

UNIVERZITA PARDUBICE

FAKULTA EKONOMICKO-SPRÁVNÍ

DIPLOMOVÁ PRÁCE

2024

Bc. Pavel Poskočil

Univerzita Pardubice  
Fakulta ekonomicko-správní

Využití RGB obrazových dat pro monitoring vodních ploch  
Diplomová práce

Univerzita Pardubice  
Fakulta ekonomicko-správní  
Akademický rok: 2023/2024

# ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Bc. Pavel Poskočil**  
Osobní číslo: **E22640**  
Studijní program: **N0688A140007 Informatika a systémové inženýrství**  
Specializace: **Infomační a bezpečnostní systémy**  
Téma práce: **Využití RGB obrazových dat pro monitoring vodních ploch**  
Zadávací katedra: **Ústav systémového inženýrství a informatiky**

## Zásady pro vypracování

Cílem práce je využití a analýza RGB snímků s velmi vysokým prostorovým rozlišením získaných z UAV pro identifikaci vodních ploch, které mohou být využity pro bezpečnostní monitoring. Student v rámci sledované zájmové oblasti projde celý proces zpracování obrazových dat včetně navržení vhodného postupu. Práce bude zahrnovat i vizualizaci a zhodnocení dosažených výsledků.

Osnova:

- Dálkový průzkum Země.
- Digitální zpracování obrazu.
- Současný stav řešené problematiky.
- Charakteristika zájmového území.
- Vlastní zpracování dat, včetně vizualizace a zhodnocení výsledků.

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

Seznam doporučené literatury:

DOBROVOLNÝ, Petr. *Dálkový průzkum Země: digitální zpracování obrazu*. 1998. Brno: Masarykova univerzita, 1998. ISBN 80-210-1812-7.  
HALOUNOVÁ, Lena a PAVELKA, Karel. *Dálkový průzkum Země*. V Praze: Česká technika – nakladatelství ČVUT, 2005. ISBN 80-01-03124-1.  
JENSEN, John R. *Remote sensing of the environment: an earth resource perspective*. 2nd ed. Prentice-Hall series in geographic information science. Upper Saddle River: Pearson/Prentice Hall, c2007. ISBN 0-13-188950-8.  
LILLESAND, Thomas M.; KIEFER, Ralph W. a CHIPMAN, Jonathan W. *Remote sensing and image interpretation*. Seventh edition. Hoboken, N.J.: John Wiley & Sons, 2015. ISBN 978-1-118-34328-9.

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

Datum zadání diplomové práce: **1. září 2023**  
Termín odevzdání diplomové práce: **30. dubna 2024**

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

L.S.

**prof. Ing. Jitka Komárková, Ph.D.** v.r.  
garant studijního programu

V Pardubicích dne 1. září 2023

Prohlašuji:

Práci s názvem: „*Využití RGB obrazových dat pro monitoring 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 29. 4. 2024

Bc. Pavel Poskočil v.r.

## **PODĚKOVÁNÍ**

Tímto bych chtěl poděkovat paní prof. Jitce Komárkové Ph.D. za cenné rady v souvislosti s řešenou problematikou, její ohleduplnost, trpělivost a věnovaný čas v průběhu vypracování této diplomové práce.

## **ANOTACE**

Diplomová práce se zabývá analýzou RGB obrazových dat pořízených z bezpilotních leteckých prostředků. Obsahem diplomové práce je teoretický popis dálkového průzkumu Země, digitálního zpracování obrazových záznamů a posouzení současné problematiky. Praktická část zahrnuje využití různých metod digitálního zpracování obrazu, především zaměřených na provedení automatické klasifikace pro vytvoření tematických map zemského povrchu a jejich hodnocení.

## **KLÍČOVÁ SLOVA**

Dálkový průzkum Země, RGB obrazová data, UAV, digitální zpracování obrazu ,automatická klasifikace.

## **TITLE**

Using of RGB images for monitoring water bodies

## **ANNOTATION**

This master thesis describe a analysis of RGB imagery from unmanned aerial vehicles. Content of master thesis is theoretical description of remote sensing, digital image processing and assessment of current state. The practical part includes the use of various digital image processing methods, mainly focused on performing automatic classification to create thematic maps of the Earth's surface and their evaluation.

## **KEYWORDS**

Remote sensing, RGB imagery, UAV, digital image processing, automatic classification.

