

Univerzita Pardubice  
Fakulta ekonomicko-správní

Využití snímků z bezpilotních prostředků pro detekci změn v okolí malých  
vodních ploch

Bc. Martin Krátký

Diplomová práce

2022

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

# ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Bc. Martin Krátký**  
Osobní číslo: **E19581**  
Studijní program: **N0688A140007 Informatika a systémové inženýrství**  
Specializace: **Informatika ve veřejné správě**  
Téma práce: **Využití snímků z bezpilotních prostředků pro detekci změn v okolí malých vodních ploch**  
Zadávající katedra: **Ústav systémového inženýrství a informatiky**

## Zásady pro vypracování

Cílem práce je využití dat z UAV pro monitoring dynamiky vybraného zájmového území. Student se bude zabývat procesem zpracování dat z UAV až po výslednou interpretaci.

Osnova:

- Dálkový průzkum Země.
  - Zpracování obrazu.
  - Bepilotní prostředky.
  - Změny v krajině.
  - Současný stav řešené problematiky.
  - Charakteristika zájmového území.
  - Vlastní zpracování.
  - Vizualizace a interpretace výsledků.
-

Rozsah pracovní zprávy: **cca 50 stran**  
Rozsah grafických prací:  
Forma zpracování diplomové práce: **tištěná/elektronická**

**Seznam doporučené literatury:**

KARAS, Jakub, 2017. 222 tipů a triků pro drony. Brno: Computer Press. ISBN 978-80-251-4874-7.  
LILLESAND, Thomas M., Ralph W. KIEFER a Jonathan W. CHIPMAN. Remote sensing and image interpretation. 6th ed. Hoboken: Wiley, c2008. ISBN 978-0-470-05245-7.  
LONGLEY, Paul. Geographic information systems & science. 3rd ed. Hoboken: John Wiley, c2011. ISBN 978-0-470-72144-5.  
SVATOŇOVÁ, Hana a Lubomír LAUERMANN, 2010. Dálkový průzkum Země – aktuální zdroj geografických informací. Brno: Masarykova univerzita. ISBN 978-80-210-5162-1.  
VALAVANIS, Kimon P. a George J. VACHTSEVANOS, ed. Handbook of Unmanned Aerial Vehicles [online]. Dordrecht: Springer Netherlands, 2015 [cit. 2020-07-10]. DOI: 10.1007/978-90-481-9707-1. ISBN 978-90-481-9706-4.

Vedoucí diplomové práce: **Mgr. Pavel Sedlák, Ph.D.**  
Ústav systémového inženýrství a informatiky

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

L.S.

---

**prof. Ing. Jan Stejskal, Ph.D.**  
děkan

---

**RNDr. Ing. Oldřich Horák, Ph.D.**  
vedoucí ústavu

V Pardubicích dne 1. září 2021

Prohlašuji:

Práci s názvem Využití snímků z bezpilotních prostředků pro detekci změn v okolí malých vodních ploch jsem vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

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

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 7/2019 Pravidla pro odevzdávání, zveřejňování a formální úpravu závěrečných prací, ve znění pozdějších dodatků, bude práce zveřejněna prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 30.04.2022

Bc. Martin Krátký v. r.

## **PODĚKOVÁNÍ**

Tímto bych rád poděkoval svému vedoucímu diplomové práce Mgr. Pavlu Sedlákovi, Ph.D. a Ing. Jakubu Jechovi za jejich odbornou pomoc, názory, připomínky, rady a poskytnuté materiály.

## **ANOTACE**

Tato práce je zaměřena na detekování změn v okolí malých vodních ploch pomocí RGB snímků z bezpilotních prostředků. V první části práce jsou popsány a vysvětleny pojmy dálkový průzkum Země, zpracování obrazu, bezpilotní prostředky, změny v krajině a je charakterizováno zájmové území. Obsahem druhé části této práce je příprava dat, jejich zpracování, vizualizace a interpretace.

## **KLÍČOVÁ SLOVA**

Dálkový průzkum Země, UAV, zpracování dat z UAV, neřízená klasifikace, řízená klasifikace

## **TITLE**

Use of images from unmanned aerial vehicles to detect changes around small water areas

## **ANNOTATION**

This work is focused on detecting changes around small water areas using RGB images from unmanned aerial vehicles. The first part of the thesis describes and explains the concepts of remote sensing, image processing, unmanned aerial vehicles, landscape changes and the area of interest. The content of the second part of this thesis is data preparation, their processing, visualization and interpretation.

## **KEYWORDS**

Remote sensing, UAV, UAV data processing, unsupervised classification, supervised classification

# OBSAH

<b>Seznam obrázků .....</b>	<b>9</b>
<b>Seznam tabulek .....</b>	<b>10</b>
<b>Seznam zkratk .....</b>	<b>11</b>
<b>Úvod .....</b>	<b>12</b>
<b>1 Dálkový průzkum Země .....</b>	<b>13</b>
<b>2 Zpracování obrazu .....</b>	<b>16</b>
2.1 Předzpracování obrazu .....	16
2.2 Zvýraznění obrazu .....	17
2.3 Klasifikace .....	20
2.3.1 Metody neřízené klasifikace .....	21
2.3.2 Metody řízené klasifikace .....	22
2.4 Postklasifikační úpravy .....	23
<b>3 Bezpilotní prostředky .....</b>	<b>24</b>
<b>4 Změny v krajině .....</b>	<b>26</b>
<b>5 Současný stav řešené problematiky .....</b>	<b>27</b>
<b>6 Software .....</b>	<b>31</b>
<b>7 Charakteristika zájmového území .....</b>	<b>32</b>
<b>8 Vlastní zpracování .....</b>	<b>33</b>
8.1 Příprava dat .....	34
8.1.1 Georeferencování .....	34
8.1.2 Ořez .....	35
8.2 Identifikace zájmového území .....	35
8.2.1 Zájmové území srpen 2018 .....	36
8.2.2 Zájmové území září 2018 .....	37
8.2.3 Zájmové území říjen 2018 .....	38
8.2.4 Zájmové území listopad 2018 .....	39
8.3 Digitalizace snímků .....	40
8.4 Klasifikace .....	42

8.5	Reklasifikace.....	44
8.6	Postklasifikační úpravy.....	45
8.7	Vizualizace klasifikace .....	46
8.7.1	Klasifikace srpen 2018.....	47
8.7.2	Klasifikace září 2018 .....	50
8.7.3	Klasifikace říjen 2018.....	53
8.7.4	Klasifikace listopad 2018.....	56
8.8	Porovnání ruční a automatické klasifikace .....	59
8.9	Interpretace výsledků.....	65
	<b>Závěr .....</b>	<b>67</b>
	<b>Použitá literatura .....</b>	<b>68</b>
	<b>Přílohy.....</b>	<b>73</b>



## SEZNAM OBRÁZKŮ

Obrázek 1: Elektromagnetické spektrum (Zdroj: Majer, 2019).....	14
Obrázek 2: Schéma pasivní a aktivní metody DPZ (Zdroj: OmniSci, Inc., © 2021) .....	15
Obrázek 3: Roztažení histogramu (Zdroj: Halounová, Pavelka, 2008, s. 146).....	18
Obrázek 4: Princip fungování majoritního filtru (Zdroj: vlastní) .....	23
Obrázek 5: Lokalita zájmového území (Zdroj: ČÚZK, 2022).....	32
Obrázek 6: Mozaika zájmového území ze srpna 2018 (Zdroj: vlastní) .....	33
Obrázek 7: Ukázka georeferencování (Zdroj: vlastní).....	34
Obrázek 8: Zájmové území srpen 2018 (Zdroj: vlastní) .....	36
Obrázek 9: Zájmové území září 2018 (Zdroj: vlastní).....	37
Obrázek 10: Zájmové území říjen 2018 (Zdroj: vlastní) .....	38
Obrázek 11: Zájmové území listopad 2018 (Zdroj: vlastní) .....	39
Obrázek 12: Ukázka digitalizace na snímku ze září 2018 (Zdroj: vlastní) .....	40
Obrázek 13: Rozloha digitalizovaných snímků (Zdroj: vlastní).....	41
Obrázek 14: ISO Cluster (ArcMap) tři třídy (Zdroj: vlastní).....	44
Obrázek 15: Porovnání klasifikace bez a s provedenými postklasifikačními úpravami (Zdroj: vlastní).....	46
Obrázek 16: Neřízená klasifikace srpen 2018 (Zdroj: vlastní) .....	47
Obrázek 17: Řízená klasifikace srpen 2018 (Zdroj: vlastní).....	48
Obrázek 18: Neřízená klasifikace září 2018 (Zdroj: vlastní).....	50
Obrázek 19: Řízená klasifikace září 2018 (Zdroj: vlastní) .....	51
Obrázek 20: Neřízená klasifikace říjen 2018 (Zdroj: vlastní).....	53
Obrázek 21: Řízená klasifikace říjen 2018 (Zdroj: vlastní).....	54
Obrázek 22: Neřízená klasifikace listopad 2018 (Zdroj: vlastní) .....	56
Obrázek 23: Řízená klasifikace listopad 2018 (Zdroj: vlastní).....	57
Obrázek 24: Nesprávně vygenerované AAP (Zdroj: vlastní) .....	60
Obrázek 25: Správně vygenerované AAP (Zdroj: vlastní) .....	61
Obrázek 26: Ověření výpočtu Kappa v IBM SPSS Statistics (Zdroj: vlastní).....	62

## SEZNAM TABULEK

Tabulka 1: Hodnoty NDVI (Zdroj: Halounová a Pavelka, 2008, s. 162) .....	20
Tabulka 2: Rozloha digitalizace (Zdroj: vlastní) .....	41
Tabulka 3: Síla Kappa koeficientu (Zdroj: Sim a Wright, 2005).....	62
Tabulka 4: Kappa koeficient pro neřízenou klasifikaci (Zdroj: vlastní) .....	63
Tabulka 5: Kappa koeficient pro řízenou klasifikaci (Zdroj: vlastní).....	63
Tabulka 6: Chybová matice – srpen (Zdroj: vlastní) .....	63
Tabulka 7: Chybová matice – září (Zdroj: vlastní) .....	64
Tabulka 8: Chybová matice – říjen (Zdroj: vlastní).....	64
Tabulka 9: Chybová matice – listopad (Zdroj: vlastní) .....	64
Tabulka 10: Rozloha ruční a automatické klasifikace (Zdroj: vlastní) .....	66

## SEZNAM ZKRATEK

AAP	Accuracy Assessment Points
CNN	Convolutional Neural Network
DN	Digital Number
DPZ	Dálkový průzkum Země
ENDVI	Enhance Normalized Difference Vegetation Index
ESRI	Environmental Systems Research Institute, Inc.
FPV	First-Person View
GNDVI	Green Normalized Difference Vegetation Index
LAI	Leaf Area Index
MT	Martin – Taylor
NDREI	Normalized Difference RedEdge Index
NDVI	Normalized Difference Vegetation Index
NGRDI	Normalized Green-Red Difference Index
NIR	Near-Infrared
OBIA	Object-Based Image Analysis
RF	Random Forest
RGB	Red, Green, Blue
RGRI	Red-Green Ratio Index
SI	Spektrální Index
SVM	Support Vector Machine
UAV	Unmanned Aerial Vehicle
VARI	Visible Atmosphericdally Resistand Index
VDVI	Visible-band Difference Vegetation Index

# ÚVOD

Dálkový průzkum Země je jednou z nejrozšířenějších metod pořizování prostorových dat o zemském povrchu, se kterou jsou spojeny následné operace analýzy a zpracování v různých softwarových prostředích. Takto získané informace nachází využití v mnoha oborech lidské činnosti, mezi které je možné zahrnout mapování, zemědělství, pozorování změny krajinného pokryvu nebo využití půdy. Nejčastěji se tato data získávala pomocí leteckého či družicového snímkování, ale v důsledku technologického pokroku se do popředí dostávají častěji bezpilotní prostředky neboli UAV. Především se jedná o rozmach multirotorových systémů, které jsou většinou veřejnosti známé pod označením dron.

Dříve byly bezpilotní prostředky používány především ve vojenství, kde našly využití v průzkumu terénu a hledání pozemních cílů nebo k jejich eliminaci. V současné době se čím dál více tyto bezpilotní prostředky vyskytují i v oblastech našeho všedního života. Ať už se jedná o specializované drony v zemědělství využívané k sazbě plodin, drony navržené k hašení požárů nebo komerční drony využívané k zábavě a rekreaci.

Výhoda využití UAV pro dálkový průzkum Země je jejich kompaktní velikost a cenová dostupnost. V rámci použití UAV je možné zkoumat izolované oblasti, kam se není schopen člověk dostat. Navíc disponují velkým prostorovým rozlišením a současně jsou snadno ovladatelnými.


Cílem této práce je detekování změn v okolí malých vodních ploch pomocí RGB snímků z bezpilotních prostředků. V první části práce jsou objasněny a vysvětleny pojmy dálkový průzkum Země, zpracování obrazu, bezpilotní prostředky, změny v krajině. Dále se práce zaměřuje na současný stav řešené problematiky a charakteristiku zájmového území. Druhá část této diplomové práce je věnována přípravě, zpracování, vizualizaci a interpretaci nasnímaných dat.

# 1 DÁLKOVÝ PRŮZKUM ZEMĚ

Dálkový průzkum Země (DPZ) se zabývá složitou problematikou od vzniku obrazových záznamů (snímků) až po jejich interpretaci. Svatoňová a Lauermann (2010, s. 7) DPZ definují jako: „zkoumání, měření a zobrazování objektů a jevů v krajinné sféře bez přímého fyzického kontaktu s nimi“. K tomuto zajištění zpravidla slouží letecké a družicové snímkování, ke kterému se v dnešní době přidává snímkování pomocí menších a levnějších bezpilotních prostředků (UAV – Unmanned Aerial Vehicle) (EnviroMINE, Inc., c 2012–2016), mezi které se řadí například balóny, vzducholoď, vrtulníky, multikoptéry a další.

Dle Horáka (2014, s. 1–2) je DPZ rychle se rozvíjející obor, který využívá technologického pokroku v pořizování dat i v metodách zpracování digitálních dat. V rámci tohoto oboru jsou získávány informace o objektech a jevech na dálku, a to bez přímého kontaktu. Jedná se tedy o neinvazivní techniku zkoumání, jelikož jsou tyto objekty a jevy na zemském povrchu. K přenášení informací se využívá elektromagnetické záření. Tyto objekty a jevy vyzařují elektromagnetické záření nebo mění jeho vlastnosti a prozrazují tak svoji přítomnost a vlastnosti. Pro pozorování objektů a jevů jsou záznamová zařízení elektromagnetického záření umístěna na nosičích, kterými jsou zpravidla letadla nebo družice.


Lillesand, Kiefer a Chipman (2008, s. 1–2) definují DPZ jako průnik vědy a umění, jak získat informace o objektech, oblastech a jevech prostřednictvím analýz dat získaných pomocí zařízení, které není v kontaktu s oblastí nebo zkoumaným jevem. K tomuto účelu slouží různé sensory, které sbírají data o výše uvedeném. Autoři uvádí, že data sesbíraná DPZ mohou mít mnoho forem, mezi které uvádí například akustické vlnění, s nimiž související sonary. Jednou z možností jejich využití je průzkum vodních ploch. V rámci této metody se pomocí sonaru vysílají krátké zvukové impulsy o vysoké frekvenci. U těchto impulsů se zaznamenává doba odrazu, jeho síla a frekvenční charakteristika, s jejichž pomocí se sestavují topografické, geologické mapy a profily sedimentů. Dalším uváděným zářením dle Lillesanda, Kiefera a Chipmana (2008, s. 1–2) je záření elektromagnetické. Část tohoto záření jsme schopni vidět vlastníma očima. Jedná se o viditelné spektrum, což je úzká část elektromagnetického spektra, které lze rozdělit na dílčí intervaly dle Svatoňové a Lauermann (2010, s. 8–11) na modré světlo (0,4–0,5  $\mu\text{m}$ ), zelené světlo (0,5–0,6  $\mu\text{m}$ ) a červené světlo (0,6–0,7  $\mu\text{m}$ ). Ostatní vlnové délky jsou pro člověka bez speciálních pomůcek k tomu určených pro lidské oko necitlivé a tím i neviditelné. Toto spektrum se někdy nazývá Maxwellovou duhou.



Obrázek 1: Elektromagnetické spektrum (Zdroj: Majer, 2019)

Celý rozsah elektromagnetického spektra, které se dělí do oblastí podle vlnové délky nebo frekvence, je zobrazen na obrázku 1. Frekvence značí počet kmitů elektromagnetické vlny za jednu sekundu. Vlnová délka představuje vzdálenost mezi amplitudami vlny. Skládá se z gama záření, rentgenového záření, ultrafialového záření, viditelného záření, infračerveného záření, mikrovlnného záření a radiového záření. Přechody mezi zářeními jsou zcela plynulé a některé se překrývají.

Svatoňová a Lauermann (2010, s. 14–20) uvádí dělení DPZ dle zdroje elektromagnetického záření na metody aktivní a pasivní. V rámci aktivní metody je toto záření emitováno ze zdroje umístěného na nosiči a je zpětně zachyceno tímto zařízením. Příkladem uvádí radar. Pasivní metody se dále dělí na přímé, které využívají odražené sluneční záření, a metody nepřímé využívající vlastní spektrální vyzařování objektu. Příkladem pasivní nepřímé metody je termokamera. Schéma těchto metod je zobrazeno na obrázku 2.



Obrázek 2: Schéma pasivní a aktivní metody DPZ (Zdroj: OmniSci, Inc., © 2021)

Metody DPZ se dělí podle pořízení dat na konvenční a nekonvenční. Konvenční metody DPZ zahrnují pořizování snímků klasickými fotografickými metodami, tyto snímky jsou pořizovány centrální projekcí. Jedná se o černobílé nebo barevné snímky v závislosti na vrstvách filmu. Jednovrstvé filmy slouží k černobílému (monochromatickému) snímkování. K pořízení barevných fotografií je třeba film s více vrstvami nejčastěji citlivými na modrou, zelenou a červenou barvu. V tomto případě je výsledkem fotografie v přirozených barvách (panchromatické snímkování). Vrstvy filmu mohou být citlivé na infračervené záření a jedná se tedy o výslednou fotografii v nepřirozených barvách. Nekonvenční metody se od metod konvenčních liší technikou vytváření obrazu. Snímky vznikají tzv. řádkováním. Zemský povrch je postupně snímán v řádcích pomocí skenerů nebo radiometrů. Průsečíkem řádku a sloupce je rastrová buňka, jejíž velikost je dána rozlišením snímkovacího zařízení a jejímž souřadnicím odpovídá zaznamenané záření pomocí čísla (DN – digital number), které odpovídá tónu šedi nebo barvy. Výsledkem jsou snímky v digitální podobě, které se od fotografií liší zkreslením a prostorovým detailem. Předností nekonvenčních metod je pořízení dat v široké části elektromagnetického spektra. (Lillesand, Kiefer a Chipman, 2008, s. 61–122)

## 2 ZPRACOVÁNÍ OBRAZU

Data v obrazové podobě, tedy obrazová data, mohou být v rámci DPZ pořízena bezkontaktními metodami formou fotografií. Jedná se buď o analogová data, nebo o snímky ze skenerů a radarů v digitální podobě, tudíž o data digitální. Analogová data lze převést na digitální a digitální je možné převést na analogová. Digitální obraz je obrazová informace převedena do číslicové formy a je potřeba počítat s určitým stupněm generalizace. Je tedy nutné pracovat s geometrickou rozlišovací schopností o určité velikosti, která už je dále nedělitelná. Digitální obraz se skládá z na sebe navazujících pixelů, které nabývají DN. Za počátek praktického využívání digitálního zpracování obrazu se považuje první polovina 70. let dvacátého století (Dobrovolný, 1998). V této době dochází k rozvoji výpočetní techniky (vstup osobních počítačů – PC – na trh) a k dostupnosti digitálních dat poskytovaných družicemi. (Kolář, Halounová a Pavelka, 1997, s. 83–88)

Kolář, Halounová a Pavelka (1997, s. 89–90) rozdělili digitální zpracování obrazu do čtyř hlavních operací. A to na předzpracování obrazu, zvýraznění obrazu, klasifikaci a postklasifikační úpravy.

### 2.1 Předzpracování obrazu

Ve fázi předzpracování obrazu dochází k odstraňování chyb vznikajících při pořízení fotografických snímků anebo při vytváření skenovaných obrazových záznamů. Lillesand, Kiefer a Chipman (2008, s. 482–545) uvádí, že obrazové zkreslení a obrazová degenerace pochází z procesu získávání obrazových dat. Záleží tedy, zda se jedná o pořízení snímku za pomoci digitálních kamer či skenerů, nebo o data pořízená ze satelitů, letadel či UAV. Jedná se o chyby předvídatelné nebo náhodné. Chyby jsou způsobeny rotací nebo zakřivením Země, změnou výšky či změnou polohy nosiče snímkovacího zařízení. V rámci předzpracování obrazu dochází k úpravám geometrického zkreslení, radiometrické korekce a odstranění šumů.

