Results**

4. Search Results


If you selected more than one data set to search, use the dropdown to see the search results for each specific data set.







Note: You must be logged in to download and order scenes


Show Result Controls







Data Set [Click here to export your results »](#)


L8 OLI/TIRS C1 Level-1 **11.**







14  ID:LC08_L1TP_191025_20170401_20170414_01_T1
Acquisition Date:01-APR-17
Path:191
Row:25

      **12.**

15  ID:LC08_L1TP_190025_20170325_20170329_01_T1
Acquisition Date:25-MAR-17
Path:190
Row:25

16  ID:LC08_L1TP_191025_20170316_20170328_01_T1
Acquisition Date:16-MAR-17
Path:191
Row:25

Search Criteria Data Sets Additional Criteria **Results**

4. Search Results

If you selected more than one data set to search, use the dropdown to see the search results for each specific data set.

Note: You must be logged in to download and order scenes

Show Result Controls

Data Set [Click here to export your results »](#)

Sentinel-2 **11.**

6  Entity ID:L1C_T33UWR_A009271_20170401T100022
Coordinates:50.0560128 , 15.7666582
Acquisition Date:2017/04/01

      **12.**

7  Entity ID:L1C_T33UWR_A008799_20170227T095613
Coordinates:50.0560128 , 15.7666582
Acquisition Date:2017/02/27

8  Entity ID:L1C_T33UWR_A008599_20170213T101553
Coordinates:50.0560128 , 15.7666582
Acquisition Date:2017/02/13


     

Obrázek 37: Výběr dat krok 11-12

Zdroj: upraveno podle [29]

Příloha B – spektrální pásma družice Landsat 8 a Sentinel 2


Tabulka 30: Spektrální pásma družice Landsat 8




Pásmo 1



Pásmo 2




Pásmo 3




Pásmo 4




Pásmo 5




Pásmo 6




Pásmo 7




Pásmo 8



Pásmo 9




Pásmo 10




Pásmo 11

Zdroj: vlastní zpracování


Tabulka 31: Spektrální pásma družice Sentinel 2




Pásmo 1




Pásmo 2




Pásmo 3




Pásmo 4




Pásmo 5




Pásmo 6




Pásmo 7




Pásmo 8A




Pásmo 8B



Pásmo 9



Pásmo 10



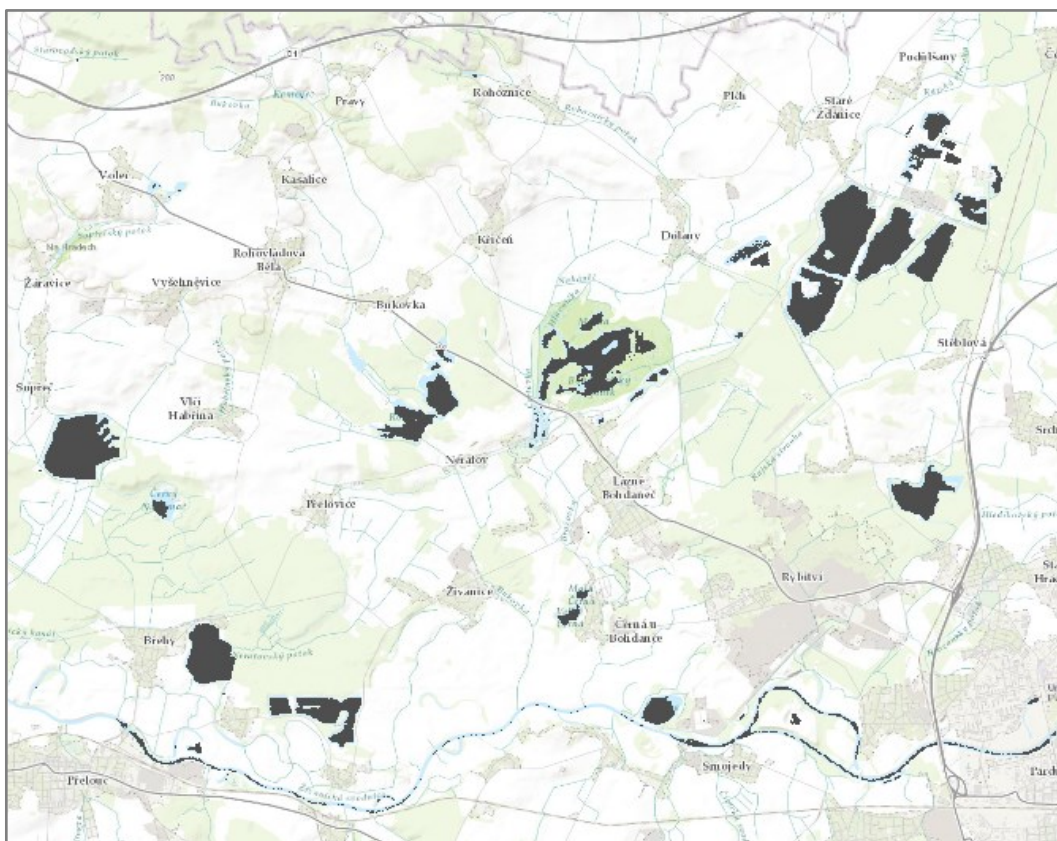
Pásmo 11



Pásmo 12


Zdroj: vlastní zpracování

Příloha C – výsledky klasifikace metodou Class Probability (4 třídy) z dat Sentinel 2



Obrázek 38: výsledek klasifikace metodou Class Probability (4 třídy) z dat Sentinel 2 na podkladové topografické mapě

Zdroj: vlastní zpracování



Obrázek 39: Výsledek klasifikace metodou Class Probability (4 třídy) z dat Sentinel 2 na podkladu pásma 8A

Zdroj: vlastní zpracování, data [29]