# OBSAH

SEZNAM ILUSTRACÍ A TABULEK .....	10
SEZNAM ZKRATEK A ZNAČEK.....	12
ÚVOD .....	13
1 DÁLKOVÝ PRŮZKUM ZEMĚ.....	14
2 DIGITÁLNÍ ZPRACOVÁNÍ OBRAZU .....	16
2.1 Digitální RGB obrazový záznam .....	16
2.2 Předzpracování .....	18
2.3 Zvýraznění.....	18
2.4 Klasifikace.....	21
2.5 Postklasifikační úpravy .....	23
2.6 Hodnocení přesnosti automatické klasifikace .....	24
3 MOMENTÁLNÍ STAV ŘEŠENÉ PROBLEMATIKY .....	26
4 IDENTIFIKACE VODNÍCH PLOCH S VYUŽITÍM RGB SNÍMKŮ.....	31
4.1 Výběr softwarového nástroje .....	33
4.2 Charakteristika sledovaného území a vstupní obrazové záznamy .....	34
4.3 Vymezení zájmové oblasti sledovaného území .....	36
4.4 Vytvoření referenční datové vrstvy .....	37
4.5 Vytvoření kontrolních bodů pro vyhodnocení přesnosti.....	41
4.6 Zvýraznění množství informace v obrazových datech.....	43
4.7 Neřízená klasifikace .....	44
4.8 Příprava trénovacích dat pro provedení řízené klasifikace .....	46
4.9 Řízená klasifikace .....	54
4.10 Posouzení výsledků využitých klasifikátorů .....	59
4.11 Vyhodnocení použité metriky založené na kontrolních bodech .....	63
4.12 Postklasifikační úpravy .....	65
4.13 Výsledné zhodnocení dosažených výsledků .....	68
ZÁVĚR.....	70



POUŽITÁ LITERATURA.....	72
SEZNAM PŘÍLOH.....	75

## SEZNAM ILUSTRACÍ A TABULEK

Obrázek 1 - Systém dálkového průzkumu Země .....	14
Obrázek 2 - Spektrum elektromagnetického záření .....	15
Obrázek 3 - Digitální obrazový záznam.....	16
Obrázek 4 - Radiometrické rozlišení.....	17
Obrázek 5 - Prahování obrazového záznamu .....	19
Obrázek 6 - Vysoká a nízká prostorová frekvence .....	19
Obrázek 7 - Barevný prostor RGB a HSV .....	20
Obrázek 8 - Tematická mapa .....	21
Obrázek 9 - Hluboké učení ve spojení s dálkovým průzkumem Země .....	23
Obrázek 10 - Ukázka aplikování majoritního filtru v detailu na úrovni pixelů.....	23
Obrázek 11 - Schéma vlastního zpracování .....	31
Obrázek 12 - Software ArcGIS Pro.....	33
Obrázek 13 - Umístění sledovaného území.....	34
Obrázek 14 - Terénní průzkum sledovaného území.....	35
Obrázek 15 - Vymezení zájmové oblasti .....	36
Obrázek 16 - Ruční identifikace první úrovně výřezu 1 .....	38
Obrázek 17 - Výřez 1 v jiných barvách zobrazení .....	38
Obrázek 18 - Postupné prahování .....	40
Obrázek 19 - Vygenerování kontrolních bodů do výřezu 1 .....	42
Obrázek 20 - Ukázka aplikování RGB vegetačních indexů pro výřez 1 .....	44
Obrázek 21 - Ukázka aplikování RGB vegetačních indexů pro výřez 1 .....	44
Obrázek 22 - Neřízená klasifikace Iso Cluster.....	45
Obrázek 23 - Dekompozice hlavních sledovaných tříd v rámci řízené klasifikace .....	46
Obrázek 24 - Trénovací plochy výřezu 1 v pravých barvách.....	47
Obrázek 25 - Podtřídy půdního pokryvu.....	48
Obrázek 26 - Podtřídy suchého travního porostu.....	49
Obrázek 27 - Podtřídy vodní plochy .....	50
Obrázek 28 - Spektrální profil trénovacích ploch výřezu 1 v pravých barvách.....	51
Obrázek 29 - Proces reklasifikace .....	51
Obrázek 30 - Trénovací plochy výřezu 1 v indexu TGI .....	52
Obrázek 31 - Spektrální profil výřezu 1 v indexu TGI .....	53

Obrázek 32 - Klasifikace Maximum Likelihood.....	55
Obrázek 33 - Klasifikátor Support Vector Machine .....	56
Obrázek 34 - Klasifikace Random Trees .....	57
Obrázek 35 - Klasifikace K-Nearest Neighbor .....	58
Obrázek 36 - Graf celkové přesnosti jednotlivých výsledků .....	59
Obrázek 37 - Graf Kappa koeficientu jednotlivých výsledků.....	60
Obrázek 38 - Chybová mapa klasifikace Maximum Likelihood výřezů v pravých barvách ...	62
Obrázek 39 - Chybová mapa klasifikace Iso Cluster výřezů v indexu TGI.....	62
Obrázek 40 - Vnořený FOR cyklus.....	64
Obrázek 41 - Výpočet celkové přesnosti a Kappa koeficientu .....	64
Obrázek 42 - Ukázka porovnání metrik .....	65
Obrázek 43 - Export a import CSV souborů .....	67
Obrázek 44 - Graf procentuálního zastoupení sledovaných povrchu .....	69
Tabulka 1 - Chybové matice .....	24
Tabulka 2 - Interpretace výsledku Kappa koeficientu .....	25
Tabulka 3 - Porovnání správně klasifikovaných pixelů před a po majoritní filtraci.....	67
Tabulka 4 - Rozloha sledovaných povrchů .....	69
Rovnice 1 - Vegetační index NDVI .....	20
Rovnice 2 - Kappa koeficient.....	25
Rovnice 3 - Index TGI .....	43
Rovnice 4 - Index NGRDI .....	43
Rovnice 5 - Index ExGI .....	43