Geometrická korekce neboli rektifikace obrazu opravuje chyby vzniklé v okamžiku měření, které vychází z letu nosiče snímkovacího zařízení. Tato data obsahují zkreslení dané změnou rychlosti, polohy nebo výšky nosiče. Provádí se georeferencováním za pomoci lícovacích bodů, což jsou body, které je možné přesně lokalizovat na snímku a jsou známy jejich mapové souřadnice. Radiometrickou korekcí se odstraňují nesprávnosti hodnot DN, které způsobují roční období, měnící se výška slunce, stav atmosféry nebo poloha nosiče. Cílem

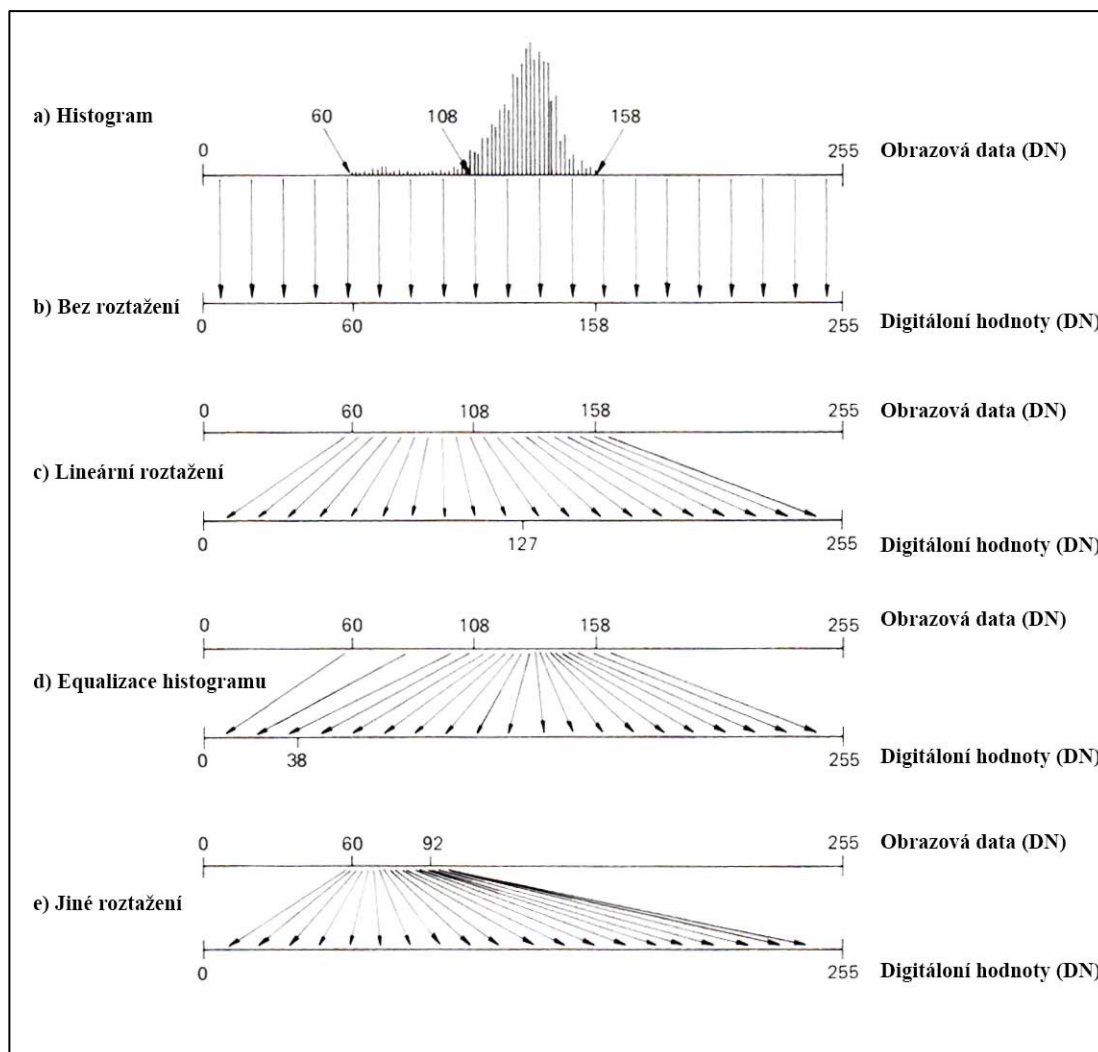


korekce je zajistit, aby hodnoty DN obrazového záznamu odpovídaly skutečným odrazivým nebo zářivým vlastnostem objektů. (Longley et al., 2011, s. 123–135)

## 2.2 Zvýraznění obrazu

Účelem zvýraznění obrazu je provedení úprav na snímku s cílem navýšit množství požadované informace, kterou chceme ze snímku získat, a současně potlačit nežádoucí informace tak, aby se zvýšila úspěšnost klasifikace obrazu. Digitální zvýraznění obrazu se rozlišuje na radiometrické, prostorové a spektrální zvýraznění. Radiometrické pracuje se zvýrazněním hodnoty buněk bez ohledu na okolí. Prostorové zvýrazňuje hodnoty buněk podle hodnot okolních buněk. Tyto dvě uvedená zvýraznění obrazu operují s buňkami. Spektrální zvýraznění se zabývá spektrálními pásmy, pracuje tedy v několika intervalech vlnové délky. Skládáním různých pásem je možné vytvářet barevný obraz, tento proces se nazývá barevnou syntézou. Transformováním původních pásem na pásma nová je možné získávat nové informace. Pásma představují hodnoty odraženého nebo vyzářeného elektromagnetického záření zachyceného na ploše buňky. (Lillesand, Kiefer a Chipman 2008, s 499–545)

Jednou z metod radiometrického zvýraznění je práhování. V rámci této metody se rozdělí hodnoty DN podle toho, zda jsou vyšší či nižší než stanovená hodnota. Těmto hodnotám je přiřazeno číslo 0 a 1 a vzniká tzv. bitový obraz. Metoda se využívá pro konstrukci masek, které se následně dají využít pro klasifikaci obrazu po částech. Rozšířenou metodou práhování jsou hustotní řezy (vícenásobné práhování), kde se na rozdíl od práhování volí více prahových hodnot a obraz je rozdělen do několika tříd. Hustotní řezy je možné použít ke zjednodušení obrazu při pozorování spojitých jevů, jako je teplota či nadmořská výška. Další metodou radiometrického zvýraznění obrazu je roztažení histogramu. Metoda se zabývá úpravou kontrastu, kdy histogram nevyužívá celé stupnice šedi, ale hodnoty DN jsou pouze v určitém rozpětí. Jednou z možných technik je lineární roztažení histogramu, při kterém se roztáhne původní rozsah DN dle přepočtu na maximální možný rozsah. Nelineární technikou je roztažení vyrovnáním histogramu neboli equalizace, kdy se málo četné hodnoty DN seskupí a četné hodnoty DN se vzdalují, čímž se ve výsledném obraze od sebe lépe odliší. V rámci roztažení histogramu je možné použít jen část původních hodnot DN, které lze lineárně roztáhnout na celý rozsah. Hodnoty mimo použitou část jsou nepoužity a odstraněny. Tato technika se využívá při analyzování určitého povrchu ze snímku. (Lillesand, Kiefer a Chipman 2008, s. 499–509; Halounová a Pavelka, 2008, s. 144–147)



Obrázek 3: Roztažení histogramu (Zdroj: Halounová, Pavelka, 2008, s. 146)

Mezi metody prostorového zvýraznění se řadí filtrace obrazu. Dle Halounové a Pavelky (2008, s. 148–158) k filtraci digitálního obrazu dochází z různých důvodů, mezi něž patří potlačení šumu, zmírnění rozostření obrazu nebo zvýšení kontrastu mezi objekty. Metoda pracuje na principu filtrovacího okna, což je čtvercová matice s vahami zapsanými v jejích buňkách. Okno se posouvá po obraze a propočítává DN hodnoty obrazu s vahami z filtrovacího okna. Výsledky jsou zapisovány do centrální buňky výsledného obrazu. Filtry lze dělit na nízkofrekvenční a vysokofrekvenční. Nízkofrekvenční filtry jsou filtry s nízkou propustností. Tyto filtry průměrují a vyhlazují obraz s důrazem na nízké frekvence. Vysokofrekvenční filtry zostrují obraz a zdůrazňují vysoké frekvence. (Lillesand, Kiefer a Chipman 2008, s. 509–523)

Poslední skupinou technik zvýraznění obrazu dle Halounové a Pavelky (2008, s. 158–162) je spektrální zvýraznění, které zahrnuje transformaci digitálních obrazových dat do lépe interpretované formy. Obrazová data pořízena metodami DPZ jsou většinou pořizována

v několika intervalech vlnové délky, jedná se tedy o multispektrální data. Skládáním více pásem se vytváří barevný obraz. Tento proces se nazývá barevnou syntézou. Pokud se výsledný obraz skládá ze tří pásem ve viditelné části spektra, tedy z červeného, zeleného a modrého pásma, jedná se o barevnou syntézu ve skutečných (pravých) barvách. Pokud se používá jiná kombinace než RGB, tedy pokud je alespoň jedno pásmo nahrazeno jiným, například pásmem infračerveným, hovoří se o barevné syntéze v nepravých barvách (Svatoňová a Lauermann, 2010, s. 40–42). K předzpracování dat před automatickou klasifikací kvůli velké korelaci mezi pásmy slouží analýza hlavních komponent. Jejím cílem je přepočítat původní pásma do nových obrazových pásem s cílem maximalizovat rozptyl a zároveň minimalizovat jejich počet. Touto metodou je možné snížit objem dat, se kterými se pracuje, a shrnout už známé informace z původních pásem do nových, které je možné využít pro syntézu. Analýzou obecných komponent je možné přepočítat původní pásma do pásem nových s cílem dosáhnout separace, aby byly jednotlivé shluky od sebe vzdáleny co nejvíce a jejich vnitřní rozsah byl co nejmenší. Tato metoda je vhodná, když jsou známé informace o určitých třídách. Další možnou technikou je transformace Martin – Taylor (MT), při které se transformuje trojrozměrný souřadnicový systém do barevného prostoru, který je přívětivý pro lidský zrak. Osami MT jsou jas, červeno-zelená barva a modro-žlutá barva. Pořadí odpovídá takové citlivosti, aby lépe odpovídalo preferenci barevného spektra lidského oka. Takto vzniklá nová pásma nesou nové informace a mohou sloužit jako vstup ke klasifikaci.

Technikou zvýraznění obrazu je použití spektrálních indexů (SI). Spektrální indexy pracují se dvěma nebo více spektrálními pásmy a vyjadřují změny mezi odrazivostí. Jejich cílem je zvýraznění chování objektu, kterým může být například vegetační složka. Spektrálních indexů existuje mnoho a řadí se mezi ně i vegetační indexy, které zkoumají vegetační složku krajiny. Různé indexy mohou rozlišovat druhy, zdravotní stav a množství vegetace nebo výnosnost zemědělských plodin. Jedním z nejrozšířenějších vegetačních indexů je normalizovaný diferenční vegetační index (Normalized Difference Vegetation Index – NDVI), který využívá vlastností dvou pásem, NIR a RED, které značí odrazivost v blízkém infračerveném spektrálním pásmu, respektive odrazivost v červeném spektrálním pásmu. Index je vyjádřen jako podíl rozdílů mezi těmito pásmy (Weier, Herring, 2000).

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Zdroj: (Index, © 2011-2022)

Výsledná hodnota indexu NDVI se pohybuje v intervalu od -1 do +1, kde nula představuje hodnoty oblačnosti a mírně nad nulou oblasti holé půdy. Záporných hodnot dosahují prvky vody, sněhu a ledu. Nízké hodnoty NDVI mají oblasti neúrodné půdy, tedy půdy s nízkou vegetací a vysoká hodnota NDVI znamená oblast s hustým pokryvem zelené vegetace. Přehled hodnot NDVI je zobrazen v tabulce 1 níže. (Lillesand, Kiefer a Chipman, 2008, s. 523–545; Halounová a Pavelka, 2008, s. 162–164)

Tabulka 1: Hodnoty NDVI (Zdroj: Halounová a Pavelka, 2008, s. 162)

Typ povrchu	NDVI
Velmi hustá vegetace	0,5
Středně hustá vegetace	0,14
Řídká vegetace	0,09
Holá půda	0,025
Oblačnost	0,002
Sníh a led	-0,046
Voda	-0,257

## 2.3 Klasifikace

Svatoňová a Lauermann (2010, s. 43–44) uvádí, že v rámci procesu klasifikace jsou nahrazeny naměřené radiometrické hodnoty hodnotami informačními. Typ a obsah informačních hodnot se odvíjí od podstaty problematiky, na které proces klasifikace probíhá. Klasifikace je založena na použití klasifikátorů, podle kterých jsou odlišné objekty a jevy v obraze zařazeny do určitých tříd. Liu a Mason (2009, s. 91–103) chápou klasifikaci jako počítačovou vědu, která se zabývá rozpoznáváním vzorů, a to podle statistických vlastností v případě shlukování nebo segmentace založené na prostorových a statistických vztazích mezi obrazovými body. Uvádí, že klasifikace se dělí na dva hlavní směry, a to na klasifikaci neřízenou a klasifikaci řízenou. V některých publikacích jsou tyto dva klasifikační směry označovány jako učení bez učitele a učení s učitelem.

Richards (2013, s. 326–341) definuje neřízenou klasifikaci jako identifikaci přirozených skupin nebo struktur pomocí shlukování, kdy je každá buňka zařazena do shluku a je označena

stejným symbolem či barvou. Jedná se o metodu, která je založena na datech a je automaticky optimalizována dle shlukovací statistiky. Campbell a Wynne (2011, s. 339–349) uvádí jako přednosti neřízené klasifikace minimální možnost lidské chyby, jelikož lidský faktor rozhoduje pouze o množství klasifikačních tříd. Dále uvádí, že u této metody nejsou potřebné znalosti o zájmovém území. Tyto znalosti jsou potřebné pouze k interpretaci výsledků procesu neřízené klasifikace. Nevýhody metody vychází z procesu seskupování a přiřazování shluků k informačním kategoriím, které jsou zajímavé k analyzování. Sem dle autorů spadá například vygenerování specifického shluku.

Dle Richardse (2013, s. 247–325) je řízená klasifikace nejčastěji používaná technika pro kvantitativní analyzování obrazových dat dálkového průzkumu Země. Campbell a Wynne (2011, s. 349–371) uvádí, že se jedná o proces, v rámci kterého se klasifikují buňky na základě předem identifikovaných vzorků. Jedná se o buňky umístěné v trénovacích oblastech na snímku, také označovány jako trénovací množiny. Oblasti by měly být homogenní v návaznosti na informační kategorii. V rámci procesu řízené klasifikace je možné odhalit chyby v klasifikaci při prozkoumávání trénovacích dat. Nepřesná klasifikace trénovacích dat představuje problémy v klasifikaci nebo ve výběru trénovacích ploch. Ale správná klasifikace trénovacích dat nemusí znamenat správnou klasifikaci dat ostatních. Dle Liua a Masona (2009, s. 91–103) je řízená klasifikace postavena na znalostech a zkušenostech uživatele, který tuto metodu provádí, a na jeho znalostech zájmového území. Výsledek klasifikace může být zkreslený subjektivním pohledem uživatele nebo zavádějící z důsledku neúplných znalostí či neznalosti dané oblasti.

### **2.3.1 Metody neřízené klasifikace**

Dle Richardse (2013, s. 322–323) je metoda „K-mean“ jedním z nejběžnějších a nejjednodušších přístupů používaných v softwarových prostředích k analýze obrazu. Metoda je založena na zadání počtu požadovaných shluků. Každý klasifikovaný pixel je v rámci této metody přiřazován do shluků dle vektoru vzdálenosti k nejbližšímu centru shluku. Následně jsou tyto centroidy přepočteny a celý proces přiřazování se opakuje až do doby dosažení určitého počtu iterací či do doby, kdy už nedochází k výraznější změně v zařazování jednotlivých pixelů do shluků. (Tso a Mather, 2009, s. 54–56)

Klasifikační metoda „ISODATA“ vychází z metody „K-mean“ a rozšiřuje ji. Abbas s kolegy (2016) uvádí, že i v tomto případě je nutné definovat počet klasifikačních tříd a počet iterací algoritmu. V rámci této metody jsou pixely zařazeny do shluků, které jsou dle jejich

směrodatné odchylky děleny. Shluky, které jsou si svými středy blízké, jsou spojovány a třídy, které obsahují malé množství pixelů, jsou rušeny. Jejich obsažené pixely jsou překlasifikovány do nejbližších shluků. (Richards, 2013, s. 323–331)

### 2.3.2 Metody řízené klasifikace

Klasifikace maximální pravděpodobnosti neboli „Maximum Likelihood Classification“ je dle Richardse (2013, s. 250–260) jednou z nejběžnějších metod řízené klasifikace dat z dálkového průzkumu Země. Tato metoda je založena na Bayesovské pravděpodobnosti. Základem je statistické rozpoznávání vzorů, při kterém je spočítána pravděpodobnost zařazení pixelu do předdefinovaných tříd. Následně jsou dané pixely na základě vypočtené pravděpodobnosti přiřazeny k daným klasifikačním třídám dle nejvyšší pravděpodobnosti. (Tso a Mather, 2009, s. 58–61)

Klasifikátor minimální vzdálenosti („Minimum Distance Classification“) je rychlejší na výpočet než klasifikátor maximální pravděpodobnosti. Metoda je postavena na vytvoření shluků, kde je každý shluk definován jako odlišná třída, a obrazové body (pixely) jsou přiřazovány ke každé třídě na základě nejkratší vektorové vzdálenosti. (Richards, 2013, s. 265–268)

Mahalanobisova klasifikace vzdálenosti („Mahalanobis Distance Classification“) je směrový klasifikátor vzdálenosti, který je založen na statistikách pro každou klasifikační třídu. Jedná se o metodu podobnou klasifikátoru maximální pravděpodobnosti, ale na rozdíl od této klasifikace předpokládá, že třídní kovariance jsou stejné. (Richards, 2013, s. 271, Campbell a Wynne, 2011, s. 437–441)


Klasifikace spektrálních úhlů („Spectral Angle Mapping“) je založena na práci se spektry jako s vektory a vypočítává spektrální úhel mezi nimi. Metoda není citlivá na osvětlení, protože využívá pouze směr vektorů, a ne jejich délku. Klasifikace spektrálních úhlů má především využití při porovnávání obrazových spekter se spektry naměřenými v laboratořích či spektrometry v terénu. (Liu a Mason, 2009, s. 96–97)

Klasifikátor SVM („Support Vector Machine“) je metoda založená na učení s učitelem, která třídí data do dvou skupin oddělených hyperrovinou. Cílem algoritmu je nalézt takovou hyperrovinu, která bude mít maximální vzdálenosti mezi danými třídami. Předností řízené klasifikace SVM je, že je méně náchylná na šумы a nevyváženost velikostí trénovacích množin. (Tso a Mather, 2009, s. 125–154)

## 2.4 Postklasifikační úpravy

Data po klasifikaci mohou mít podobu typu „pepř a sůl“, kdy se v rámci klasifikované oblasti vyskytují jiné třídy. Tento výsledek klasifikace nemusí být vhodný k interpretaci dat, kdy se v homogenní oblasti, například vodní hladině, vyskytují prvky jiné, například lodě. Tyto prvky jsou někdy označovány jako odlehlé hodnoty nebo jedinečné extrémy. K postklasifikačním úpravám se využívají postklasifikační filtry založené na logických operátorech, které postupují přes klasifikovaná data a na základě určené majoritní třídy mění hodnoty buněk z nemajoritních na majoritní. (Halounová a Pavelka, 2008, s. 181–182)

Příkladem postklasifikačního filtru je filtr majoritní, který je založen na vztahu sousedství. V rámci principu je stanovena filtrovací mřížka, v níž je měněna hodnota centrální buňky v závislosti na majoritní shodě buněk sousedních. (Liu a Mason, 2009, s. 43) Tento princip je zobrazen na obrázku 4, kdy je měněna centrální buňka mřížky o rozměru 3 x 3 na základě majoritní většiny. V okolí centrální buňky s hodnou 3 se nachází pět buněk z osmi s uvedenou hodnotou 1. Na základě tohoto rozložení je majoritním filtrem změněna hodnota centrální buňky 3 na hodnotu 1.



Obrázek 4: Princip fungování majoritního filtru (Zdroj: vlastní)

### 3 BEZPILOTNÍ PROSTŘEDKY

UAV (Unmanned Aerial Vehicle) značí bezpilotní letecký prostředek v povědomí veřejnosti známý pod pojmem dron vycházející z anglického drone. Jedná se o letoun, který umožňuje let bez posádky na palubě (Valavanis, Vachtsevanos, 2014, s. 11–13). UAV mohou být řízeny na dálku v dohledu pilota nebo i mimo jeho dohled. Nebo mohou létat samostatně pomocí předem naprogramovaných letových plánů či autonomních systémů, v závislosti na dané legislativě. (Karas, 2017, s. 15, 25)

Drony je možné dělit dle mnoha hledisek. Miříjovský (2013, s. 19–20) uvádí jako možné dělení na motorový či nemotorový model. V rámci motorových modelů rozlišuje motory spalovací, kam spadají rogalá. Mezi modely poháněné elektromotorem jsou řazeny multikoptéry. Vrtulníky, vzducholodě a letadla s fixními křídly mohou být zařazeny do obou zmíněných skupin, záleží na typu motoru. Nemotorové systémy je možné dělit na platformy udržované ve vzduchu různými směsmi, kam spadají balóny, či platformy závislé na povětrnostních podmínkách. I do této skupiny je možné zařadit vzducholodě či například draky.

Za počátek UAV je možné považovat vypuštění horkovzdušného balónu bratry Montgolfierovými ve Francii roku 1783. O první použití dronů se v 19. století, přesněji v roce 1849, snažila rakouská armáda. K útoku na Benátky použila balóny s výbušninami (Wapons and Warfare, 2021). V témže století vznikla i první fotografie z UAV. Postaral se o ni ve Francii v roce 1858 Gaspard-Félix Tournachon. Fotografii pořídil z horkovzdušného balónu ve výšce zhruba 80 m. Vývoj UAV je pevně spjat s rozvojem letectví, technologií a vojenstvím, kde našlo přední využití, ať už k průzkumu terénu nebo k bombardování vojenských cílů. Zájem o jejich vývoj vzrostl během první světové války (Dronethusiast, © 2014–2021). Jedním z nejznámějších použití vojenských dronů je nasazení UAV Predator ve válce v Iráku. Gettinger (2019) se zabývá vojenskými UAV. Ve své publikaci mapuje vojenské drony 95 zemí světa. (Daly, © 2012–2021)

V současné době se drony používají v mnoha odvětvích. Slouží k monitorování území, hledání osob. Nachází uplatnění v archeologii, stavebnictví, ve filmovém průmyslu a v zemědělství. Sylvester (2018, s. 57–72) uvádí, že UAV má v zemědělství využití v oblastech plánování výsadby a v analyzování stavu živin. Možným využitím je monitorování plodin v rámci chytrého zemědělství, kdy je například možné pomocí časových řad odhalit neefektivitu produkce. Nebo je možné pomocí multispektrálních senzorů pozorovat odrazivost



rostlin, a tím zjišťovat jejich zdravotní stav. Upravené drony mohou sloužit k setí plodin nebo k jejich zavlažování. Karas (2017, s. 148–149) uvádí příklad komerčního využití dronů, a to k závodění. Tzv. FPV (First-Person View) Racing, kde se jedná o kvadrokoptéry osazené kamerou, které jsou ovládány pilotem skrze FPV brýle, které přenáší video z dronu v reálném čase.