## SEZNAM ZKRATEK A ZNAČEK

CNN	– Konvoluční neuronová síť
CPU	– Central Processing Unit
DPZ	– Dálkový průzkum Země
DT	– Decision Tree
ExG	– Normalized Excess Green Index
ExGI	– Excess Green Index
GLI	– Green Leaf Index
GPU	– Graphics Processing Unit
KNN	– K-Nearest Neighbor
MExG	– Modified Excess Green
MGRVI	– Modified Green Red Vegetation Index
ML	– Maximum Likelihood
NGRDI	– Normalized Green-Red Difference Index
RF	– Random Forest
RGB	– Red, Green, Blue
RGBVI	– Red Green Blue Vegetation Index
RT	– Random Trees
SVM	– Support Vector Machine
TGI	– Triangular Greenness Index
UAV	– Bezpilotní letecký prostředek
VARI	– Visible Atmospheric Resistant Index

## ÚVOD

V současné době představuje dálkový průzkum Země rozsáhlý vědní obor, který svou činností podstatně přispívá do jiných oborů každodenních lidských aktivit. Data dálkového průzkumu Země a získané informace z nich hrají významnou roli například v zemědělství pro sledování stavu vegetace.

Významnou roli také hrají jako součást informačních a bezpečnostních systémů pro potřeby záchranných složek, například při přírodních katastrofách za účely monitorování zemětřesení, povodní nebo lesních požárů. Jejich široké využití lze také sledovat v armádní sféře, například pro monitorování průchodnosti terénu (detekce vodních těles, mokřad a podobně). K těmto účelům se využívají zejména obrazové záznamy získané z bezpilotních leteckých prostředků (UAV), které jsou následně zpracovávány a vyhodnoceny. V této souvislosti hraje jednu z klíčových rolí právě zmíněné zpracování nashromážděných dat.

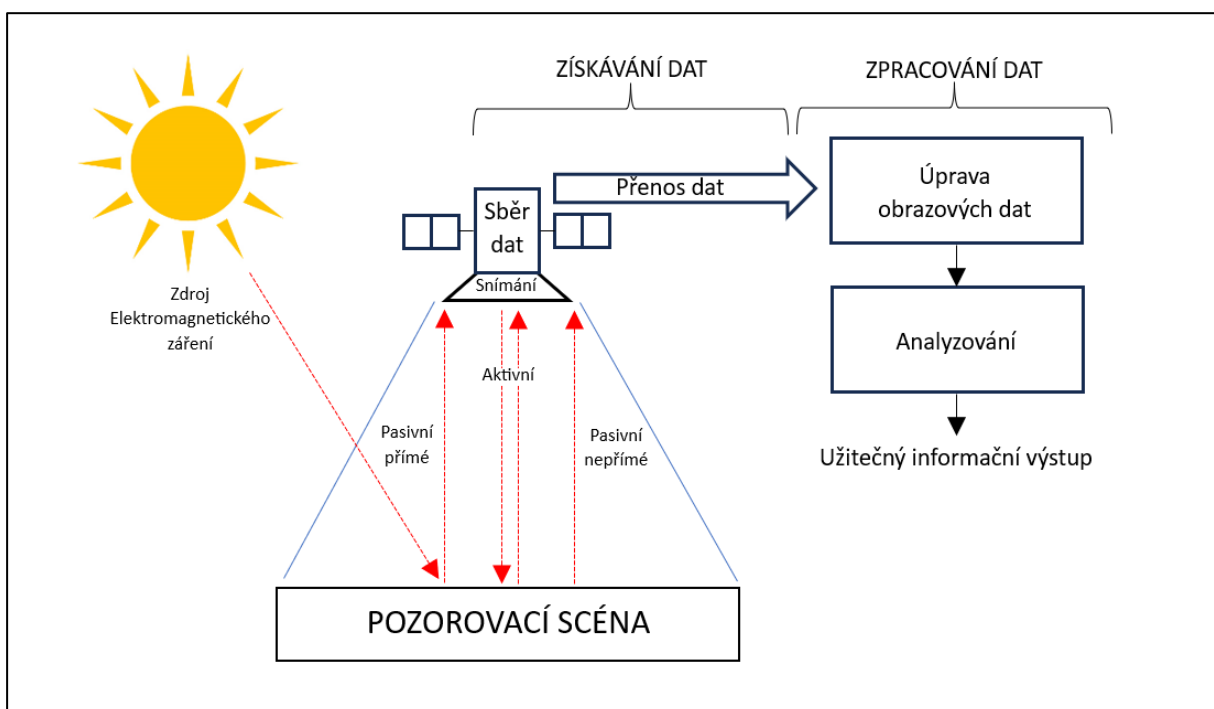
Cílem práce je zpracování a následné vyhodnocení krajinného pokryvu s využitím RGB obrazových dat o vysokém prostorovém rozlišení získaných prostřednictvím bezpilotních dronů. RGB obrazové záznamy jsou snímky zachycující zemský povrch pouze ve vlnových délkách viditelné části spektra. Absence jiných vlnových délek, které by detailněji vypovídaly o zemském povrchu, představuje v této oblasti z pohledu zpracování a následné analýzy skutečnou výzvu. Ačkoliv moderní technologie dovolují u UAV využití i jiných částí spekter, jako například infračervenou část spektra. Tato možnost je stále v porovnání s UAV pracující v režimu snímání viditelného spektra finančně nákladnější.

První kapitola této práce je věnována teoretickému úvodu do dálkového průzkumu Země. S dálkovým průzkumem Země je v dnešní době úzce spjat i jiný obor informačních technologií, a tím je digitální zpracování obrazu. Právě digitálnímu zpracování obrazu je věnována druhá kapitola. Následující kapitola se zabývá posouzením momentálního stavu řešené problematiky ve formě rešerše studií a akademických článků. Čtvrtá kapitola již řeší vlastní zpracování RGB obrazových dat a zachycuje celý tento proces v rámci stanoveného území. Poslední, pátá kapitola zhodnocuje dosažené výsledky v rámci celého procesu zpracování s následnou analýzou povrchu sledované oblasti.

# 1 DÁLKOVÝ PRŮZKUM ZEMĚ

Dálkový průzkum Země (DPZ) můžeme definovat jako získávání dat o zemském povrchu za využití snímacích zařízení a následného extrahování užitečných informací z těchto dat, kde je samotný proces získávání zprostředkován distančně, tedy bez fyzického kontaktu se zemským povrchem. (Lillesand, 2015)

Podle zmíněné úvodní definice můžeme hovořit o dvou hlavních činnostech, které DPZ představuje. Jedná se o získávání (sběr a přenos) dat a následné zpracování (úprava a analyzování) pořízených dat pro získání výstupní užitečné informace. Tento proces popisuje v obecné úrovni obrázek 1. (Lillesand, 2015)




Obrázek 1 - Systém dálkového průzkumu Země

*Zdroj: Vlastní zpracování podle (Canada Centre for Remote Sensing, 2015)*

Při sběru dat se obdobně, tak jako v případě realizování jiných forem distančních měření vychází z předpokladu, že objekty a probíhající děje ovlivňují své okolní prostředí prostřednictvím různých silových polí. V případě DPZ je tímto elektromagnetické pole, které se šíří prostorem a má formu elektromagnetického záření o určité vlnové délce. Elektromagnetické záření se v přírodě vyskytuje ve spojitém rozložení vlnových délek, které je celkově označováno jako spektrum elektromagnetického záření (obrázek 2). Hlavní podstatou DPZ je skutečnost, že pozorované povrchy (vegetace, voda, holá půda, urbanizované oblasti apod.) určitý druh tohoto záření pohlcují, odrážejí nebo také dokonce sami emitují.

Na této skutečnosti poté můžeme během fáze zpracování dat identifikovat různé typy výše uvedených povrchů. (Dobrovolný, 1998)



Obrázek 2 - Spektrum elektromagnetického záření

Zdroj: (The electromagnetic spectrum, 2024)

Elektromagnetické záření může být prostředky DPZ zachyceno v různých intervalech vlnových délek odpovídající různým druhům elektromagnetického záření. Pro účely DPZ je využíváno ultrafialové, viditelné, infračervené (blízké, střední a tepelné) a mikrovlnné záření. V případě prostředků DPZ se v zásadě jedná o snímací zařízení upevněné na tzv. nosič, který v dnešní době představují převážně družice, UAV nebo letadla. Samotný sběr dat může být zprostředkován jako aktivní, pasivní přímé nebo pasivní nepřímé snímání. Při aktivním snímání je zdrojem elektromagnetického záření samotné snímací zařízení. Při pasivním přímém snímání je tímto zdrojem Slunce. Poslední způsob, pasivní nepřímé snímání, nastává v situaci, kdy je zdrojem elektromagnetického záření samotný objekt v pozorovací scéně. (Dobrovolný, 1998)

Především na základě skutečností vyplvajících z výše uvedeného popisu (rozsahu snímaných vlnových délek, nosiči snímacího zařízení, realizované povaze a typu snímání) mohou být nashromážděná data různého charakteru a samozřejmě v sobě také mohou obsahovat rozdílné informace, které by z dat mohli být potencionálně získané. Od tohoto se dále odvíjí samotné zpracování dat (druhá hlavní činnost DPZ), neboť pro různá data využíváme různých přístupů k jejich zpracování.