## 4 ZMĚNY V KRAJINĚ

Lipský (2010) uvádí, že se krajina vyvíjela vlivem přírodních činitelů od nepaměti. Přírodní faktory zpravidla působí na krajinu v dlouhých časových intervalech, ale v rámci přírodních katastrof se může krajina změnit během okamžiku. Kdežto zásah člověka působí na krajinu razantně a v krátkém časovém úseku. Člověk mění ráz krajiny svojí činností, to je výstavbou, povrchovou těžbou, zemědělstvím nebo kácením lesů. Evropská úmluva o krajině (2010) definuje krajinu jako: „*část území, tak jak je vnímána lidmi, jejíž charakter je výsledkem činnosti a vzájemného působení přírodních nebo lidských faktorů.*“ Zákon o ochraně přírody a krajiny vydaný Ministerstvem životního prostředí (Zákon č. 114/1992 Sb.) definuje krajinu jako: „*část zemského povrchu s charakteristickým reliéfem, tvořená souborem funkčně propojených ekosystémů a civilizačními prvky.*“ Krajina je tedy systém, na který působí přírodní faktory a zásahy člověka.

Sledování změn v krajině je založeno na pozorování krajinných složek, jejich zastoupení, u kterého se pozoruje rozšiřování, zmenšování či ústup. Krajinné změny je možné sledovat metodami dálkového průzkumu Země za pomoci satelitního, leteckého nebo UAV snímání, které pomocí časových řad zobrazuje krajinné změny. Je možné zkoumat změny ve využívání ploch (Land Use) nebo změny ve využívání půdy a změny krajinného pokryvu (Land Cover). Lze pozorovat změny typů krajiny, krajinného rázu, biodiverzity krajiny, ekologickou stabilitu a její strukturu. Změny ve struktuře krajiny, jako je výrazné rozšiřování polí, rozorávání travních porostů nebo výstavba komunikací, mají dopad na pohyb organismů v krajině, ale ovlivňují i vodní režim krajiny a její erozi. (Lipský, 2010)

## 5 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

Články zmíněné níže se zabývají využitím a zpracováním dat z UAV různými metodami, tedy podobnou tematikou jako je zaměření této diplomové práce.

Hsuan, Hao, Kuo (2018) se zabývali použitím dat z UAV ke sledování poškozených polí rýže na Taiwanu. Ve sledovaném období byla daná oblast zasažena silnými větry a deštěm, které vedly k poškození plodin. V rámci výzkumu stanovili 34 kontrolních bodů a provedli 306 snímků zájmového území o rozloze 258 ha. Za pomoci softwaru Pix4Dmapper provedli geometrickou korekci a ortorektifikaci nad snímky k vytvoření mozaiky v RGB barvách a NIR. Zvýraznění obrazu proběhlo pomocí výpočtu indexu NDVI a analýzou hlavních komponent v prostředí ERDAS IMAGINE. Dané mozaiky byly proloženy s mapovým podkladem. Výsledkem jejich práce bylo porovnání softwarových výstupů s fyzickou kontrolou poškozené oblasti. Autoři uvádí shodu ve výstupech přesahující 90 % a domnívají se, že takto získaná a zpracovaná data dokáží poskytnout časově efektivnější kontrolu po následcích přírodních katastrof. Práce je zde uvedena, jelikož se zabývá problematikou zpracování RGB snímku z UAV.

Oddi s kolegy (2021) se zabývali klasifikací travních porostů pastvin pomocí RGB snímků pořízených z UAV v západoitalských Alpách. Snímky byly pořízeny v polovině října roku 2012 a 2018, kdy se autoři domnívali, že toto období je nejlepší k dosažení dobrých výsledků klasifikace, jelikož vegetace stárla a jevíly se největší rozdíly mezi druhy porostů. Snímky pořídili za pomoci UAV DJI Phantom 4 s kompaktní kamerou FC6310 a s překrytím snímků mezi 70 a 75 %. Ke zpracování snímků byl použit software PhotoScan Agisoft, jehož výstupem byly tři RGB ortomozaiky v prostorovém rozlišení 1 cm, 5 cm a 20 cm. Klasifikační problém byl řešen dvěma metodami. Jednalo se o vizuální photointerpretaci za pomoci experta na studovanou oblast v prostředí QGIS 3.10.1, který klasifikoval čtyři třídy, a to třídu modřínů, nahnědlých keřů, zelených keřů a travních porostů. Takto byla klasifikace provedena na mozaikách s největším a nejmenším prostorovým rozlišením. Druhou metodou byla poloautomatická klasifikace v prostředí QGIS 3.10.1 na všech třech mozaikách. Ve výsledku autoři uvádějí, že manuální klasifikace na mozaikách s prostorovým rozlišením 1 cm dosahovala celkové přesnosti 99,3 % a při prostorovém rozlišení 20 cm 88,5 %. V rámci bodové klasifikace na syrových datech byla celková úspěšnost při největším prostorovém rozlišení 69,2 % a nejmenším 82,5 %, což byl také nejlepší výsledek této metody. Autoři uvádí, že na snímcích ve velkém prostorovém rozlišení se jevíly ruchy a stíny, které byly chybně klasifikovány. S přidáním filtrovacího algoritmu se úspěšnost zvedla na 86,3 %. Objektová

klasifikace byla stanovena s celkovou úspěšností 77,7 %. Zde autoři uvádí, že tento typ klasifikace není zcela vhodný pro jejich práci, jelikož jejich zájmové území je skoro ze 100 procent tvořeno vegetací a odkazují se na ostatní studie, které se zabývají krajinným pokryvem, kde jeho heterogenita má vliv na přesnost klasifikace na objektové klasifikaci. Autoři odkazují, že vegetace a lesy se vyznačují nižší přesností u této metody než například mokřady a zemědělské oblasti. Závěrem shrnují, že se jim podařilo účinně omezit terénní práci pomocí metod DPZ a UAV ke zmapování vegetace travních porostů a uvést limity testovaných metod. Tato práce se zabývá ruční a automatickou klasifikací, tedy problematikou, která je řešena v této diplomové práci.

Článek „*Determining the Leaf Area Index and Percentage of Area Covered by Coffee Crops Using UAV RGB Images*“ se zabývá sledováním vývoje indexu listové plochy (LAI – Leaf Area Index) a procentuálním krajinným pokryvem rostlin kávy. Výzkum probíhal v Brazílii mezi červnem 2017 a květnem 2018. Byl použit dron DJI Phantom 3 osazený RGB digitální kamerou Sony EXMOR 1/2.3. Snímkování zájmové oblasti dle autorů probíhalo měsíčně v rozmezí mezi jedenáctou a druhou hodinou z výšky 30 m. K plánování letu UAV byl použit software DroneDeploy. Autoři uvádí, že se jedná o jednoduchou a časově efektivní metodu pro výpočet LAI a procentuálního krajinného pokryvu, který by mohl sloužit zemědělcům při sledování růstu plodin, kontroly plevele, monitorování škůdců a chorob kávových plantáží. V závěru došli, že se jim pomocí digitálních snímků pořízených z UAV podařilo získat nedestruktivní metodou informace o LAI a procentuálním krajinném pokryvu, který silně koreloval s údaji získanými z terénu. (Mendes dos Santos et al., 2020) V rámci tohoto článku je řešena problematika zpracovávání RGB snímku pořízených z UAV.

Song a Park (2020) použili UAV se spektrálním snímačem k pozorování rostlin ve vodní nádrži o průměru 230 m a hloubce mezi 4 až 5 m v Koreji. K pořízení snímků použili UAV s fixními křídly. Snímky byly použity k vytvoření pěti vegetačních indexů NDVI (Normalized Difference Vegetation Index), ENDVI (Enhance Normalized Difference Vegetation Index), NDREI (Normalized Difference RedEdge Index), NGRDI (Normalized Green-Red Difference Index) a GNDVI (Green Normalized Difference Vegetation Index). V rámci jejich výzkumu proběhlo snímkování ve čtyřech měsících (duben, květen, červen a říjen) roku 2018. Plánování letu proběhlo pomocí softwaru Firefly 6 Planner. V každém z pěti spekter snímače bylo pořízeno 338 snímků, ze kterých byly vytvořeny mozaiky v Pix4D Software 2.1. K analýzám byl použit software ArcGIS 10.2. Studie prokázala, že takto zpracované snímky jsou použitelné k pozorování vodních rostlin. Autoři uvádějí, že je stále nutné ověřovat výsledky terénními

průzkumy. Článek se zabývá zpracováním RGB snímků pořízených z UAV v softwarovém prostředí ArcGIS. Článek je zde zmíněn, jelikož se zabývá stejnou problematikou, která je řešena i v této práci, včetně daného softwaru.

V článku „Mapping Wetland Plant Communities Using Unmanned Aerial Vehicle Hyperspectral Imagery by Comparing Object/Pixel-Based Classifications Combining Multiple Machine-Learning Algorithms“ autoři v oblasti mokřad v severozápadní Číně zkoumali využití snímků z UAV s fixním křídlem (CW-10 JOUAV) a hyperspektrální sensor (UHD 185 hyperspectral camera) ke klasifikaci rostlinných společenství různými klasifikačními metodami. K zarovnání snímků autoři využili program The Cubert Cube-Pilot software v 1.4 a pro generování spektrální ortofotomozaiky byl použit software Agisoft PhotoScan ve verzi 1.2.5. V rámci zpracování obrazu se zabývali transformací dat kvůli eliminaci signálu v pozadí a snížení vlivu změn světla pomocí derivační a logaritmické transformace. Podle autorů může transformace vést ke zvýšení spektrálních rozdílů ve viditelné oblasti. Dalším krokem byl výpočet vegetačních indexů. Autoři se zabývali odstraněním spektrální dimenzionality pomocí analýzy hlavních komponent. Klasifikace byla provedena metodami RF (Random Forest), CNN (Convolutional Neural Network), SVM (Support vector Machine). Ke klasifikaci založené na pixelech byl použit software ENVI 5.5 a k objektové klasifikaci software Trimble eCogniton Developer 9.3. Ve výsledku uvádí, že objektová klasifikace si vedla lépe o 9–15 %. Nejlepším klasifikátorem pro sledování rostlin v mokřadech, tedy s největší procentuální úspěšností, byl dle výsledku autorů článku RF s úspěšností 87,15 %, následovaný CNN (83,31 %) a SVM (80,29 %). Autoři se domnívají, že k vysoké úspěšnosti metody RF vedla efektivní transformace dat. (Du, Mao, Wang, Qui, Yan, Feng, Zhang, 2021) V článku je využita klasifikace metodou SVM a softwarové prostředí ENVI, které jsou využity i v této diplomové práci.

Wicaksono a Hermina (2021) se ve své práci zabývají použitím snímků z UAV k objektové klasifikaci využití půdy. Klasifikace obsahovala třídy budov, zpevněných cest, trávníku a jednotlivých druhů stromů. Zájmovým územím této práce byla část univerzitního kampusu. Snímky pořídili pomocí UAV Phantom 4 Pro z výšky 90 m v RGB spektru. Tyto snímky byly zpracovány pomocí softwaru Agisoft Photoscan a byla na nich provedena geometrická korekce. Pro klasifikaci OBIA (Object-Based Image Analysis) využití pokryvu byly použity vegetační indexy VDVI (Visible-band Difference Vegetation Index), Vari (Visible Atmosphericly Resistant Index), NGRDI (Normalized Green-red Difference Index) a RGRI (Red-Green Radio Index). Vegetační indexy sloužily jako vstup pro segmentační operace v softwaru eCogniton.

Výsledkem jejich práce byl mapový výstup založený na kombinaci OBIA a setu pravidel s klasifikovanými budovami, cestami, travním porostem a jednotlivými stromy. Autoři zmiňují, že snímkování pomocí UAV pro účely klasifikace stromů má nevýhodu v tom, že menší stromy jsou v zákrytu pod většími, a tím pádem je není možné pomocí UAV odhalit a následně klasifikovat. Práce je zde uvedena, jelikož se zabývá klasifikací za využití RGB snímků pořízených z UAV.

V článku „*Land Cover Classification from fused DSM and UAV Images Using Convolutional Neural Networks*“ se autoři zaměřili na použití RGB snímku pořízeného z UAV a pomocí metod neurálních sítí provedli klasifikaci krajinného pokryvu v oblasti Malajsijské Univerzity. Snímek byl pořízen v únoru 2018 v poledne pomocí dronu z výšky 353 m s RGB kamerou PowerShot SX23 HS. Ze snímku byla vyprodukována ortofotomozaika a byl vygenerován digitální model povrchů pomocí metody mračna bodů v softwaru Agisoft PhotoScan a ArcGIS v 10.5. V práci se zabírají klasifikací pomocí konvoluční neuronové sítě na dvou data setech. V prvním případě byl použit pouze RGB podklad, ve druhém v kombinaci s digitálním modelem povrchu. Mezi klasifikované prvky se řadí půda, budovy, vegetace/stromy, travní porosty, zpevněné cesty, stíny a vodní útvary. V závěru své práce autoři uvádějí, že si model s kombinací RGB snímku a digitálního modelu vedl v průměru o 1,5 % lépe než klasifikace pouze na RGB snímku. Zde autoři uvádějí, že bez informace o výšce terénu byly některé objekty chybně klasifikovány. Příkladem jsou záměny půdy s budovami a travní porosty se stromy. Autoři uvádí, že dokázali přesně klasifikovat využití půdy ze snímků z UAV na základě CNN, a že se jeví propojení datových sad slibně pro další možné zkoumání. (Al-Najjar et al., 2019) Článek se zabývá zpracováním RGB snímků pořízených z UAV a jejich využití v prostředí ArcGIS jako tato diplomová práce.

## 6 SOFTWARE

V procesu zpracování dat v této práci byl využit software ArcGIS ve verzi 10.5. Jedná se o softwarové prostředí od společnosti ESRI (Environmental Systems Research Institute, Inc.), která je jedním z největších výrobců softwarů zabývajících se problematikou geografických informačních systémů (Longley et al., 2011, s. 190–191). Software obsahuje několik integrovaných aplikací, mezi které se řadí například ArcMap, ArcToolbox, ArcCatalog a ModelBuilder. ArcMap představuje jednu z hlavních aplikací, která se využívá k zobrazování, analýzám a úpravě prostorových dat. ArcToolbox obsahuje kolekci nástrojů k analýze prostorových dat a převodu mezi datovými formáty. ArcCatalog zajišťuje správu a uspořádání geodatabází, mapových dokumentů, rastrových souborů, panelů nástrojů a dalších. ModelBuilder umožňuje vytvářet sekvence kroků, které je možné uložit a následně znovu spouštět. (Longley et al., 2011, s. 190–191, Price, 2015, s. 18–24)

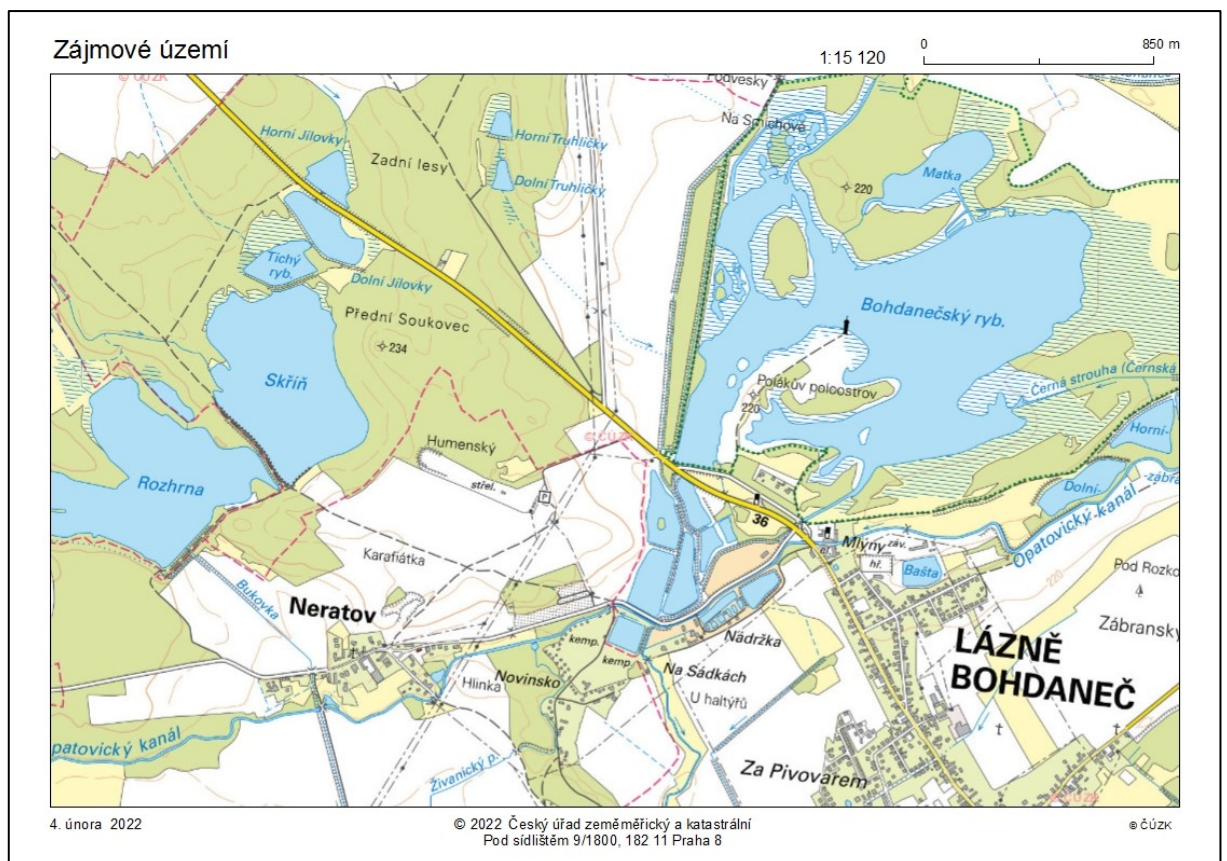
ArcGIS Pro je nejnovějším produktem společnosti ESRI sloužícím pro tvorbu a správu dat včetně provádění prostorových analýz a vizualizací dat ve 2D a 3D. Díky 64-bitové architektuře je tento nástroj rychlejší a výkonnější oproti předchozím verzím a je možné pracovat s několika vrstvami nebo mapami současně. Předností tohoto softwaru je snadné sdílení projektů s ostatními uživateli. V této práci byl využit daný software ve verzi 2.9.0. (Law, Collings, 2016, s. 23–57)

ENVI je software, od společnosti L3Harris Geospatial Solutions, Inc., pro zpracování a analýzu obrazových dat. Tento software umožňuje zpracovávat satelitní, letecká i pozemní data z více než dvou stovek vstupních formátů. Mezi přednosti tohoto softwaru se řadí možnost zpracovávat multispektrální a hyperspektrální data. Výstupy jednotlivých analýz v prostředí ENVI lze jednoduše přenést do softwarového prostředí ArcGIS. Daný software byl použit ve verzi 5.3. (ENVI, © 2022)

Icaros OneButton™ Standart Edition 5.0 je fotogrametrický software od společnosti Icaros, který slouží ke zpracovávání surových snímků z UAV. Jedním z možných výstupů tohoto softwaru jsou geometricky korektní ortomozaiky, které mohou být přesně měřeny a analyzovány. Výstupy z tohoto softwaru jsou kompatibilní se softwary ArcGIS a ENVI. (Icaros, © 2022)

## 7 CHARAKTERISTIKA ZÁJMOVÉHO ÚZEMÍ

Zájmovým územím této práce je rybník Skříň v Pardubickém kraji v okrese Pardubice. Nachází se zhruba 3 km od obce Lázně Bohdaneč. Rybník leží v nadmořské výšce 224 m n. m a rozkládá se na ploše 26 ha. Jeho objem činí zhruba 130 000 m<sup>3</sup>. V jeho těsném sousedství se nalézá rybník Rozhrna, do kterého zasahuje odtokové vyústění rybníku Skříň. Rybníky Skříň a Rozhrna jsou od sebe rozděleny hrází o šířce čtyř metrů, kterou prochází naučná stezka Pernštejnskými rybníky. V současné době je rybník Skříň ve správě Rybničního hospodářství Lázně Bohdaneč a využívá se k chovu ryb. Společně s přilehlými rybníky tvoří ornitologickou oblast vodního ptactva. Lokalita zájmového území rybníku Skříň a jeho okolí je zobrazena na obrázku 5 níže.



Obrázek 5: Lokalita zájmového území (Zdroj: ČÚZK, 2022)



## 8 VLASTNÍ ZPRACOVÁNÍ

Vstupními daty diplomové práce jsou mozaiky zájmového území rybníku Skříň ve formátu \*.tiff (Tagged Image File Format). Předností tohoto formátu je jeho bezztrátová komprese. Data pro jednotlivé mozaiky zájmového území byla pořízena v jednotlivých měsících kalendářního roku 2018 z letové hladiny 40 m v rámci pravidelného snímkování části tohoto rybníku za pomoci UAV DJI Phantom 3. Jednotlivé mozaiky zájmového území byly složeny z 64 snímků v softwaru Icaros OneButton™ Standart Edition 5.0. Ukázka mozaiky zájmového území je zobrazena na obrázku 6 níže. DJI Phantom 3 je komerční kvadrokoptéra od firmy DJI vážící 1,2 kg a s možností trvání letu do 25 minut osazenou RGB senzorem 1/2.3" se zorným úhlem 94° a ohniskovou vzdáleností 20 mm (DJI, © 2022). Data z tohoto snímkování jsou využívána k výzkumu a v závěrečných pracích studentů Ústavu systémového inženýrství a informatiky Univerzity Pardubice. Tato práce zkoumá zájmové území z datových řad mezi srpnem a listopadem roku 2018.