## 2 DIGITÁLNÍ ZPRACOVÁNÍ OBRAZU


Digitální zpracování obrazu a počítačové vidění obecně v dnešním technologicky moderním světě ovlivňuje mnoho oblastí lidské činnosti. Obdobně je tomuto i v případě využití v DPZ, kde se pod tímto termínem skrývá rozsáhlé zastoupení různých manipulačních technik nad obrazovými daty s cílem dosáhnout tíženého výsledku. K tomuto tématu existuje v odborné literatuře mnoho odlišných členění.

Halounová a Pavelka (2005) uvádějí rozdělení do čtyřech hlavních a na sebe navazujících základních fází těchto operací, kterými jsou:

- předzpracování,
- zvýraznění,
- automatická klasifikace,
- postklasifikačních úpravy.

### 2.1 Digitální RGB obrazový záznam

RGB obrazová data představují maticové uspořádání základních obrazových bodů (tzv. pixelů) o konkrétním počtu řádků a konkrétním počtu sloupců (obrázek 3). Jednotlivé pixely jsou ve výpočetní paměti počítače uloženy formou číselně kódovaných pozic, které jsou následně prostřednictvím barevného kompozice RGB jednotně vizualizovány a vnímány jako celistvý barevný snímek. Tato barevná kompozice vzniká aditivním skládáním poměrů tří základních barev (R-červeném kanálu, G-zeleném kanálu a B-modrém kanálu). (IBM, 2019)




Obrázek 3 - Digitální obrazový záznam

Zdroj:(Introduction to image and raster data, 2024)



Každý pixel barevného RGB snímku je tak definovaný třemi hodnotami v kanálech RGB a každý RGB snímek je složen ze třech dílčích matic ve kterých jsou uloženy číselné hodnoty pro jednotlivé RGB kanály. V rámci DPZ se poté jedná o obrazová data získaná pouze ve viditelné části spektra elektromagnetického záření a tedy v tzv. přirozených barvách.

Jak již byl nastíněno, pixely jsou číselně kódované hodnoty. Tyto hodnoty mohou být kódované v určitém rozsahu tzv. bitové hloubce, který v případě DPZ označujeme jako radiometrické rozlišení. Ve své podstatě radiometrické rozlišení vypovídá o počtu rozeznatelných úrovní v obrazovém záznamu. Například v případě bitové hloubky o 1 bitu rozeznáváme dvě barevné úrovně na snímku (černá a bílá), při 8-bitové hloubce (černobílý snímek) rozeznáváme 256 úrovní černobílé, respektive stupně šedi. A v případě 8-bitové hloubky v třech kanálech RGB (barevný snímek) rozlišujeme 16 777 216 ( $256^3$ ) barevných úrovní. (Dobrovolný, 1998) Tento příklad znázorňuje obrázek 4.



Obrázek 4 - Radiometrické rozlišení

*Zdroj: Vlastní zpracování*

U obrazových záznamů DPZ jsou mimo radiometrické rozlišovací schopnosti dále rozeznávány další tři vlastnosti, a to prostorové, časové a spektrální rozlišení. Prostorové rozlišení udává, jakou velikost skutečné plochy zemského povrchu je možné zachytit v jednom pixelu obrazového záznamu. Toto rozlišení se zejména liší v případě využitého nosiče (družice, letadlo nebo UAV) snímacího zařízení. Časové rozlišení stanovuje s jakou opakovatelností (periodou) může být snímání znova provedeno. Spektrální vlastnost vyjadřuje v kolika intervalech vlnových délek je snímek zaznamenán. V této souvislosti rozeznáváme zejména panchromatický, multispektrální nebo hyperspektrální snímek. (Dobrovolný, 1998)

## 2.2 Předzpracování

V reálném světě působí na každý druh měření nechtěné vlivy, které zapříčiňují výskyt různých chyb v naměřených datech. Obdobně k těmto nechtěným vlivům může docházet i v případě DPZ při snímání zemského povrchu. Vzhledem k potřebám dalšího zpracování získaných obrazových dat je tak nutné tyto vzniklé chyby z obrazových záznamů v nejlepším případě odstranit, nebo alespoň do rozumné míry potlačit. Fáze předzpracování tak zahrnuje manipulaci s obrazovými daty za účelem provedení určitých korekcí vzniklých chyb. Tyto opravy mohou být v zásadě dvojího druhu a lišit se v typu vyskytlé chyby. První kategorii tvoří tzv. radiometrické opravy, které se snaží o modifikování hodnoty pixelu tak, aby radiometrická hodnota lépe vypovídala o skutečných vlastnostech zemského povrchu. (Dobrovolný, 1998)

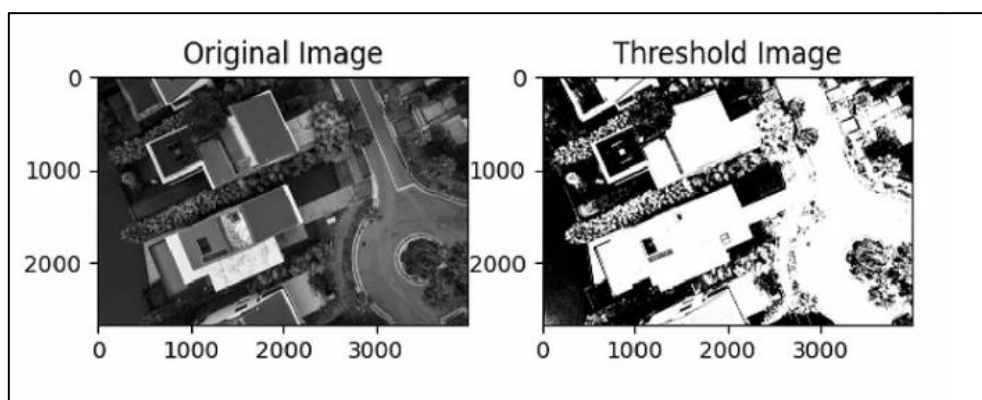
Druhou kategorií korekcí představují tzv. geometrické opravy, které upravují obrazový záznam s cílem odstranění geometrické nepřesnosti na základě převedení všech obrazových bodů z jednoho souřadného systému do jiného. V odborné literatuře je tento proces označován jako technika rektifikace s následným převzorkováním. Do geometrických korekcí můžeme také například zahrnout tzv. mozaikování, které představuje vytvoření jednoho rozsáhlejšího snímku pozorovací scény složeného z dílčích obrazových záznamů získaných během snímkování. (Lillesand, 2015)

## 2.3 Zvýraznění

Manipulační techniky fáze zvýraznění jsou na obrazová data použity se záměrem vylepšení jejich vizuální podoby a tímto tak docílit potencionálního navýšení množství informace, které se v těchto obrazových záznamech může nacházet. V této souvislosti se využívají různé zvýrazňovací techniky v různém pořadí jejich uplatnění. Obecně tyto techniky můžeme rozdělit na tři hlavních kategorií. (Lillesand, 2015)

### ▪ Bodové zvýraznění

Techniky bodové zvýraznění operují s hodnotou každého pixelu obrazového záznamu separátně, tj. bez ohledu na hodnoty okolních pixelů. Typickým představitelem operací této kategorie je například prahování, které na základě stanovené prahové hodnoty provede segmentaci všech pixelů do dvou podskupin. Vstupní a výsledný výstupní snímek této operace je znázorněn na obrázku 5. Mimo uvedené prahování může být dalším typem těchto operací například zvětšování kontrastu nebo hustotní řezy. (Dobrovolný, 1998)

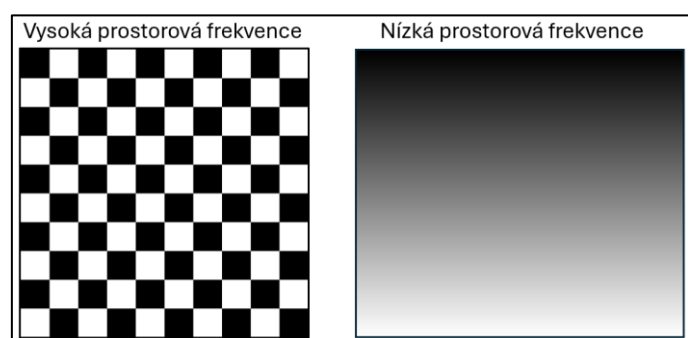


Obrázek 5 - Prahování obrazového záznamu

Zdroj: (Simple Thresholding, 2023)

### ▪ Prostorové zvýraznění

Techniky prostorové zvýraznění oproti předešlé skupině operací zohledňují při svém vykonání pouze závislost hodnot okolních pixelů a následně tak mění středový obrazový bod určený k modifikaci. Tyto techniky jsou především založeny na obrazových filtrech pracujících s prostorovou frekvencí snímku, která vyjadřuje rychlost změny variací tónů. Příkladem vysoké a nízké prostorové frekvence je obrázek 6. (Dobrovolný, 1998)



Obrázek 6 - Vysoká a nízká prostorová frekvence

Zdroj: Vlastní zpracování podle (Dobrovolný, 1998)

Jak uvádí (Dobrovolný, 1998) rychle změny tónů v hodnotách jednotlivých pixelů (vysoké prostorové frekvence) indikují liniové prvky v obraze (například zástavby, komunikace nebo přírodní hranice). Naopak nepatrné změny tónů v hodnotách jednotlivých pixelů mohou popisovat postupné změny homogenního povrchu, například vodní plochy, louky nebo vyplněné lesní oblasti. Aplikací vysokofrekvenčních nebo nízkofrekvenčních prostorových filtrů tak lze detekovat propust vysokofrekvenční nebo nízkofrekvenční informace z obrazového záznamu.