Obrázek 6: Mozaika zájmového území ze srpna 2018 (Zdroj: vlastní)

## 8.1 Příprava dat

V rámci předzpracování obrazu byl v softwaru ArcMap 10.5 vytvořen nový datový soubor typu shapefile, což je soubor umožňující ukládat a popisovat prostorové vztahy a informace. Dále byl nastaven souřadnicový systém odpovídající vstupním datům. V tomto případě se jedná o souřadnicový systém WGS 84 UTM Zone 33N. Tento souřadnicový systém je založen na Mercatorovu zobrazení v příčné poloze, které je rozděleno zvlášť pro severní a jižní polokouli Země. Dále byla zdrojová data ve formátu \*.tiff načtena do ArcMapu a následně georeferencována, aby došlo k co nejpřesnějšímu překryvu mozaik zájmového území. V této práci se data georeferencovala vůči mozaice zájmového území z měsíce srpna. V tomto případě byly vybrány především spadlé stromy a kameny, které jsou jasně rozpoznatelné na všech mozaikách a jsou v čase stálé.

### 8.1.1 Georeferencování

Funkce Georeferencování se nachází v panelu „Georeferencing“. V rámci tohoto procesu se pomocí „Control Points“ označují a přiřazují významné lícovací body v datech k referenčním datům. Ukázka georeferencování mozaiky z měsíce září vůči referenčním mozaice z měsíce srpna (vlevo) na příkladu padlého stromu je zobrazena na obrázku 7 níže.



Obrázek 7: Ukázka georeferencování (Zdroj: vlastní)

### **8.1.2 Ořez**

Z georeferencovaných mozaik je vybrána pouze menší část zájmového území („area of interest“), na které je prováděn výzkum, a to kvůli rychlejšímu a méně náročnému procesu zpracování výpočetní technikou. Nejprve je potřeba vytyčit zájmovou oblast. Toho je možné docílit pomocí nové polygonové vrstvy. V rámci tvorby nové vrstvy se definuje její jméno, typ a souřadnicový systém. Byl zvolen typ „Polygon“ a souřadnicový systém WGS 84 UTM Zone 33N. K oříznutí byla použita funkce „Extract by Mask“. K oříznutí zájmového území je možné využít více nástrojů. Příkladem podobné funkce je „Clip Raster“. „Extract by Mask“ je součástí „ArcToolbox“ pod kategorií „Spatial Analyst Tools“ a „Extraction“. V rámci tohoto nástroje je třeba zvolit vstupní rastr, na kterém bude prováděn ořez, a vrstvu ořezu, kterou může tvořit v rámci použití dané funkce jiný rastr nebo dataset. V tomto případě se jedná o vytvořenou polygonovou vrstvu ohraničující ořez. Výstupem funkce „Extract by Mask“ je oříznutá mozaika dle polygonové vrstvy.

## **8.2 Identifikace zájmového území**

Výstupem předcházejících bodů jsou georeferencované a oříznuté části mozaik zájmového území rybníka Skříň, na kterých bude prováděno další zpracování v rámci této diplomové práce.

### 8.2.1 Zájmové území srpen 2018

Obrázek 8 zobrazuje ořez mozaiky zájmového území z měsíce srpna 2018. V tomto měsíci už probíhal proces vypouštění rybníku Skříň. Ze snímku je zřetelně rozpoznatelná zelená vegetace okolí rybníka a břehová část, kde v rámci vypouštění opadla voda. Vegetace je představena na snímku několika odstíny zelené barvy. Odstíny vegetace jsou velmi zřetelné v levé dolní části snímku na korunách stromů. Ve spodní části snímku, na místě snížení hladiny vody, je viditelný artefakt, který vznikl při skládání mozaiky. Vodní povrch na tomto snímku má při pozorování zelený nádech a při bližším pozorování se toto zbarvení odstínem podobá břehové vegetaci. V rámci vodní hladiny jsou pozorovatelné alespoň tři barevné odstíny.



Obrázek 8: Zájmové území srpen 2018 (Zdroj: vlastní)

### 8.2.2 Zájmové území září 2018

V měsíci září pokračuje vypouštění rybníku. Ze snímku (obrázek 9) je zřetelný úbytek vodní hladiny v porovnání s předchozím měsícem. Dále je pozorovatelné bujení zelené vegetace v místech po opadlé vodě. Vegetace je na snímku zachycena ve světlých až tmavých odstínech zeleně. Obdobně jako na předchozím snímku je viditelné různé zbarvení korun stromů v levé spodní části snímku. Dále jsou na snímku v porovnání s předchozím měsícem více patrné stíny. Vodní hladina je zřetelně tvořena dvěma barevnými odstíny. V horní polovině břehové části je zobrazeno mísení břehové části a vodní hladiny.



Obrázek 9: Zájmové území září 2018 (Zdroj: vlastní)

### 8.2.3 Zájmové území říjen 2018


Na obrázku 10, který představuje snímek z měsíce října, lze pozorovat téměř vypuštěný rybník Skříň. V levé části snímku jsou pozorovatelné dlouhé stíny stromů, dále holé větve korun stromů. Vegetace na tomto snímku je zachycena ve světlých i tmavých odstínech zelené barvy. Některé části vegetace dostávají žlutý nádech. V rámci tohoto měsíce pokračuje rozšiřování zelené vegetace po ploše vypuštěného dna rybníku. Zbytky vody jsou patrné v nejhlubších výmolech dna rybníku a ve strouze vedoucí k výpusti. Pouhým pozorováním tohoto snímku nelze v některých případech snadno odlišit dno rybníka a vodní povrch.



Obrázek 10: Zájmové území říjen 2018 (Zdroj: vlastní)

#### 8.2.4 Zájmové území listopad 2018

Posledním pozorovaným měsícem je měsíc listopad. Tento měsíc je zachycen na výřezu z mozaiky na obrázku 11. V měsíci listopadu 2018 je zřetelný úbytek zeleně břehové vegetace. Na stromech v levé spodní části snímku jsou k vidění holé větve. Dále je pozorovatelné rozšíření zeleně na dně rybníka. Tato vegetace má v některých případech velmi malou hustotu zastoupení. Na snímku je zaznamenatelné vyschnutí výmolů, ve kterých se držela hladina vody z předcházejících měsíců. Voda je okem patrná pouze ve vypouštěcím korytu a při pozorném sledování v pravé spodní části snímku.




Obrázek 11: Zájmové území listopad 2018 (Zdroj: vlastní)

### 8.3 Digitalizace snímků

Digitalizace zájmového území v měsících srpnu, září, říjnu a listopadu byla provedena v softwarovém prostředí ArcGIS 10.5 v aplikaci ArcMap. V rámci tohoto procesu byl vytvořen nový datový soubor typu shapefile pro každý digitalizovaný snímek. Dále bylo nutné definovat počet skupin pro digitalizaci. Na základě struktury snímků se jedná o tři skupiny, a to o vodu, holou půdu a vegetaci. Tyto skupiny jsou obsaženy na všech snímcích a v rámci jejich vývoje v čase se jejich rozloha na snímcích vizuálně mění. Tento počet a typ tříd budou vstupy i pro automatickou klasifikaci.

Samotný proces digitalizace je časově náročný, jelikož je třeba ručně vybírat jednotlivé prvky ze snímků pomocí polygonů a přiřazovat je do jednotlivých klasifikačních skupin. Tvorbu není možné uspěchat z důvodu dosažení co možná nejpresnějšího digitalizovaného snímku. Další náročností digitalizace snímků je nízký kontrast mezi prvky zdrojových dat. Zejména na snímku z října a listopadu, kdy se velmi obtížně identifikuje vodní povrch a oblasti s velmi řídkým zastoupením vegetace zejména v místech dna vypuštěného rybníka. Ke zlepšení digitalizace bylo provedeno zvýraznění obrazu pomocí záměny spektrálních pásem z RGB 1, 2, 3 na RGB 3, 2, 1. V rámci této kombinace pásem je zobrazovaná barva podobná lidskému vidění. Na snímcích je zdravá vegetace zobrazována zeleně, zbylá vegetace je zbarvena do hněda či žluta (Quinn, © 2001). Zdigitalizovaný snímek z měsíce září je zobrazen na obrázku 12 níže.



Obrázek 12: Ukázka digitalizace na snímku ze září 2018 (Zdroj: vlastní)

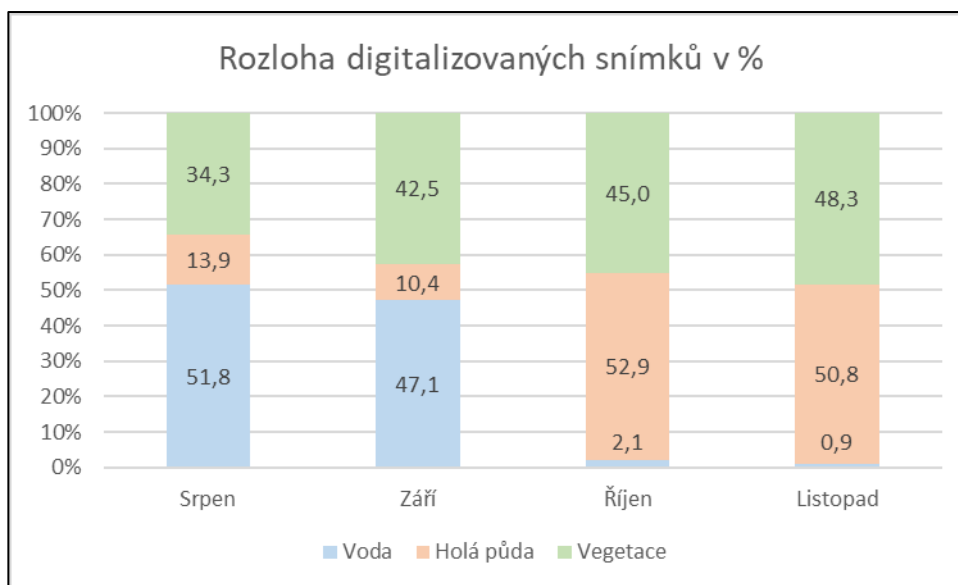


Dalším krokem byl výpočet rozlohy digitalizovaných snímků. Toho je možné dosáhnout přidáním nového sloupce v atributové tabulce. Pomocí volby „Calculate Geometry“ lze na základě souřadnicového systému vypočítat rozlohu pro digitalizované skupiny vody, holé půdy a vegetace. Přehled vypočtené rozlohy digitalizovaných snímků je zobrazen v tabulce 2.

Tabulka 2: Rozloha digitalizace (Zdroj: vlastní)

Měsíc	Rozloha (m <sup>2</sup> )		
	Voda	Holá půda	Vegetace
Srpen	5018	1351	3327
Září	4564	1007	4124
Říjen	204	5124	4366
Listopad	92	4923	4681

Z vypočtené rozlohy digitalizovaného území je zřetelná změna zastoupení jednotlivých prvků v jednotlivých měsících, a to především v úbytku vody a zvětšení oblasti pokryté vegetací. Tyto změny jsou procentuálně vyjádřeny na obrázku 13.



Obrázek 13: Rozloha digitalizovaných snímků (Zdroj: vlastní)

## 8.4 Klasifikace

V rámci diplomové práce byla provedena řízená a neřízená klasifikace různými algoritmy v softwarovém prostředí ArcGIS 10.5, ArcGIS Pro 2.9.0 a ENVI 5.3.

V softwarovém prostředí ArcGIS 10.5 v aplikaci ArcMap lze otevřít klasifikační menu „Image Classification“ pomocí pravého kliknutí na horní liště a vyhledáním zmíněné položky. V rámci této lišty je třeba zvolit položku neřízené klasifikace „Iso Cluster Unsupervised Classification“, po které se spustí vybraný nástroj. V rámci průvodce se volí vstupní rastr, tedy jeho pásma, a nastavení počtu klasifikačních tříd. Dále je možné navolit cestu k místu uložení výstupu. V rámci nastavování neřízené klasifikace v prostředí ArcMap minimální počet buněk pro třídy zůstal v původní hodnotě 20. To samé platí i pro interval pro odběr vzorků, který zůstal v původní hodnotě 10. Následným spuštěním je zahájen proces výpočtu nástroje nad zdrojovými daty a výsledná klasifikace se promítne jako nová vrstva v projektu.

K použití řízené klasifikace v prostředí ArcMap se využívá stejný nástroj jako v případě neřízené klasifikace, tj. „Image Classification“. V porovnání s neřízenou klasifikací je v klasifikaci řízené nutno zvolit trénovací množiny. K tomu se využívají položky „draw polygon“, „draw rectangle“ a „draw circle“. Po vybrání ikony je možné vytyčit oblasti trénovací množiny na příslušném snímku, na kterém bude provedena řízená klasifikace. K práci s trénovacími daty je vhodné využít „Training Sample Manager“, s jehož pomocí lze měnit názvy trénovacích ploch a jejich barvu. Dalším využitím je spojování a rozpojování už vytyčených trénovacích oblastí do tříd. Trénovací data se dají v rámci „Training Sample Manager“ uložit ve formě datového souboru „shapefile“, který lze následně využít v prostředí ArcGIS Pro 2.9.0 a ENVI 5.3. Spuštění řízené klasifikace „Maximum Likelihood“ s navolenými trénovacími množinami lze docílit pomocí volby „Interactive Supervised Classification“. Výstupem této funkce je nová rastrová vrstva s provedenou klasifikací.

Software ArcGIS Pro nabízí položky pro řízenou klasifikaci v horní liště prostředí pod záložkou „Imagery“ a volbou „Classification Tools“. V rámci průvodce klasifikací se volí jednotlivé metody klasifikace. V tomto případě se jednalo o klasifikátor „Support Vector Machine“. Dalším nastavením je výběr trénovacích vzorků, zde byly vloženy data z už dříve vytvořených trénovacích množin v softwaru ArcMap. Následně je třeba navolit maximální počet vzorků pro jednotlivou třídu. Tento údaj zůstal ve výchozím nastavení, tedy na hodnotě 500. Zbylými nastaveními je výběr cesty k uložení souboru a samotné spuštění klasifikační metody.

V programu ENVI se klasifikační menu nachází v „Toolbox“ pod složkou „Classification“ a „Classification Workflow“. Při zvolení této volby se načte průvodce klasifikací v prostředí ENVI. Prvním krokem je volba rastrového souboru, na kterém bude prováděna klasifikace. V dalším kroku se v průvodci volí typ klasifikace mezi neřízenou klasifikací „No Training Data“ a klasifikací řízenou „Use Training Data“. V případě výběru neřízené klasifikace se v rámci tohoto průvodce provádí neřízená klasifikace „IsoData“. Při nastavování neřízené klasifikace „IsoData“ se volí počet klasifikovaných tříd a v rámci pokročilého nastavení je možné zvolit počet iterací („Maximum Iterations“), který je nastaven na 10, a „Change Threshold %“ s defaultní hodnotou 2, který představuje ukončení procesu klasifikace v závislosti na procentuální změně během iterací za předpokladu, že je menší než uvedená hodnota změny. Následnou volbou tlačítka „Next“ proběhne neřízená klasifikace. Dalším krokem průvodce je volba postklasifikačních úprav, které odstraňují šumy a malé oblasti vzniklé klasifikací. V této fázi práce nebyly postklasifikační filtry využity v závislosti na vizuálním porovnání výsledné klasifikace v prostředí ENVI a ArcMap. Posledním krokem průvodce neřízené klasifikace je uložení výstupu klasifikace včetně volby cesty k uloženým výstupům.

Druhou metodou neřízené klasifikace v prostředí ENVI byla klasifikace „K-Means“, ke které vede cesta přes „ArcTollbox“, kde se pod složkou „Classification“ v podsložce „Unsupervised Classification“ nachází funkce „K-Means Classification“. Při nastavení neřízené klasifikace „K-Means“ se volí počet klasifikovaných tříd, „Change Thresholds %“ s defaultní hodnotou 5 a počet iterací, který je ve výchozím nastavení nastaven na 1. Při testování této metody bylo ponecháno nastavení „Change Thresholds %“ na hodnotě 5 a počet iterací byl proveden s hodnotou 1 a 10. Deset iterací odpovídá nastavení metody „IsoData“ a s tímto nastavením docházelo vizuálně k lepším výsledkům klasifikace. Posledním nastavovaným polem je cesta k uložení výstupu. Po aplikování klasifikace vznikne nová vrstva s provedenou klasifikací v „Layer Manager“.


K provedení metod řízené klasifikace v prostředí ENVI byl použit průvodce „Classification Workflow“. Po zvolení vstupní rastrové vrstvy, na které bude klasifikace prováděna, je třeba zvolit řízenou klasifikaci „Use Training Data“. Po této volbě se v dalším kroku volí trénovací data. Ta je možné načíst z exportovaného datového souboru „shapefile“ z prostředí ArcMap a následně je možné pojmenovat třídy a zvolit jejich barvu. Na záložce „Algorithm“ lze zvolit jednu ze čtyř metod řízené klasifikace. Jedná se o metody „Maximum Likelihood“, „Minimum Distance“, „Mahalanobis Distance“ a „Spectral Angle Mapper“.

Při zpracovávání této práce byly zvoleny postupně všechny metody. Jejich předvolby zůstaly v původním nastavení. Při stisknutí tlačítka „Next“ se provede vybraná klasifikační metoda nad trénovacími daty. Následně je možné zvolit cestu k uložení klasifikace.

Výše zmíněnými postupy byla provedena klasifikace čtyř snímků zájmového území dvěma metodami v prostředí ArcMap, jednou metodou v prostředí ArcGIS Pro a šesti metodami v prostředí ENVI.

## 8.5 Reklasifikace

V případě neřízené klasifikace v měsíci říjnu a listopadu se nepodařilo klasifikovat určité oblasti. Jednalo se o oblasti vody, holé půdy a vegetace při nastavení neřízených klasifikátorů pro tři třídy nebo v rozsahu tříd 2 až 5 v závislosti na klasifikační metodě. Tato skutečnost je zobrazena na obrázku 14 níže, který zobrazuje výsledek neřízené klasifikace v prostředí ArcMap nastavený na výstup tří tříd.



Obrázek 14: ISO Cluster (ArcMap) tři třídy (Zdroj: vlastní)

Ke zlepšení těchto výstupů byla provedena reklasifikace neřízených klasifikátorů v uvedených měsících. V rámci reklasifikace je možné slučovat jednotlivé třídy do menšího počtu, a tím zvýšit přesnost neřízené klasifikace. K tomuto účelu byla znovu provedena klasifikace výše zmíněnými metodami nejprve pro 6 tříd. Zde se opět nepodařilo sloučit jednotlivé třídy do odpovídajících výstupů. Následně byla provedena klasifikace pro 9 tříd. Tyto třídy po sloučení vizuálně lépe odpovídají požadovaným klasifikačním třídám vody, holé


půdy a vegetace. Reklasifikační nástroj „Reclassify“ se nachází v „ArcToolbox“ pod položkou „Spatial Analyst Tools“ a „Reclass“. V rámci tohoto nástroje se volí vstupní rastr, tedy výstup neřízeného klasifikátoru s odpovídajícím počtem tříd pro slučování. Dalším nastavením je volba reklasifikačního pole, které představuje označení klasifikačních tříd. V tomto případě se jedná o pole „Value“. K načtení všech položek je třeba zvolit pole „Unique“ a následně je možné ručně překlasifikovat jednotlivé třídy do vizuálně lépe odpovídajících výstupů. Následným a zároveň posledním nastavením je volba uložení výstupu a spuštění nástroje.

## 8.6 Postklasifikační úpravy

Postklasifikační úpravy se v prostředí ArcMap nachází v „ArcToolbox“ pod záložkou „Spatial Analyst Tools“ a „Generalization“. Jako možnou metodu těchto úprav ArcMap nabízí „Majority Filter“, který pracuje na principu nahrazování hodnoty buňky na základě většinové hodnoty buněk sousedících. Pro použití této funkce se volí vstupní rastr, na kterém má proběhnout posklasifikační úprava, a dále výběr cesty k výstupu. „Majority Filter“ pracuje se dvěma hlavními nastaveními. První udává, kolik buněk musí mít stejnou hodnotu k provedení změny. V tomto případě je možné zvolit „Majority“, tedy většinový podíl buněk, nebo „Half“, kdy postačí pouze polovina buněk se stejnou informací. Druhým nastavením je počet sousedních buněk, podle kterých bude probíhat změna. Zde je možný výběr mezi čtyřmi a osmi. To znamená, že tři ze čtyř nebo pět z osmi sousedních buněk musí mít stejnou hodnotu při nastavení „Majority“ a dvě ze čtyř nebo čtyři z osmi pro nastavení parametru „Half“.

Další možností posklasifikačních úprav je funkce „Boundary Clean“, která vyhlazuje hranice mezi zónami. V rámci této funkce se změní všechny oblasti, které jsou menší než oblast o rozměru 3 px na 3 px. V rámci funkce se volí vstupní rastr, na kterém bude prováděna změna, a cesta k výstupu funkce. Dalším nastavením je technika třídění „Sorting Technique“, která nabízí možnosti „No Sort“, při kterém se zóny s většími hodnotami rozšiřují do zón s hodnotami menšími. „Descend“, kdy zóny s většími plochami mají vyšší prioritu expanze. A „Ascend“, která je opakem možnosti „Descend“. Oblasti s menšími plochami mají tedy vyšší prioritu expanze do oblastí s většími plochami. Dále je možné nastavit počet směrů pro tento proces, kdy je možné provést proces rozšiřování a zmenšování dle vybraného typu a následně se provede proces s obrácenou prioritou. Nebo lze zvolit pouze provedení funkce podle vybraného typu.

V rámci testování těchto postklasifikačních metod se jejich výsledky projevují v malé míře v závislosti na detailnosti zájmového území, které má rozlišení 3140 px na 3431 px. Pro výrazné zlepšení výsledného obrazu by bylo vhodné několikrát zopakovat procesy postklasifikačních úprav, a to pro každý výstup klasifikace zvlášť. Jednalo by se o velmi pracnou a časově nákladnou úpravu, která se nevyrovná získanému zlepšení výsledné klasifikace. Na základě těchto zjištění nakonec nebyly postklasifikační úpravy na výsledky jednotlivých klasifikačních metod aplikovány. Na obrázku 15 jsou zobrazeny postklasifikační úpravy provedené na řízené klasifikaci z měsíce září v prostředí ENVI. V rámci postklasifikačních úprav byly provedeny zmíněné metody dvanáctkrát. V levé části obrázku je zobrazen výstup klasifikace a v pravé výsledek po provedení daných úprav.



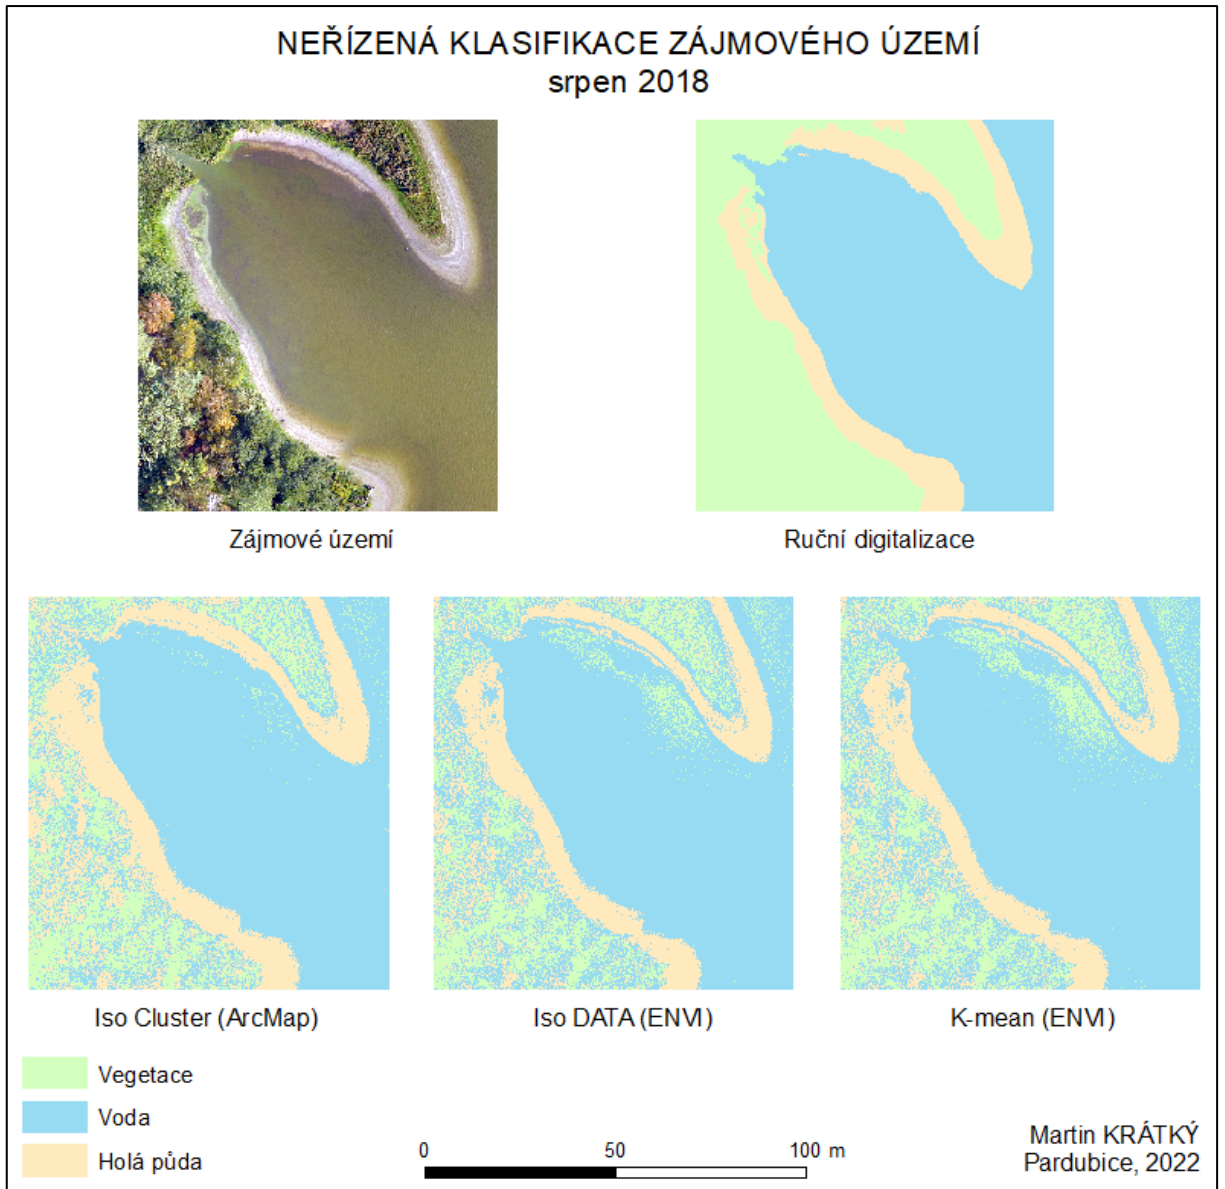
Obrázek 15: Porovnání klasifikace bez a s provedenými postklasifikačními úpravami (Zdroj: vlastní)

## 8.7 Vizualizace klasifikace

Klasifikační výstupy jednotlivých metod byly vizualizovány kartografickým výstupem v softwaru ArcMap. V rámci těchto výstupů vznikla vizualizace každého období pro neřízenou a řízenou klasifikaci.

### 8.7.1 Klasifikace srpen 2018

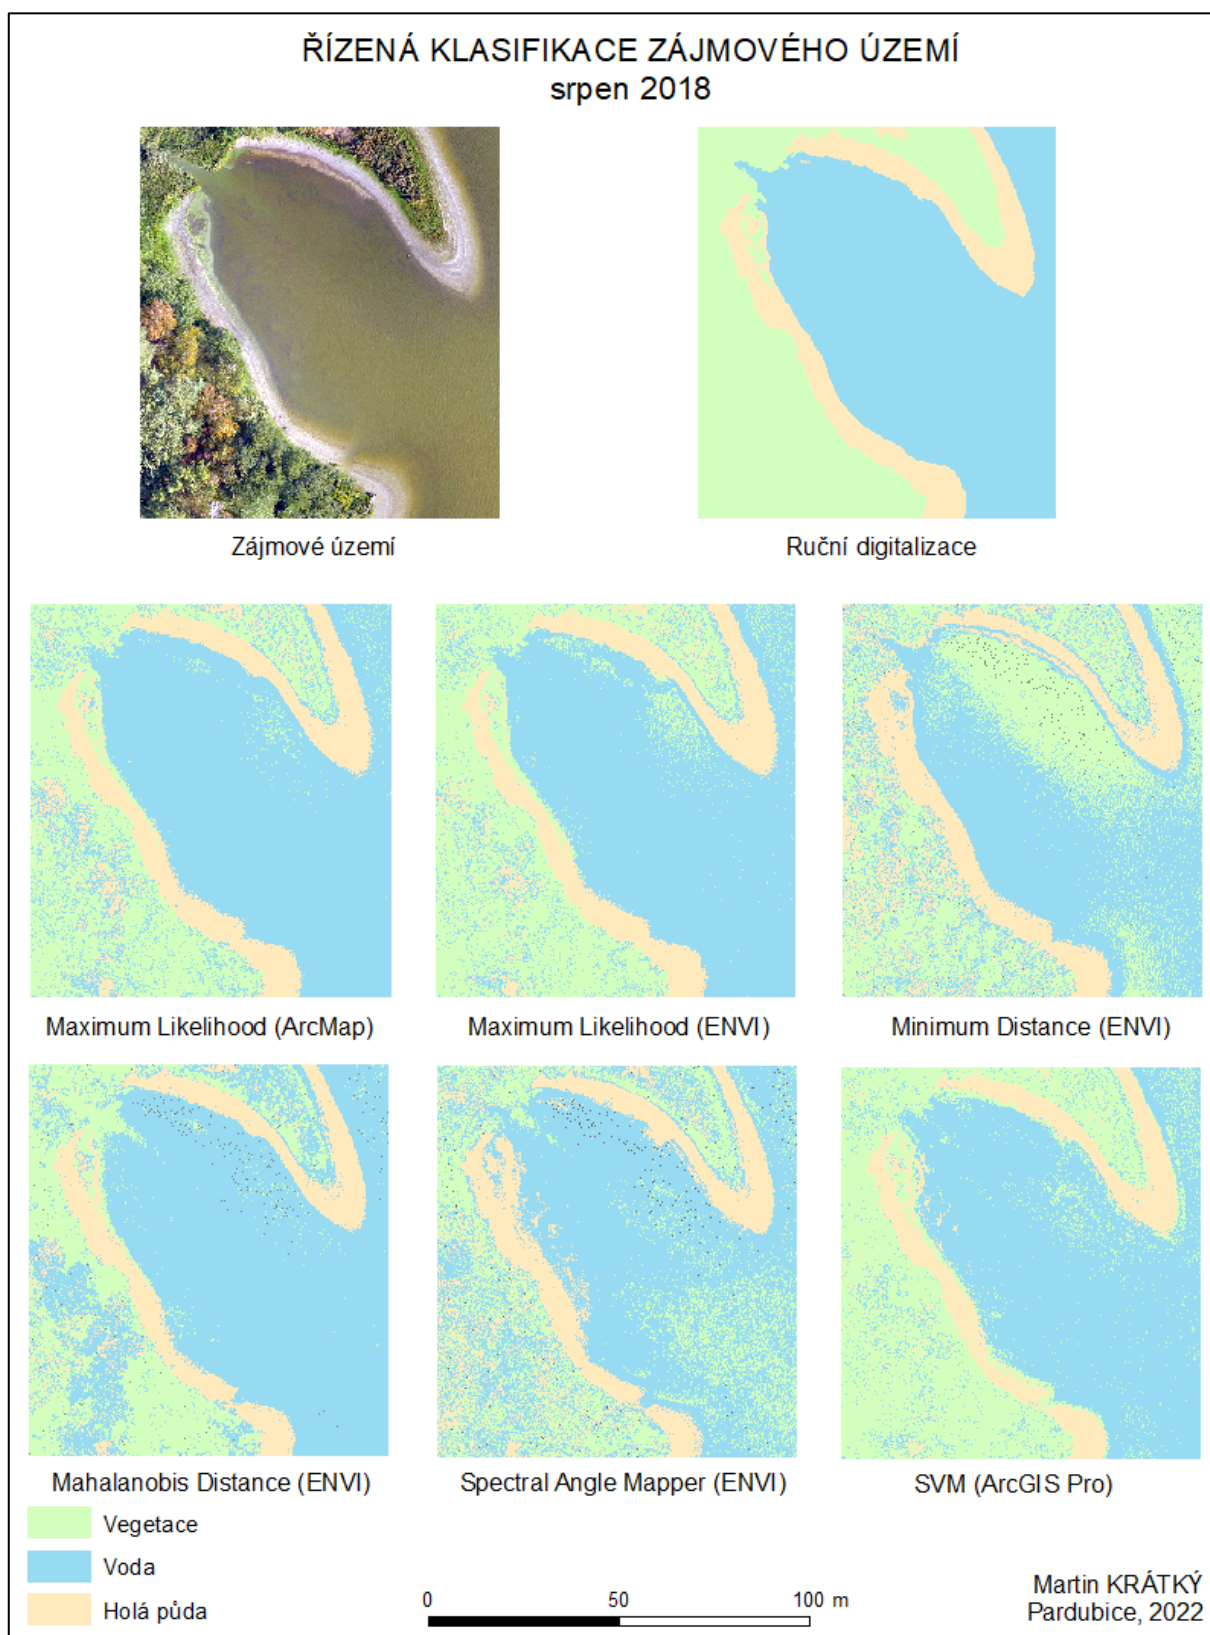
Vizualizace neřízené klasifikace na snímku ze srpna 2018 do tří tříd (voda, holá půda a vegetace) je zobrazena na obrázku 16.



Obrázek 16: Neřízená klasifikace srpen 2018 (Zdroj: vlastní)

V rámci neřízené klasifikace v měsíci srpnu všechny tři metody dokázaly zařadit vstupní data do tří tříd, které odpovídají požadovanému výstupu. Dle vizuálního hodnocení si s problematikou klasifikování vodní plochy rybníka vedla nejlépe metoda „Iso Cluster“. Zbylé dvě metody v rámci této oblasti zaznamenaly větší zastoupení nesprávně klasifikované vegetace. Všechny uvedené metody obtížně klasifikují břehovou vegetaci, kde se mísí klasifikace vegetace, holé půdy a vody.

Výsledky řízené klasifikace snímku ze srpna 2018 jsou zobrazeny na obrázku 17 níže.



Obrázek 17: Řízená klasifikace srpna 2018 (Zdroj: vlastní)



Dle vizuálního pozorování výstup z klasifikační metody „Maximum Likelihood“ dosahuje v obou softwarových prostředích podobných výsledků. Výstup ze softwaru ArcMap lépe klasifikoval povrch vodní hladiny rybníka. Toto je patrné v horní polovině snímku. V porovnání s ArcMap ENVI vizuálně lépe klasifikoval vegetaci. Dané změny jsou pozorovatelné převážně v oblasti korun stromů v levé dolní části snímku, kde jsou koruny stromů na referenčním snímku zbarveny do oranžova a žluta. Tyto stromy jsou klasifikovány jako holá půda. Břehovou oblast vodní plochy vyhodnotily klasifikátory podobně jako v případě ruční digitalizace snímků.

Metoda „Minimum Distance“ jako jedna z mála výstupů dokázala správně klasifikovat vodu v místě výpusti rybníku, ale oblast vodní hladiny byla v rámci tohoto klasifikátoru v horní části snímku chybně zaměněna za vegetaci. Dále je zde nesoulad ve vyhodnocení vegetace a holé půdy za vodu v levé horní části snímku při porovnání s ruční klasifikací. Některé oblasti na snímku se touto metodou nepodařilo klasifikovat.

Klasifikátor „Mahalanobis Distance“ správně dle vizuální interpretace klasifikoval povrch vodní hladiny rybníka, ale část vegetace v levé spodní části snímku klasifikoval ve větších oblastech jako vodu. Některé oblasti na snímku se touto metodou nepodařilo klasifikovat.

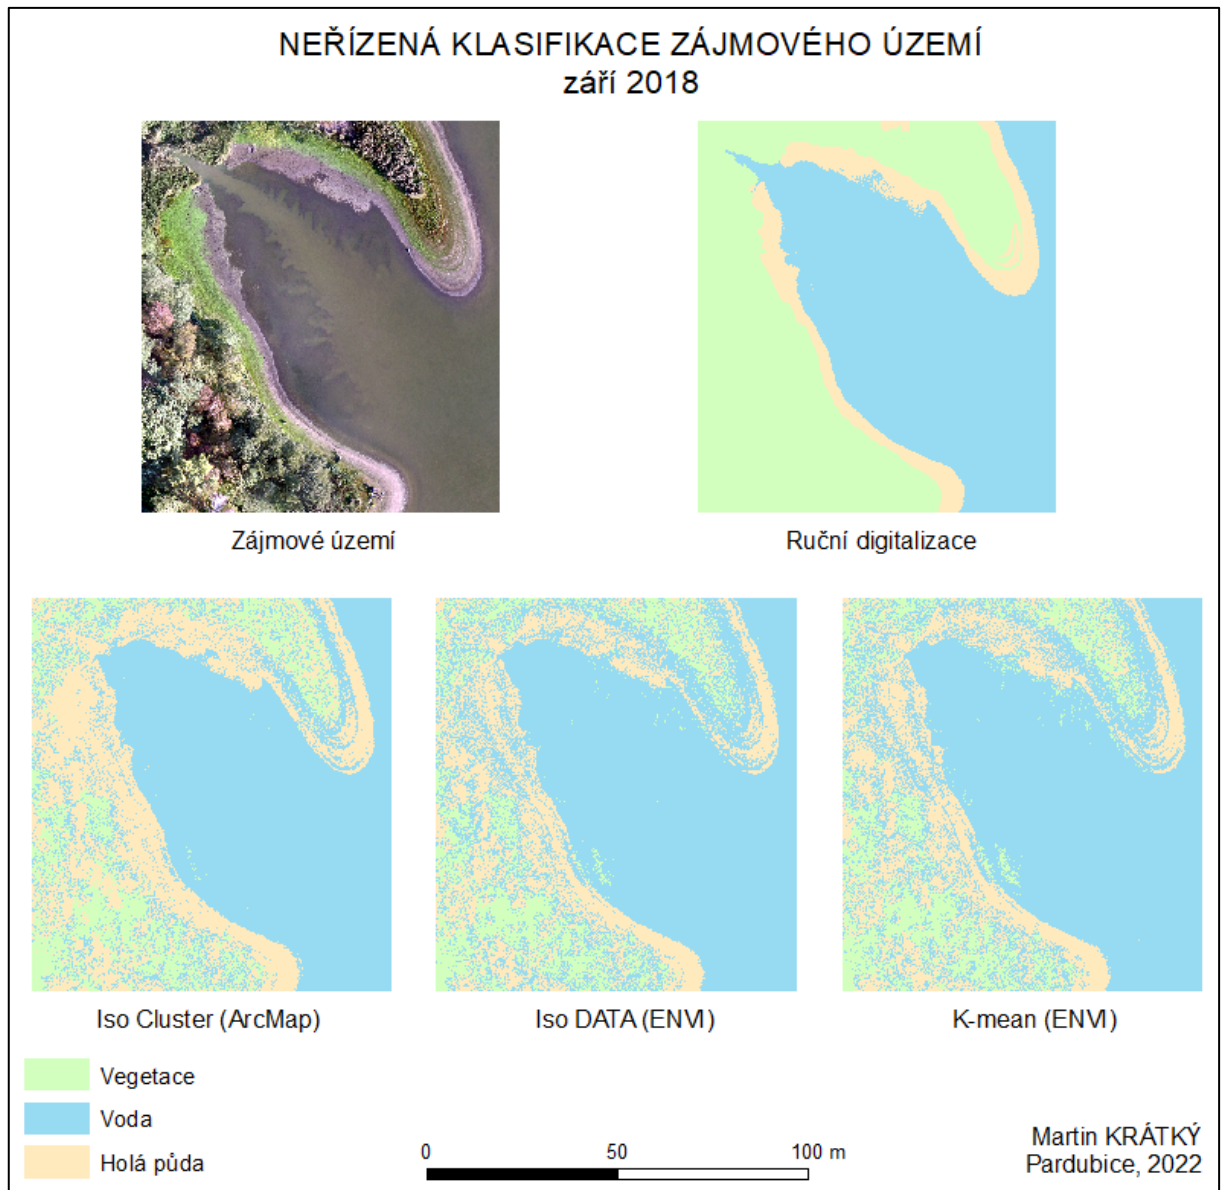
Metoda „Spectral Angle Mapper“ dokázala klasifikovat tři hlavní klasifikační oblasti, ale výsledky této klasifikace neodpovídají celistvým plochám. I této metodě se nepodařilo klasifikovat všechny pixely.

Klasifikátor „Support Vector Machine“ klasifikoval vizuálně nejlépe břehovou část vegetace jako celistvou plochu, ale chybně klasifikoval na některých místech vodní hladinu, kterou vyhodnotil jako vegetaci a holou půdu.

V souhrnu si vizuálně s tímto klasifikačním problémem nejhůře poradila metoda „Minimum Distance“, kde je velká plocha vody chybně klasifikována jako vegetace. Klasifikátor „Support Vector Machine“ klasifikoval vizuálně lépe břehovou část vegetace, ale chybně klasifikoval na některých místech vodní hladinu jako vegetaci, kdežto klasifikátor „Maximum Likelihood“ lépe klasifikovat plochy vodní hladiny rybníka a hůře břehovou vegetaci. Nejlepším klasifikátorem pro rozlišení vegetace, vody a holé půdy na snímku z měsíce srpna dle vizuálního hodnocení je technika „SVM“ a „Maximum Likelihood“.