### ▪ Spektrální zvýraznění

Poslední manipulační techniky zvýraznění zahrnují přístupy založené na již uvedené skutečnosti, že zemský povrch (například vegetace nebo vodní plochy) vykazuje v odlišných intervalech vlnových délek elektromagnetického záření jiné spektrální projevy. Využitím více pásem vlnových délek a jejich následnou kombinací tak můžeme docílit navýšení množství informace.


Mezi tyto zvýrazňovací techniky tak například patří vytváření barevných syntéz v nepravých barvách (tedy syntéz, kde barevným prostorem RGB není výpočetně vizualizována pouze viditelná část spektra). Jiným příkladem mohou být techniky založené na využití spektrálně vegetačních indexů, například index NDVI (Normalized Difference Vegetation Index), který pracuje v intervalu červené viditelné – blízké infračervené části spektra a je vhodný pro zhodnocení stavu vegetace. (Lillesand, 2015)

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

*Rovnice 1 - Vegetační index NDVI*

*Zdroj: (Lillesand, 2015)*

Do této skupiny zvýraznění lze také zahrnout interpretaci obrazových dat prostřednictvím jiného barevného prostoru než RGB. Takovým příkladem může být barevný model HSV, který je místo červeného, zeleného a modrého kanálu vizualizován formou odstínu (H – „Hue“, sytostí barvy (S – „Saturation“) a jasnem (V – „Value“). (Agapiou, 2017)



*Obrázek 7 - Barevný prostor RGB a HSV*

*Zdroj: (RGB vs HSV, 2018)*

## 2.4 Klasifikace

Klasifikace představuje samočinnou transformaci všech pixelů digitálního snímku do informačních tříd, kde každá tato třída reflektuje určitý druh zemského povrchu. Výsledkem tohoto začlenění je výstup označovaný jako tzv. tematická mapa (obrázek 8), která je složena pouze z těchto informačních tříd. Získání výstupu ve formě tematické mapy je docíleno prostřednictvím tzv. klasifikátorů, které si můžeme představit jako určité algoritmy, na jejichž základě je proces klasifikace proveden.



Obrázek 8 - Tematická mapa

*Zdroj: (Classify pixels, 2024)*

Tyto klasifikátory mohou být založeny na různých charakteristických rysech vyskytujících se v obrazových záznamech. Nejčastěji používanými a propracovanými jsou klasifikační algoritmy pracující se spektrálním chováním, ty využívají již zmíněného předpokladu, že různé druhy zemského povrchu vykazují různé spektrální projevy. Klasifikátory také mohou využívat například prostorového chování, kdy jsou sledovány různé prostorové vlastnosti, které by odlišovali jednotlivé objekty. Příkladem těchto prostorových rysů může být odlišný rozměr, tvar nebo vzájemná distance objektů v prostorovém uspořádání obrazového záznamu. (Lillesand, 2015)

Z pohledu zacházení s jednotlivými pixely při samotném běhu automatické klasifikace můžeme také klasifikátory rozdělovat na tzv. „per-pixel“ kategorií, kdy je začleněn každý pixel separátně bez ohledu na okolní obrazové body. Druhou možností je tzv. „per-object“ při které nejprve

dochází ke stanovení objektů v obrazovém záznamu, a až poté se určuje jejich příslušnost ke konkrétní informační třídě. (Horák, 2014)

Na základě konceptu využitého klasifikačního algoritmu a jeho principu činnosti můžeme jednotlivé klasifikátory členit do tří základní přístupů, kterým je neřízená klasifikace, řízená klasifikace a hluboké učení. Přičemž přístup neřízení a řízené klasifikace představuje tradiční koncepty strojového učení. (Mehmood, 2022) Tyto přístupy také ve své podstatě stanovují, jakým způsobem a v jak velké míře zasahuje zpracovatel do celého procesu automatické klasifikace. (Dobrovolný, 1998)

- **Neřízená klasifikace**

Neřízené klasifikátory představují algoritmy, které se snaží o automatické nalezení jednotlivých informačních tříd na základě podobností nacházejících se v obrazových datech. Tyto algoritmy zpravidla fungují na shlukovací analýze. Zpracovatel tyto algoritmy ovlivňuje pouze stanovením počtu tříd před vykonáním algoritmu. Následně po provedení klasifikace ovšem musí těmto třídám přidělit jejich informační význam. Nejčastějším představiteli této skupiny klasifikátorů je algoritmus „K-Means“ a „ISODATA“. (Al-doski, 2013)