## 8.7.2 Klasifikace září 2018

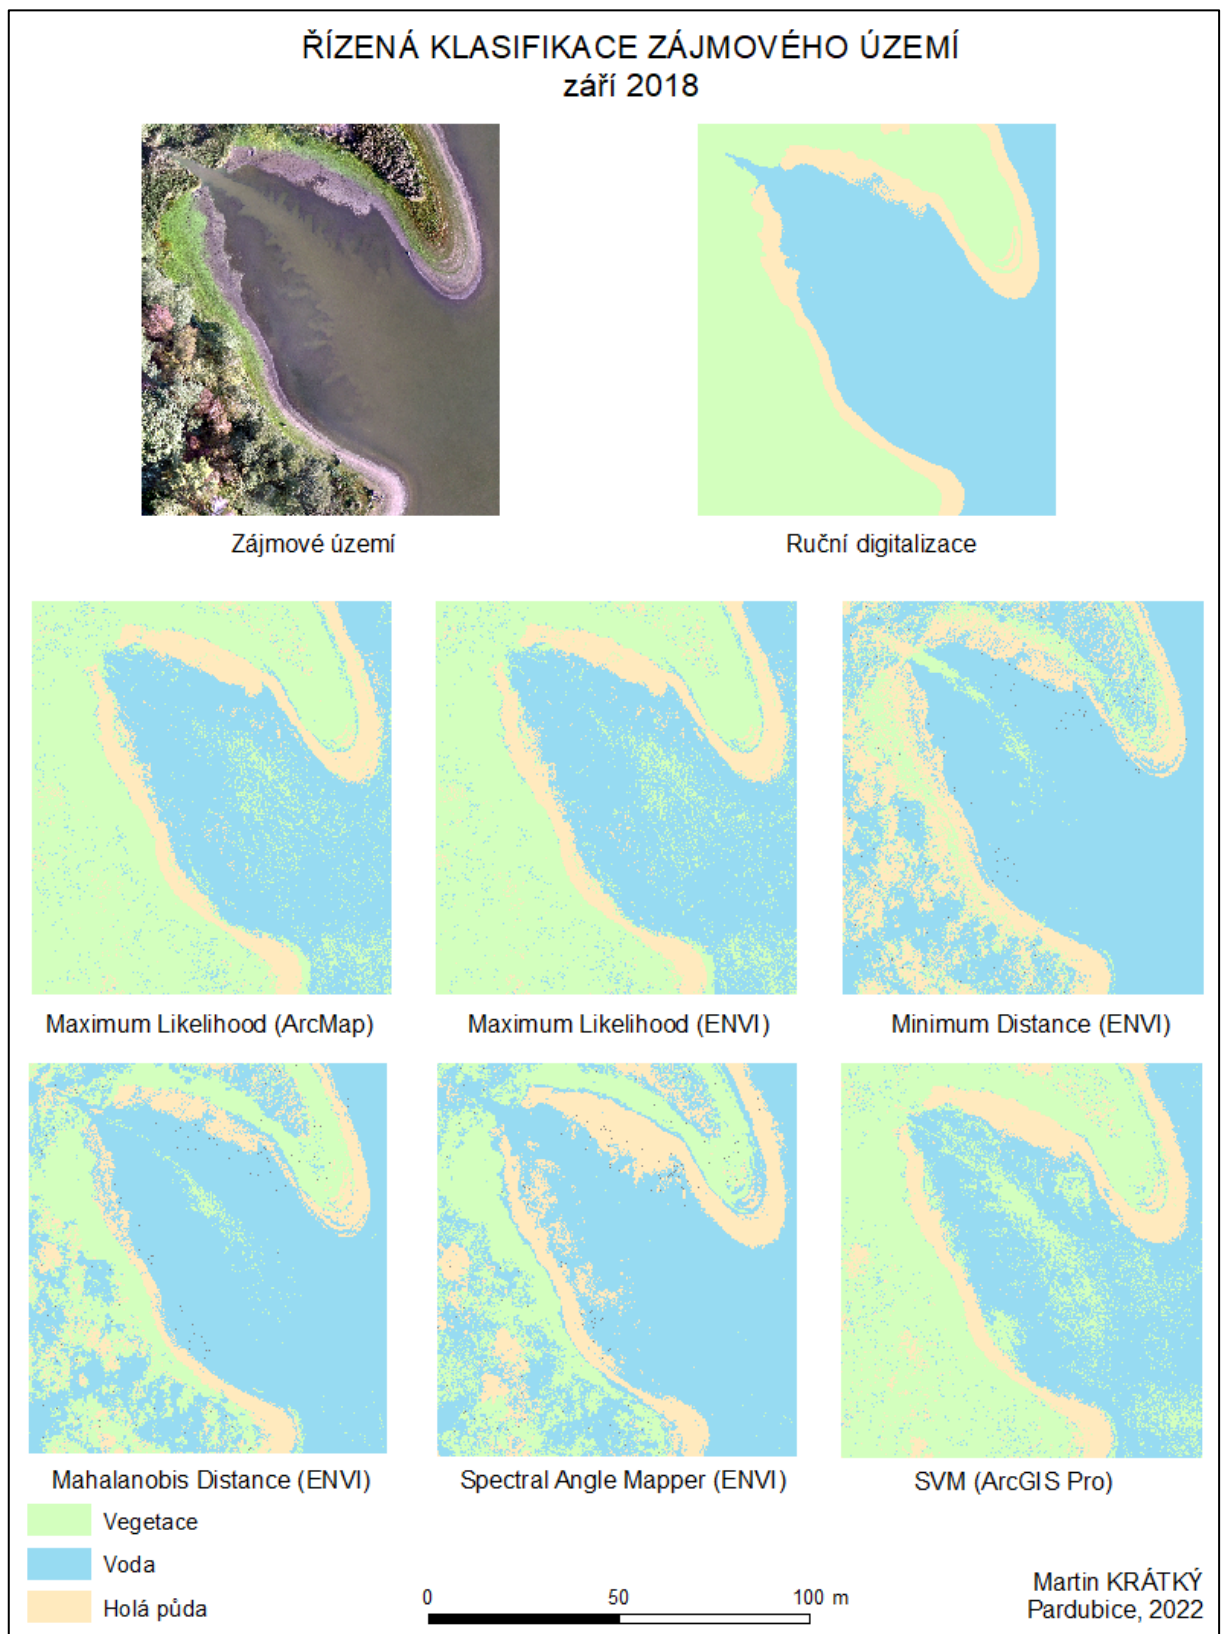
Neřízená klasifikace zájmového území z měsíce září je zobrazena na obrázku 18.



Obrázek 18: Neřízená klasifikace září 2018 (Zdroj: vlastní)

Při využití všech určených metod neřízené klasifikace se povedlo klasifikovat tři určené klasifikační třídy – voda, holé půda, vegetace. Tyto metody dle vizuálního zhodnocení správně klasifikují vodní hladinu a v poměrně obстойné míře holou půdu v oblastech břehů. Klasifikátory neřízené klasifikace nedokázaly správně klasifikovat vegetaci, kterou ve velké míře zaměňují za třídu holé půdy a vody.

Výstupy řízené klasifikace z měsíce září 2018 jsou zobrazeny na obrázku 19.



Obrázek 19: Řízená klasifikace září 2018 (Zdroj: vlastní)

Při vizuálním prozkoumání těchto snímků se dá říct, že techniky „Maximum Likelihood“ v obou softwarových prostředích v dobré míře klasifikují vegetaci na snímku, ale části vodní hladiny zaměňují právě za vegetaci a holou půdu. Obstojně klasifikují oblast břehové holé půdy. Naproti tomu tyto metody nedokázaly klasifikovat vodní hladinu v místě prolínání s pevninou v horní části snímku, což je patrné na referenčním snímku a snímku z ruční digitalizace zájmového území.

Klasifikátor „Minimum Distance“ zpravidla správně klasifikoval oblast vodní hladiny rybníka až na část okolo výpustě, která je klasifikována jako oblast vegetace. Část snímku, která byla ruční klasifikací určena jako vegetace, je touto metodou převážně klasifikována jako voda a holá půda. Tato metoda v uvedeném měsíci nejhůře detekovala vegetaci.

Na výstupu z techniky „Mahalanobis Distance“ je patrné, že tento klasifikátor nejlépe klasifikoval detaily vodní plochy rybníka správně jako vodu, čehož si můžeme všimnout v oblasti výpustě a v oblasti mísení holé půdy s vodou v horní části snímku. Tato metoda, ale klasifikovala oblast břehové holé půdy v levé části snímku jako vodu. Při klasifikování vegetace tato metoda správně klasifikovala nízkou vegetaci, ale vysokou vegetaci klasifikovala jako vodu.

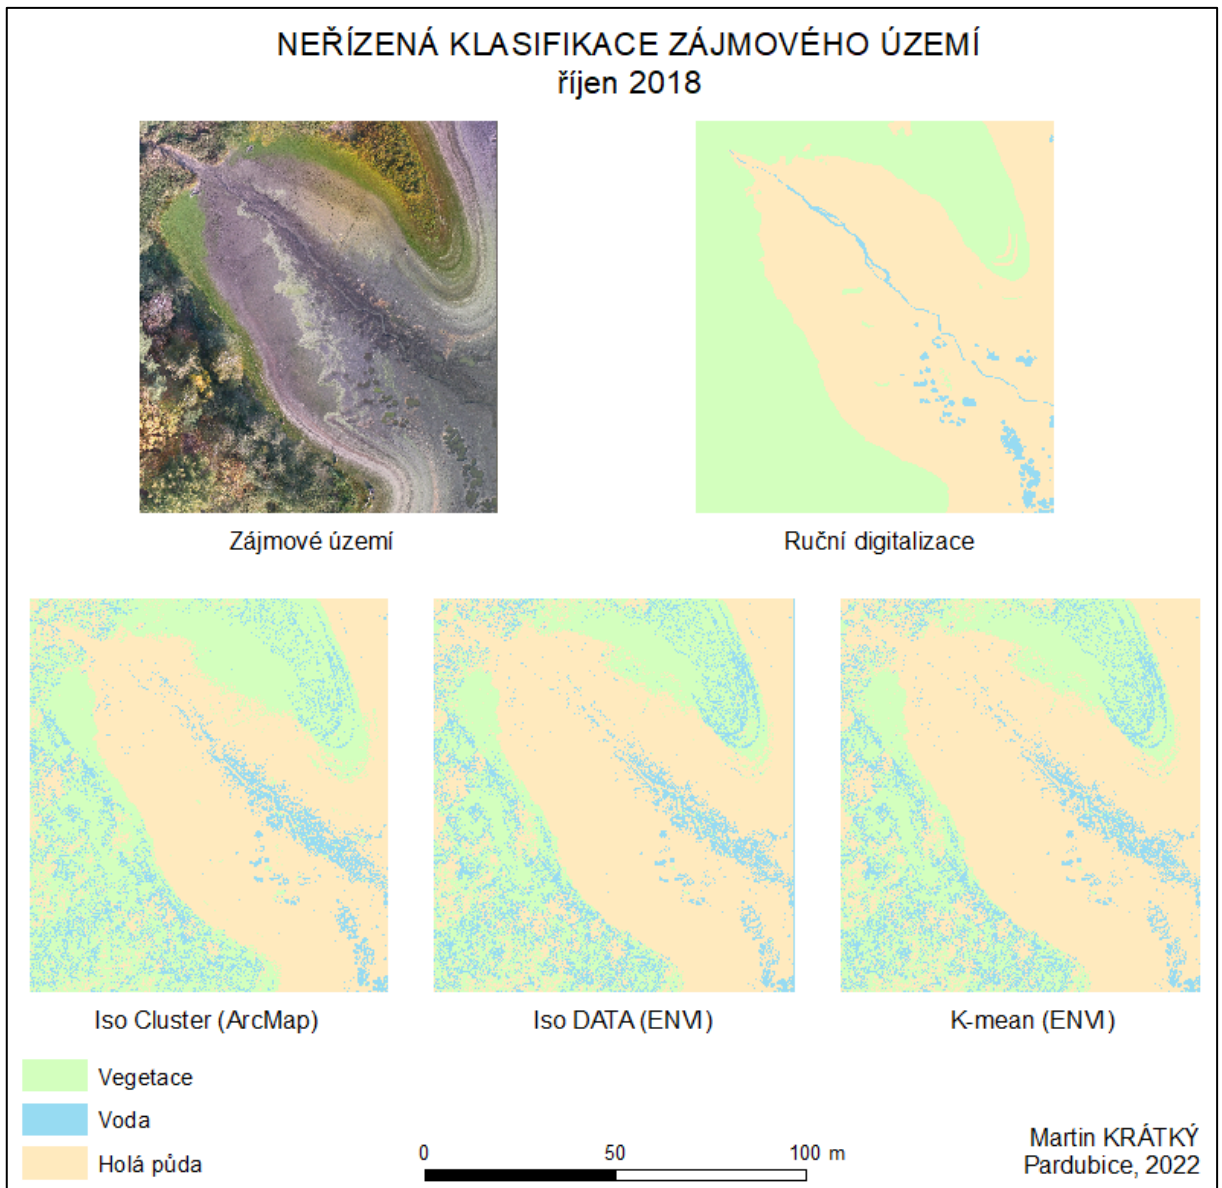
Metoda „Spectral Angle Mapper“ správně klasifikovala oblast výpustě rybníka jako vodní hladinu. Části vodní hladiny byly tímto klasifikátorem klasifikovány jako holá půda. Klasifikátor správně klasifikoval nízkou vegetaci, ale vysokou vegetaci klasifikoval v některých místech jako vodu a holou půdu.

Výstup z metody „SVM“ se vizuálně podobá výstupu z metod „Maximum Likelihood“. Tento klasifikátor v dobré míře klasifikoval vegetaci a holou půdu. Část vodní hladiny tato metoda klasifikovala jako vegetaci, a to i v případě oblasti výpustě rybníku. Této metodě se nepodařilo klasifikovat mísení vodní hladiny a holé půdy v břehové části snímku.

Dle vizuálního pozorování si v měsíci září s klasifikačním problémem rozlišení vody, holé půdy a vegetace nejlépe vedla metoda „Maximum Likelihood“, která měla obdobné výsledky z obou softwarových prostředí. Ale tato metoda nedokázala správně klasifikovat oblast výpustě rybníku a oblast mísení vody a holé půdy, což se podařilo metodě „Mahalanobis Distance“, která se jeví jako lepší metoda pro přesnou detekci větších vodních ploch. Některé výstupy ze softwaru ENVI nedokázaly klasifikovat všechny oblasti na snímku.

### 8.7.3 Klasifikace říjen 2018

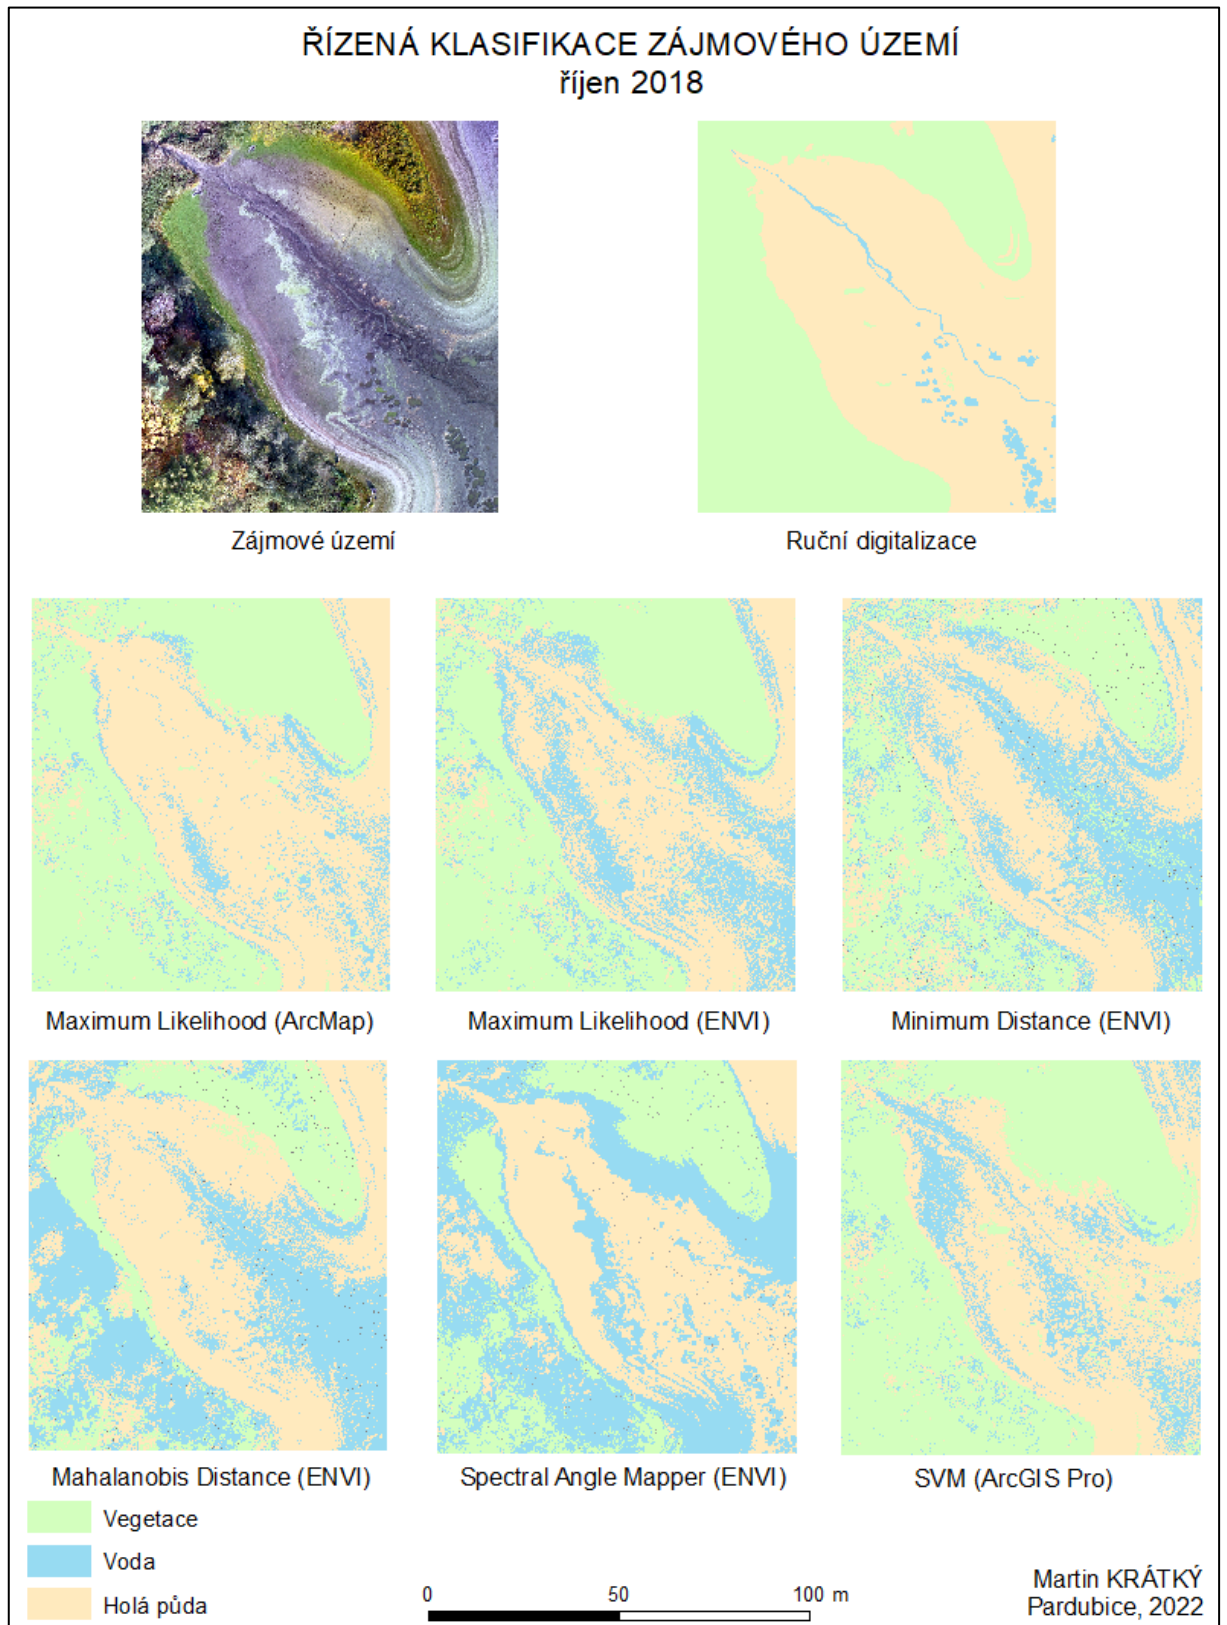
Výstupy neřízené klasifikace z měsíce října jsou zobrazeny na obrázku 20.



Obrázek 20: Neřízená klasifikace říjen 2018 (Zdroj: vlastní)

Reklasifikované výstupy ze všech klasifikačních metod podávají vizuálně obdobný výsledek. Podařilo se správně zobrazit plochu holé půdy v oblasti dna rybníka, ale těmito klasifikátorům se nepodařilo zachytit vodní koryto rybníku. Část vegetace v horní části snímku neodpovídá vizuálně výstupu z ruční klasifikace. Metodám se nepodařilo klasifikovat vegetaci v levé části snímku jako jednotnou oblast.

Řízená klasifikace snímku z měsíce října jednotlivými metodami je zobrazena na obrázku 21.



Obrázek 21: Řízená klasifikace říjen 2018 (Zdroj: vlastní)

Z ruční digitalizace a referenčního snímku zájmového území je patrné, že je v tomto období zastoupena třída vody v malé míře, a to pouze ve vymletém korytu a ve výmolech dna rybníku. Odstín zbarvení u těchto oblastí se výrazně podobá částem dna rybníka, který není pokryt vegetací. Klasifikátory „Maximum Likelihood“ klasifikovaly celistvou vegetaci. Výstup z prostředí ArcMap lépe klasifikoval holou půdu dna rybníka než výstup z prostředí ENVI, u kterého je mylně klasifikována oblast holé půdy jako voda. Obou výstupům se nepodařilo klasifikovat vodní koryto a v ojedinělých případech správně klasifikovaly menší oblasti vodních ploch. Vizuálně si v tomto měsíci s klasifikačním problémem nejlépe poradil software ArcMap.

V rámci výstupu z metody „Minimum Distance“ je větší plocha holé půdy chybně klasifikována jako voda. Metoda správně klasifikovala obrys oblasti vegetace, ale v některých místech dochází k záměně klasifikace za holou půdu.

Výstup z klasifikátoru „Mahalanobis Distance“ klasifikoval velkou část holé půdy jako vodu. Ani v tomto případě se nepodařilo správně klasifikovat vodní plochy. Stíny a tmavší odstíny vegetace z referenčního snímku byly touto metodou klasifikovány jako třída vody.

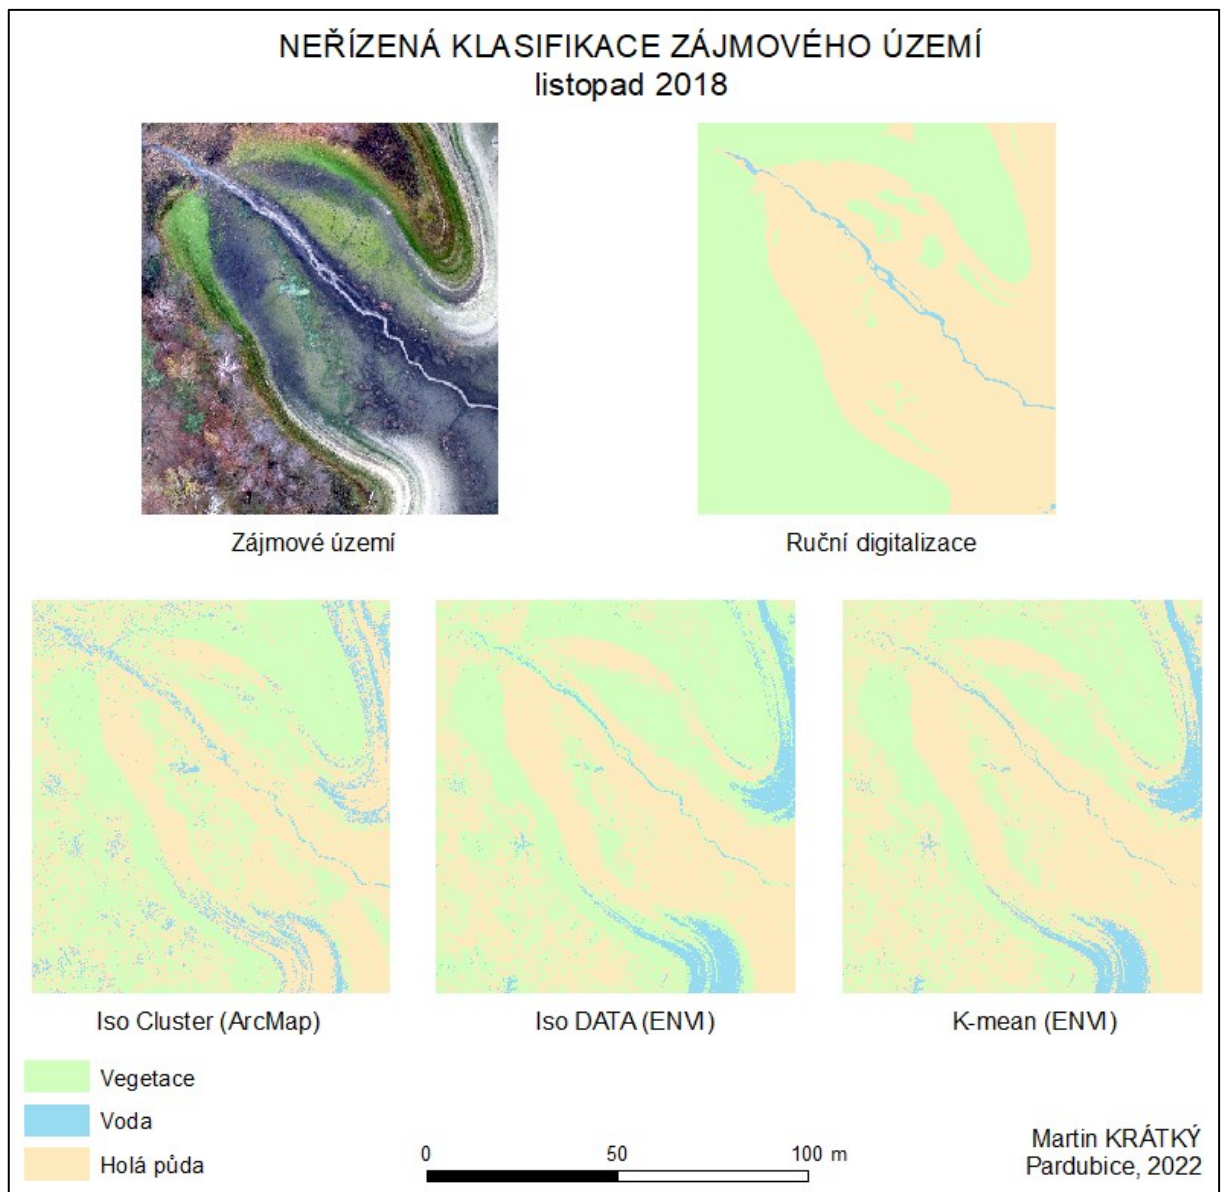
„Spectral Angle Mapper“ obdobně jako předchozí klasifikátor chybně klasifikoval vegetaci ve stínech jako vodní plochy. V rámci tohoto výstupu je pozorovatelné chybné klasifikování břehové holé půdy za třídu vody.

Klasifikátor „SVM“ dle pozorování správně klasifikoval oblast celistvé vegetace, ale obdobně jako výstupy z prvních uvedených metod klasifikoval část holé půdy v horní polovině snímku jako vegetaci. Ani v rámci tohoto klasifikátoru se nepodařilo klasifikovat vodní plochy v souladu s ruční digitalizací zájmového území.

Metodami řízené klasifikace se v tomto případě nepodařilo zachytit oblasti vody z referenčního snímku. Ve většině případů dochází k chybnému klasifikování této třídy s oblastmi vegetace a holé půdy. Po prozkoumání výše uvedených výstupů nejlépe klasifikují vegetaci klasifikátory „Maximum Likelihood“ v obou verzích a klasifikátor „Support Vector Machine“. Výstup, který se nejvíce podobá výsledkům odpovídajícím ruční digitalizaci je „Maximum Likelihood“ z prostředí ArcMap, který vizuálně nejméně chybně zatřídil vodní plochy a současně v dobré míře klasifikoval vegetaci na snímku. V rámci některých výstupů se nepodařilo klasifikovat všechny pixely snímku.

## 8.7.4 Klasifikace listopad 2018

Výstupy neřízené klasifikace z měsíce listopadu jsou zobrazeny na obrázku 22 níže.

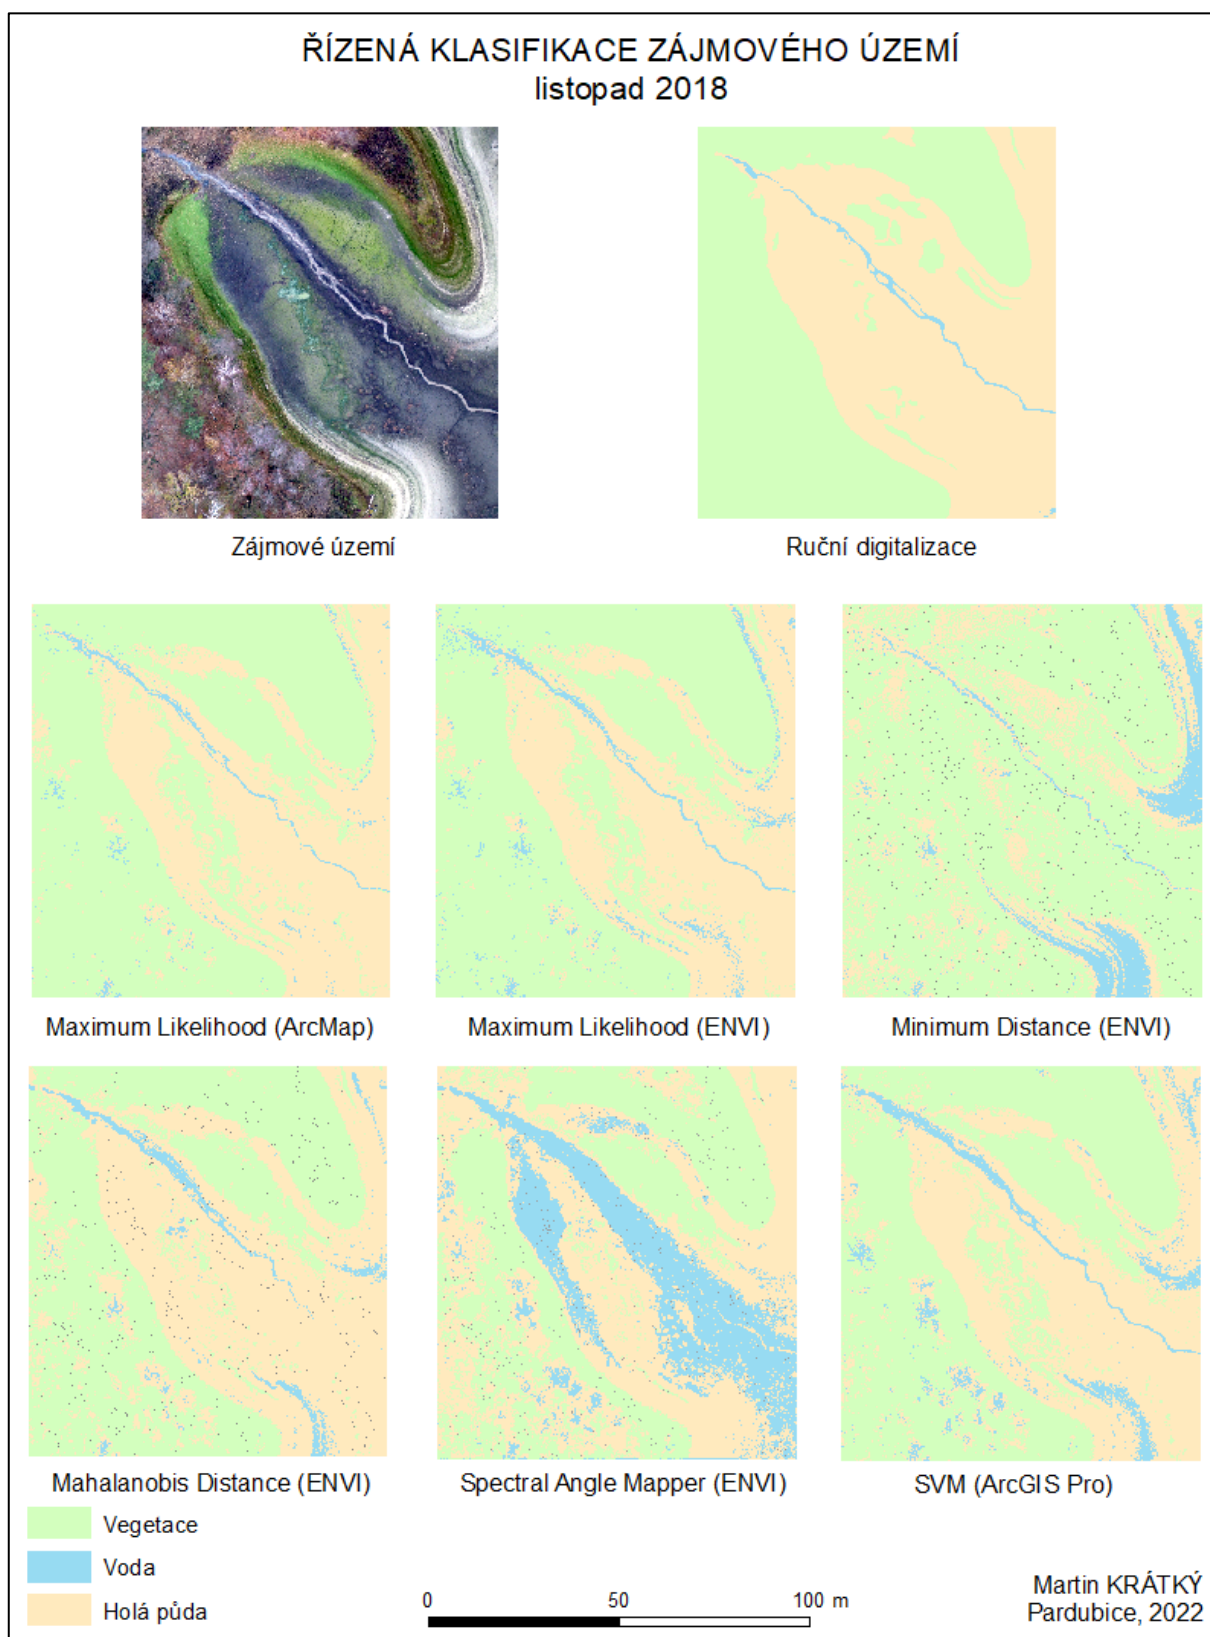


Obrázek 22: Neřízená klasifikace listopad 2018 (Zdroj: vlastní)

Je možné, že výsledky ruční a automatické neřízené klasifikace si nebudou odpovídat v rámci třídy vegetace, která je na referenčním snímku zastoupena v malé hustotě, a tedy ji bylo obtížné klasifikovat ručně. Klasifikátory neřízené klasifikace po provedení reklasifikace z 9 tříd do 3 správně klasifikují vodní koryto, ale na snímcích je nesprávně zastoupena třída vody v pravé horní a spodní části snímku. Metodám se nepodařilo klasifikovat vegetaci v levé části snímku jako jednotnou třídu.



Výstupy řízené klasifikace za měsíc listopad jsou zobrazeny na obrázku 23 níže.



Obrázek 23: Řízená klasifikace listopad 2018 (Zdroj: vlastní)

V rámci tohoto období byla velmi obtížná ruční klasifikace v důsledku malé hustoty zastoupení vegetace na referenčním snímku. Je tedy možné, že výsledky ruční a automatické klasifikace si nebudou odpovídat v rámci třídy vegetace. Výstupy klasifikačních metod klasifikace měsíce listopadu metodami „Maximum Likelihood“ se podařilo klasifikovat třídy vegetace, holé půdy a vody. Výstupy ze softwaru ArcMap i ENVI podávají vizuálně podobné výsledky. Na výstupech v oblasti vegetace byly holé koruny stromů klasifikovány jako voda. Metodám se podařilo klasifikovat zastoupení vody v oblasti koryta na dně rybníku.

Výstupu „Minimum Distance“ se podařilo klasifikovat vodní koryto, ale většinu dna rybníka tato metoda klasifikovala jako vegetaci. Dle prozkoumání všech výstupů měla tato metoda vizuálně nejhorší správnost klasifikování holé půdy.

Technika „Mahalanobis Distance“ správně klasifikovala oblast holé půdy a vegetace, ale nepodařilo se plně klasifikovat vodní tok v plné délce. V oblasti vegetace jsou místa klasifikována jako voda, přesněji v případech holých korun stromů. Taktéž byly vyhodnoceny zmíněné oblasti jako holá půda.

Výstup z „Spectral Angle Mapper“ chybně klasifikoval velkou oblast holé půdy jako vodu. Vegetace z referenčního snímku v levé polovině snímku je v rámci tohoto výstupu v některých oblastech klasifikována jako holá půda.

Klasifikátor „SVM“ správně klasifikoval oblasti vegetace a holé půdy. Holé koruny stromů v rámci této klasifikace byly klasifikovány jako třída voda. Některá místa dna rybníka byla zaměněna za vodní hladinu.

V souhrnu automatické klasifikace za měsíc listopad si vizuálně nejlépe vedl klasifikátor „Maximum Likelihood“, který správně klasifikoval souvislé oblasti klasifikovaných tříd. Tuto metodu následuje klasifikátor „SVM“. Vizuálně si s tímto klasifikačním problémem nejhůře poradila „Minimum Distance“, kde byla podstatná část holé půdy klasifikována jako vegetace, a metoda „Mahalanobis Distance“, kdy byly oblasti holé půdy mylně klasifikovány jako vodní plochy.

## 8.8 Porovnání ruční a automatické klasifikace


K určení úspěšnosti klasifikace byla použita matice záměn. K výpočtu této matice je třeba upravit data v ArcMapu. K tomu lze použít funkci, která se nachází v „ArcToolbox“ pod skupinou „Spatial Analyst Tools“ v podskupině „Segmentation and Classification“. Zde se využijí dva nástroje, a to „Create Accuracy Assessment Points“ a „Update Accuracy Assessment Points“.

V rámci nastavení funkce „Create Accuracy Assessment Points“ je třeba zvolit vstupní data. Dalším nastavením je cesta k uložení výstupu a volba přiřazování bodů. V tomto případě lze zvolit, zda se mají body přiřazovat do sloupce buď v atributové tabulce k referenčním datům, nebo ke klasifikačním datům. Důležitým bodem nastavení je počet náhodných bodů „Number of Random Points“, toto nastavení je v rámci výchozího nastavení na hodnotě 500. Posledním nastavením je volba generování bodů. Software ArcMap nabízí tři možnosti. Jedná se o „Stratified Random“, kde se v rámci této možnosti vygenerují body úměrně dle plochy klasifikační třídy. Při možnosti „Equalized Stratified Random“ budou náhodně vygenerované body rozděleny se stejným počtem v každé třídě. Poslední možností je volba „Random“, při které jsou vygenerované body náhodně rozmístěny po ploše vstupních dat.

K porovnání ruční a automatické klasifikace je třeba přiřadit třídy jednotlivých klasifikačních metod k dříve vytvořené bodové vrstvě s daty s ruční klasifikací. K tomuto účelu se využívá funkce „Update Accuracy Assessment Points“. Cesta k této funkci je popsána výše. V rámci tohoto nástroje je třeba zvolit vstupní data, tedy výsledek jednotlivých klasifikačních metod. Dalším krokem je vložení bodové vrstvy „Accuracy Assessment Points“, pro kterou budou provedeny změny. Posledními nastaveními jsou výběry výstupu dané funkce a výběr pole, pro které proběhne daná změna. Výstupem je nová bodová vrstva s aktualizovanou atributovou tabulkou dle zadaných parametrů.

Při prvním testování dané funkce bylo zvoleno vstupem této metody ručně zdigitalizované zájmové území. Počet náhodných bodů byl nastaven na výchozí hodnotu 500. S přihlédnutím k tomu, že v měsících říjnu a listopadu je zastoupení třídy vody malé v porovnání s ostatními třídami, byla zvolena metoda „Equalized Stratified Random“, aby v rámci těchto bodů byla zastoupena každá třída, což by se v případě náhodného vytvoření bodů metodou „Random“ nebo „Stratified Random“ nemuselo stát, nebo by tato třída byla zastoupena velmi zřídka. Výstupem je nová bodová vrstva s 500 náhodnými body pro každou třídu a novým záznamem v atributové tabulce, který představuje zařazení do třídy dle ruční klasifikace zájmového území.


Při volbě tohoto vstupu se náhodné body v rámci generační metody „Equalized Stratified Random“ a následně u zbylých generačních metod vyskytují především v blízkosti hran jednotlivých klasifikačních tříd. Výsledné porovnání ruční klasifikace a klasifikace různými metodami je ve výsledku takto vygenerovanými body zkreslené a není tedy vhodné k určení úspěšnosti jednotlivých klasifikačních metod. Tato skutečnost je zobrazena na obrázku 24, který představuje vygenerované body metodou „Random“ na zájmovém území z listopadu 2018.



Obrázek 24: Nesprávně vygenerované AAP (Zdroj: vlastní)

V dalším pokusu byl zvolen jako vstup ořez zájmového území, přesněji jeho jedno pásmo. Počet vygenerovaných náhodných bodů byl nastaven na 1000 a jejich distribuce byla zvolena metodou „Random“. Vygenerované náhodné body tímto způsobem mnohem lépe pokryly

oblast zájmového území, což je zobrazeno na obrázku 25. Takto vygenerované AAP byly následně použity k dalšímu zpracování.



Obrázek 25: Správně vygenerované AAP (Zdroj: vlastní)

Výsledná matice záměn byla vytvořena v prostředí Excel pro všechny klasifikační metody po exportu a importu dat z atributových tabulek jednotlivých datových souborů z ArcMapu.

K porovnání ruční a automatické klasifikace byl vypočten Kappa koeficient dle Sima a Wrighta (2005). Kappa koeficient představuje ukazatel přesnosti, který porovnává přesnost klasifikace s přesností náhodného zařazení pixelu, tedy shodu zařazení pixelů mezi zvolenými klasifikacemi. V rámci této publikace je definována síla tohoto koeficientu, která je rozdělena do šesti kategorií. Tato informace je zobrazena v tabulce 3 níže.

Tabulka 3: Síla Kappa koeficientu (Zdroj: Sim a Wright, 2005)

Hodnota	Síla
<0	Slabá
0–0,2	Nízká
0,21–0,4	Mírná
0,41–0,6	Střední
0,61–0,8	Významná
0,81–1	Téměř perfektní

K ověření výpočtu tohoto koeficientu byl jeho výpočet proveden i ve statistickém softwaru IBM SPSS Statistics. Při tomto testování shoda výsledků odpovídala ve všech testovaných případech. Ukázka ověření výpočtu pro klasifikaci snímku ze srpna 2018 a klasifikátoru „Maximum Likelihood“ z prostředí ENVI je zobrazena na obrázku 26.

<b>Ruční * Automatická Crosstabulation</b>					
Count		Automatická			Total
		Holá půda	Vegetace	Voda	
Ruční	Holá půda	129	19	4	152
	Vegetace	18	252	61	331
	Voda	9	20	488	517
Total		156	291	553	1000

<b>Symmetric Measures</b>					
		Value	Asymptotic Standard Error <sup>a</sup>	Approximate T <sup>b</sup>	Approximate Significance
Measure of Agreement	Kappa	,779	,018	32,943	,000
N of Valid Cases		1000			

Obrázek 26: Ověření výpočtu Kappa v IBM SPSS Statistics (Zdroj: vlastní)

Přehled výpočtu koeficientu Kappa dle ručního výpočtu pro neřízenou a řízenou klasifikaci je zobrazen v tabulce 4 a tabulce 5.

Tabulka 4: Kappa koeficient pro neřízenou klasifikaci (Zdroj: vlastní)

Měsíc	Neřízená klasifikace		
	ArcMap	ENVI	
	Iso Cluster	K-mean	IsoData
Srpen	0,608	0,557	0,557
Září	0,464	0,412	0,408
Říjen	0,599	0,531	0,531
Listopad	0,416	0,364	0,303

Tabulka 5: Kappa koeficient pro řízenou klasifikaci (Zdroj: vlastní)

Měsíc	Řízená klasifikace					
	ArcGIS Pro	ArcMap	ENVI			
	SVM	Maximum Likelihood	Maximum Likelihood	Minimum Distance	Mahalanobis Distance	Spectral Angle Mapper
Srpen	0,782	0,754	0,779	0,414	0,681	0,450
Září	0,740	0,786	0,789	0,423	0,644	0,571
Říjen	0,606	0,658	0,513	0,421	0,346	0,354
Listopad	0,677	0,723	0,707	0,123	0,740	0,371

Z vypočtených hodnot Kappa koeficientu je patrné, že metody řízené klasifikace představují lepší shodu mezi ruční klasifikací a klasifikací provedenou softwarem. Z obou testovaných softwarových prostředí se zejména jedná o klasifikátory „SVM“ a „Maximum Likelihood“. V měsíci listopadu 2018 měla dle tohoto koeficientu nejlepší shodu metoda „Mahalanobis Distance“.

V rámci porovnání klasifikací v měsíci srpnu měla největší shodu dle Kappa koeficientu metoda „SVM“ z prostředí ArcGIS Pro s hodnotou Kappa 0,782. Tato hodnota představuje významnou shodu. Shodně bylo zařazeno 870 náhodně vygenerovaných bodů (AAP) z tisíce, což představuje shodné zařazení ve výši 87 %. Chybová matice ruční digitalizace a automatické klasifikace je zobrazena v tabulce 6.

Tabulka 6: Chybová matice – srpen (Zdroj: vlastní)

Ruční klasifikace	Automatická klasifikace		
	Voda	Holá půda	Vegetace
Voda	473	7	37
Holá půda	7	113	32
Vegetace	37	10	284

Největší shodu v měsíci září měla klasifikační metoda „Maximum Likelihood“ ze softwaru ENVI s hodnotou Kappa koeficientu 0,789. Hodnota představuje významnou shodu. V rámci chybové matice bylo shodně zařazeno 876 bodů. Jedná se tedy o shodu v 88 %. Chybová matice ruční digitalizace a automatické klasifikace je zobrazena v tabulce 7.

Tabulka 7: Chybová matice – září (Zdroj: vlastní)

Ruční klasifikace	Automatická klasifikace		
	Voda	Holá půda	Vegetace
Voda	397	30	54
Holá půda	2	77	14
Vegetace	18	6	402

Porovnání klasifikací v měsíci říjnu zaznamenalo nejnižší hodnoty přesnosti mezi ruční a automatickou klasifikací. Nejlépe si v tomto měsíci dle Kappa koeficientu vedla metoda „Maximum Likelihood“ z prostředí ArcMap 10.5, která zaznamenala významnou hodnotu 0,658. V rámci této metody bylo shodně zařazeno 810 bodů a jedná se tedy o shodné zařazení v 81 % případů. Chybová matice ruční digitalizace a automatické klasifikace je zobrazena v tabulce 8.

Tabulka 8: Chybová matice – říjen (Zdroj: vlastní)

Ruční klasifikace	Automatická klasifikace		
	Voda	Holá půda	Vegetace
Voda	5	19	1
Holá půda	63	391	51
Vegetace	23	33	414

Největší shodu dle koeficientu Kappa v měsíci listopadu zaznamenal klasifikátor „Mahalanobis Distance“ s významnou hodnotou Kappa 0,74. V rámci porovnání ruční a automatické klasifikace bylo shoda v 86 % případů, shodně bylo zařazeno 864 bodů. Chybová matice ruční digitalizace a automatické klasifikace je zobrazena v tabulce 9.

Tabulka 9: Chybová matice – listopad (Zdroj: vlastní)

Ruční klasifikace	Automatická klasifikace			
	Neklasifikováno	Voda	Holá půda	Vegetace
Neklasifikováno	0	0	0	0
Voda	0	11	1	0
Holá půda	4	17	413	52
Vegetace	1	3	58	440



## 8.9 Interpretace výsledků

Na uvedených snímcích z období mezi srpnem a listopadem 2018 byly pozorovány změny zastoupení prvků vody, holé půdy a vegetace pomocí ruční a automatické klasifikace. V těchto uvedených měsících probíhalo vypouštění rybníka Skříň, které už započalo před prvním snímkováním, a je tedy zřetelně pozorovatelné snížení vodní hladiny a rozšiřování vegetace ve dříve zaplavených oblastech. V měsíci srpnu byla ruční klasifikací detekována voda o rozloze 5018 m<sup>2</sup> na vybraném zájmovém území. Dle nejshodnějšího klasifikátoru metodou „SVM“ byla naměřena rozloha této třídy na témže území 4913 m<sup>2</sup>. Rozloha břehové holé půdy v rámci ruční digitalizace byla zachycena na ploše 1351 m<sup>2</sup>. Pomocí automatické klasifikace byla třída holé půdy naměřena na ploše 1305 m<sup>2</sup>. Rozdíl mezi změřenou rozlohou vegetace je také minimální, a to v rámci ruční klasifikace 3327 m<sup>2</sup> a automatické klasifikace 3478 m<sup>2</sup>. V tomto měsíci podávají oba způsoby pozorování zastoupení tříd podobné výsledky.

V měsíci září pokračuje úbytek vodní hladiny, která byla pomocí ruční klasifikace vypočtena s plochou 4564 m<sup>2</sup>. Dle klasifikátoru „Maximum Likelihood“ byla tato třída zachycena na ploše 3892 m<sup>2</sup>. V tomto měsíci je nejvíce pozorovatelná změna rozšíření třídy vegetace na ploše holé půdy z předcházejícího měsíce. Zde byla změřena rozloha holé půdy o rozloze 1007 m<sup>2</sup> ruční klasifikací, respektive 1243 m<sup>2</sup> automatickou klasifikací. Vegetace se v tomto měsíci rozšířila na plochu změřenou ruční digitalizací 4124 m<sup>2</sup> a automatickou klasifikací 4561 m<sup>2</sup>.

Na snímku z měsíce října je zobrazen skoro vypuštěný rybník. V tomto měsíci byla obecně nejmenší shoda mezi ruční a automatickou klasifikací. Největší shodu dle koeficientu Kappa zaznamenala metoda „Maximum Likelihood“. Plocha třídy vody je na snímku zastoupena v malé míře a byla v tomto měsíci spočtena na rozlohu 204 m<sup>2</sup> ruční klasifikací a 907 m<sup>2</sup> automatickou klasifikací. Holá půda se rozkládá na ploše 5124 m<sup>2</sup>, respektive 4401 m<sup>2</sup> a třída vegetace o rozloze 4366 m<sup>2</sup> a 4386 m<sup>2</sup>.

V posledním měřeném měsíci listopadu byla voda zastoupena v minimální míře. Tato třída byla klasifikována ruční klasifikací o rozloze 92 m<sup>2</sup> a automatickou klasifikací klasifikátorem „Mahalanobis Distance“ o ploše 296 m<sup>2</sup>. Třída holé půdy je klasifikována o rozloze 4923 m<sup>2</sup> respektive 4736 m<sup>2</sup>. Poslední zastoupená třída vegetace je zastoupena shodně s rozlohou 4366 m<sup>2</sup> a 4386 m<sup>2</sup>.

Přehled rozloh vody, holé půdy a vegetace vypočtený z ruční a automatické klasifikace je zobrazen v tabulce 10 níže.

Tabulka 10: Rozloha ruční a automatické klasifikace (Zdroj: vlastní)

Měsíc	Rozloha klasifikace (m <sup>2</sup> )					
	Voda		Holá půda		Vegetace	
	Ruční	Automatická	Ruční	Automatická	Ruční	Automatická
Srpen	5018	4913	1351	1305	3327	3478
Září	4564	3892	1007	1243	4124	4561
Říjen	204	907	5124	4401	4366	4386
Listopad	92	296	4923	4736	4681	4608

## ZÁVĚR

Cílem diplomové práce bylo detekování změn v okolí malých vodních ploch za pomoci RGB snímků pořízených z bezpilotních prostředků.

Vstupními daty této práce byly mozaiky zájmového území rybníka Skříň pořízené ve čtyřech časových obdobích. Jednalo se o měsíce srpen, září, říjen a listopad roku 2018. V rámci těchto měsíců probíhalo vypouštění rybníka a byly pozorované změny v zastoupení třídy vody, holé půdy a vegetace. Snímky daného zájmového území byly pořízeny pomocí UAV DJI Phantom 3 v rámci pravidelného snímkování zájmové oblasti a následně byly z těchto snímků vytvořeny mozaiky.

V procesu přípravy dat byly dané mozaiky georeferencovány a následně byl proveden ořez zájmového území kvůli snížení výpočetní náročnosti dalších operací. Následně byla provedena ruční digitalizace zájmového území a vypočtena rozloha tříd vody, holé půdy a vegetace v jednotlivých měsících.

Dalším krokem bylo provedení automatické klasifikace pro jednotlivá zájmová území devíti klasifikátory. Třemi neřízenými a šesti řízenými v softwarových prostředích ArcGIS, ArcGIS Pro a ENVI. Výstupy v rámci neřízené klasifikace v měsíci říjnu a listopadu nesprávně klasifikovaly třídu vody kvůli jejímu malému zastoupení. Proto byla v rámci těchto měsíců vygenerována klasifikace s více třídami, které byly následně reklasifikovány do odpovídající podoby.

Vzniklé klasifikační výstupy jednotlivými metodami byly vizualizovány kartografickými metodami a následně okomentovány. Porovnání ruční a automatické klasifikace proběhlo pomocí automaticky vygenerovaných Accuracy Assessment Points a následným výpočtem Kappa koeficientu shody. V závěru práce byly vypočteny rozlohy nejshodnějšího automatického klasifikátoru s ruční klasifikací a následně byly tyto výsledky interpretovány formou textu a tabulek v příslušné kapitole.

Tato diplomová práce může sloužit jako postup pro zpracování dat získaných bezpilotními prostředky a pro jejich následnou vizualizaci a interpretaci.

## POUŽITÁ LITERATURA

1. ABBAS, A. W., N. MINALLH, N. AHMAD, S. A. R. ABID a M. A. A. KHAN, 2016. K-Means and ISODATA Clustering Algorithms for Landcover Classification Using Remote Sensing. *Sindh Universtiy Research Journal*. 48(2), 315-318 [cit. 2022-04-01]
2. AL-NAJJAR, Husam A. H., Bahareh KALANTAR, Biswajeet PRADHAN, Vahideh SAEIDI, Alfian Abdul HALIN, Naonori UEDA a Shattri MANSOR, 2019. Land Cover Classification from fused DSM and UAV Images Using Convolutional Neural Networks. *Remote Sensing*. 11(12). ISSN 2072-4292. Dostupné z: doi:10.3390/rs11121461
3. CAMPBELL, James B. a Randolph H. WYNNE, 2011. *Introduction to Remote Sensing*. 5th ed. Guilford Press, 667 s. ISBN 9781609181765.
4. ČESKO, Zákon č. 114/1992 Sb., Zákon o ochraně přírody a krajiny, 1992. In: *Sbírka zákonů České republiky*. částka 28. Dostupné také z: [https://www.mzp.cz/www/platnalegislativa.nsf/58170589E7DC0591C125654B004E91C1/%24file/z114\\_1992.pdf](https://www.mzp.cz/www/platnalegislativa.nsf/58170589E7DC0591C125654B004E91C1/%24file/z114_1992.pdf)
5. ČÚZK, © 2022. ČÚZK: *Geoportál* [online]. [cit. 2022-04-01]. Dostupné z: [https://geoportal.cuzk.cz/\(S\(oo0xqdrea1hgpyaomgwzdgla\)\)/Default.aspx?head\\_tab=sekc e-00-gp&mode=TextMeta&text=uvod\\_uvod&menu=01&news=yes&UvodniStrana=yes](https://geoportal.cuzk.cz/(S(oo0xqdrea1hgpyaomgwzdgla))/Default.aspx?head_tab=sekc e-00-gp&mode=TextMeta&text=uvod_uvod&menu=01&news=yes&UvodniStrana=yes)
6. DALY, David, © 2012-2021. A Not-So-Short History of Unmanned Aerial Vehicles (UAV). In: *Consortiq* [online]. [cit. 2021-11-23]. Dostupné z: <https://consortiq.com/short-history-unmanned-aerial-vehicles-uavs/>
7. DJI. Phantom 3 Standard. In: *DJI.com* [online]. © 2022 [cit. 2022-04-01]. Dostupné z: <https://www.dji.com/cz/phantom-3-standard>
8. DOBROVOLNÝ, Petr, 1998. *Dálkový průzkum Země: digitální zpracování obrazu*. Brno: Masarykova univerzita. ISBN 80-210-1812-7
9. DRONETHUSIAST, © 2014-2021. The History Of Drones: Drone History Timeline From 1849 To 2019. In: *Dronethusiast* [online]. [cit. 2022-04-01]. Dostupné z: <https://www.dronethusiast.com/history-of-drones/>

10. DU, Baojia, Dehua MAO, Zongming WANG, Zhiqiang QIU, Hengqi YAN, Kaidong FENG a Zhongbin ZHANG, 2021. Mapping Wetland Plant Communities Using Unmanned Aerial Vehicle Hyperspectral Imagery by Comparing Object/Pixel-Based Classifications Combining Multiple Machine-Learning Algorithms. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 14, 8249-8258. ISSN 1939-1404. Dostupné z: doi:10.1109/JSTARS.2021.3100923
11. ENVI, © 2022. *L3Harris Geospatial* [online]. [cit. 2022-04-01]. Dostupné z: <https://www.l3harrisgeospatial.com/Software-Technology/ENVI>
12. ENVIROMINE, INC., c 2012-2016. The Pros & Cons of UAV's vs. Airplanes for Aerial Mapping. In: *EnviroMINE, Inc.* [online]. March 16, 2017 [cit. 2022-04-01]. Dostupné z: <http://www.enviromineinc.com/blog/2017/3/15/the-pros-cons-of-uavs-vs-airplanes-for-aerial-mapping>
13. GETTINGER, Dan, 2019. *The Drone Databook* [online]. The Center for the Study of the Drone at Bard College [cit. 2022-04-01]. Dostupné z: <https://dronecenter.bard.edu/projects/drone-proliferation/databook/>
14. HALOUNOVÁ, Lena a Jiří PAVELKA, 2008. *Dálkový průzkum Země*. 3. Praha: ČVUT, 182 s. ISBN 978-80-01-03124-7
15. HORÁK, Jiří, 2014. *Dálkový průzkum Země*. Ostrava: VŠB-TU Ostrava, 137 s.
16. HSUAN, Wu Ching, Liang Sheng HAO a Yeh Ching KUO, 2018. Recognition of rice damage area on UAV ortho-images. *2018 IEEE International Conference on Applied System Invention (ICASI)*. IEEE, 2018, 1092-1094. ISBN 978-1-5386-4342-6. Dostupné z: doi:10.1109/ICASI.2018.8394470
17. Icaros: Remote Sensing Solution, © 2022. *Icaros* [online]. [cit. 2022-04-01]. Dostupné z: <https://icarosgeospatial.com/>
18. Index: Normalized Difference MIR/NIR Normalized Difference Vegetation Index (in case of strong atmospheric disturbances), © 2011-2022. In: *Index DataBase: A database for remote sensing indices* [online]. [cit. 2022-04-01]. Dostupné z: <https://www.indexdatabase.de/db/i-single.php?id=59>

19. KARAS, Jakub, 2017. *222 tipů a triků pro drony*. 3rd ed. Brno: Computer Press. ISBN 978-80-251-4874-7.
20. KOLÁŘ, Jan, Lena HALOUNOVÁ a Karel PAVELKA, 1997. *Dálkový průzkum Země 10*. Praha: České vysoké učení technické. ISBN 80-010-1567-X.
21. KREPS, Sarah, 2016. *Drones: What Everyone Needs To Know*. New York: Oxford University Press, 200 s. ISBN 978-0-19-023535-2
22. LAW, Michael a Amy COLLINS, 2016. *Getting to know ArcGIS Pro*. Redlands, California: Esri Press. ISBN 978-158-9484-573.
23. LILLESAND, Thomas M., Ralph W. KIEFER a Jonathan W. CHIPMAN, 2008. *Remote sensing and image interpretation*. 6th ed. Hoboken, NJ: John Wiley. ISBN 978-0-470-05245-7
24. LIPSKÝ, Zdeněk, 2010. Kam se ubírá česká krajina. *Present Trends in Development of the Czech Rural Landscape*). *Geographia Cassoviensis IV. č. 2*: 77-83. Dostupné z: [https://uge-old.science.upjs.sk/images/geographia\\_cassoviensis/articles/GC-2010-4-2/14Lipsky\\_a.pdf](https://uge-old.science.upjs.sk/images/geographia_cassoviensis/articles/GC-2010-4-2/14Lipsky_a.pdf)
25. LIU, Jian Guo a Philippa J. MASON, 2009. *Essential Image Processing and GIS for Remote Sensing*. NJ: John Wiley, 443 s. ISBN 9781118687963.
26. LONGLEY, Paul, Goodchild MICHAEL, Maguire DAVID a Rhind DAVID, 2011. *Geographic Information Systems and Science*. 3rd ed. Hoboken: Wiley, 560 s. ISBN 978-0-470-72144-5
27. MAJER, Dušan. Elektromagnetické spektrum. *Kosmonautix.cz* [online]. 27. února 2019 [cit. 2022-04-01]. Dostupné z: <https://kosmonautix.cz/2019/02/komunikace-pres-paprsky-x/spektrum/>
28. MENDES DOS SANTOS, Luana, Gabriel Araujo e Silva FERRAZ, Brenon Diennevan de Souza BARBOSA, Adriano Valentim DIOTTO, Marco Thulio ANDRADE, Leonardo CONTI a Giuseppe ROSSI, 2020. Determining the Leaf Area Index and Percentage of Area Covered by Coffee Crops Using UAV RGB Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 13, 6401-6409. ISSN 1939-1404. Dostupné z: doi:10.1109/JSTARS.2020.3034193

29. ODDI, Ludovica, Edoardo CREMONESE, Lorenzo ASCARI, Gianluca FILIPPA, Marta GALVAGNO, Davide SERAFINO a Umberto Morra di CELLA, 2021. Using UAV Imagery to Detect and Map Woody Species Encroachment in a Subalpine Grassland: Advantages and Limits. *Remote Sensing*. 13(7). ISSN 2072-4292. Dostupné z: doi:10.3390/rs13071239
30. OMNISCI, INC., © 2021. *Remote Sensing Definition* [online]. [cit. 2022-04-01]. Dostupné z: <https://www.omnisci.com/technical-glossary/remote-sensing>
31. PRICE, Maribeth Hughett, 2015. *Mastering ArcGIS*. Seventh Edition. McGraw-Hill, 624 s. ISBN 978-0-07-809514-6.
32. QUINN, James W., © 2001. *Band Combinations* [online]. [cit. 2022-04-01]. Dostupné z: [http://www.web.pdx.edu/~nauna/resources/10\\_BandCombinations.htm](http://www.web.pdx.edu/~nauna/resources/10_BandCombinations.htm)
33. RICHARDS, John A., 2013. *Remote Sensing Digital Image Analysis: An Introduction*. 5th ed. Springer, Berlin, Heidelberg, 494 s. ISBN 978-3-642-30061-5.
34. SIM, Julius a Chris C WRIGHT, 2005. The Kappa Statistic in Reliability Studies: Use, Interpretation, and Sample Size Requirements. *Physical Therapy*. 85(3), 257-268. ISSN 0031-9023. Dostupné z: doi:10.1093/ptj/85.3.257
35. SONG, Bonggeun a Kyunghun PARK, 2020. Detection of Aquatic Plants Using Multispectral UAV Imagery and Vegetation Index. *Remote Sensing*. 12(3). ISSN 2072-4292. Dostupné z: doi:10.3390/rs12030387
36. SVATOŇOVÁ, Hana a Lubomír LAUERMAN, 2010. *Dálkový průzkum Země – aktuální zdroj geografických informací*. Brno: Masarykova univerzita. ISBN 978-80-210-5162-1
37. SYLVESTER, Gerard, ed., 2018. *E-AGRICULTURE IN ACTION: DRONES FOR AGRICULTURE*. Bangkok: Food and Agriculture Organization of the United Nations and International Telecommunication Union. ISBN 978-92-5-130246-0s
38. TSO, Brandt a Paul M. MATHER, 2009. *Classification methods for remotely sensed data*. London: CRC Press, 352 s. 2nd ed. ISBN 978-1-4200-9072-7.

39. VALAVANIS, Kimon P. a George J. VACHTSEVANOS, ed. *Handbook of Unmanned Aerial Vehicles* [online]. Dordrecht: Springer Netherlands, 2015 [cit. 2022-04-01]. DOI: 10.1007/978-90-481-9707-1. ISBN 978-90-481-9706-4
40. WAEPONS AND WARFARE, 2021. Siege of Venice (August 1848 – August 27, 1849). In: *Weapons and Warfare: History and Hardware of Warfare* [online]. July 12, 2021 [cit. 2022-04-01]. Dostupné z: <https://weaponsandwarfare.com/2021/07/12/siege-of-venice-august-1848-august-27-1849/>
41. WEIER, John a David HERRING, 2000. Measuring Vegetation (NDVI & EVI). In: *Earth Observatory* [online]. NASA [cit. 2021-12-18]. Dostupné z: <https://earthobservatory.nasa.gov/features/MeasuringVegetation>
42. WICAKSONO, A a R HERNINA, 2021. Urban tree analysis using unmanned aerial vehicle (uav) images and object-based classification (case study: university of indonesia campus). *IOP Conference Series: Earth and Environmental Science*. 683(1). ISSN 1755-1307. Dostupné z: doi:10.1088/1755-1315/683/1/012105
43. Zákon č. 114/1992 Sb., o ochraně přírody a krajiny §3 odst1 písm. m).



# **PŘÍLOHY**

Příloha A Digitalizace zájmového území

DIGITALIZACE ZÁJMOVÉHO ÚZEMÍ  
v roce 2018


Srpen



Září



Říjen



Listopad



Martin Krátký  
Pardubice 2022