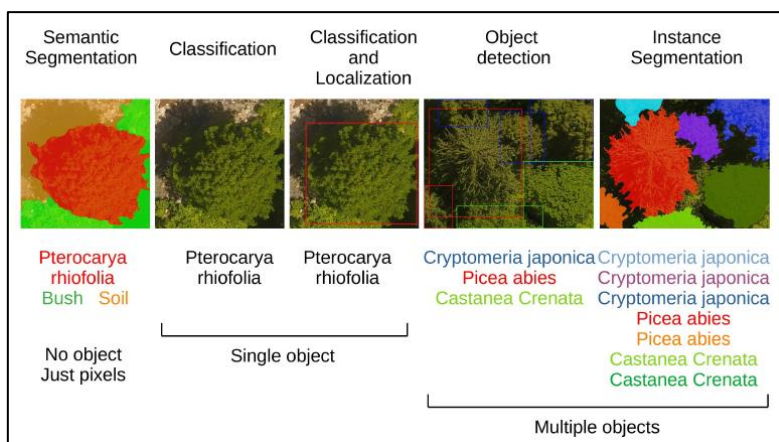
- **Řízená klasifikace**

Algoritmy řízené klasifikace na rozdíl od předchozí skupiny vyžadují před jejich vykonáním stanovení vstupních dat, které představují trénovací množinu. Tyto algoritmy mají různorodý princip určení náležitosti pixelů do jednotlivých informačních tříd. Tato náležitost ovšem vždy v případě těchto algoritmů vychází ze vstupně definovaných trénovacích ploch. Řízenou klasifikaci tak můžeme rozdělit na první dílčí krok ve které je ze strany zpracovatele provedeno vytvoření trénovacích vzorů pro každou informační třídu. A následný druhý dílčí krok, který představuje provedení samotné klasifikace. (Lillesand, 2015) Typickými představiteli řízené klasifikace může být například klasifikátory „Maximum Likelihood“ (ML) (Al-doski, 2013) nebo „Support Vector Machine“ (SVM). (Gidudu, 2007)

- **Hluboké učení (Deep Learning)**

Hluboké učení je v současné době aktuálním trendem, které ve spojení s DPZ může dokázat realizovat klíčové úkony počítačového vidění. Příklady těchto úkonů jsou znázorněny formou obrázku 9, který vizualizuje výsledky činností sémantické segmentace, klasifikace, klasifikace s následnou lokalizací, detekcí objektů a instantní segmentací. V případě analýzy obrazu se nejčastěji používá specifický podtyp architektury hlubokého učení nazývaný jako konvoluční neuronová síť (CNN). V souvislosti s řešenou problematikou automatické

klasifikace jednotlivých pixelů se poté využívá již výše uvedená činnost označovaná jako sémantické segmentace při které CNN predikuje příslušnost každého pixelu do jednotlivých segmentů, respektive informačních tříd. (Diez, 2021)

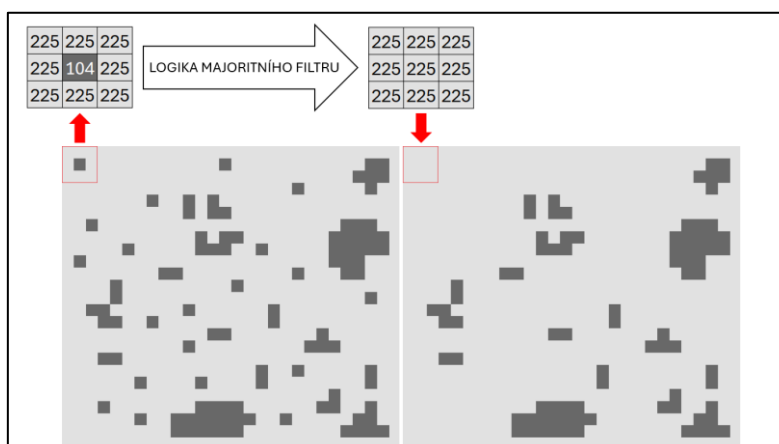


Obrázek 9 - Hluboké učení ve spojení s dálkovým průzkumem Země

Zdroj:(Diez, 2021)

## 2.5 Postklasifikační úpravy

V tematických mapách se mnohdy po vykonání automatické klasifikace objevuje efekt tzv. pepře a soli, který představuje zvýšený počet malých pixelových shluků nebo jen osamocených pixelů vyskytujících se v relativně celistvé skupině pixelů jiného informačního významu. Tento efekt je ve výsledné tematické mapě zpravidla nežádoucí. Právě postklasifikační úpravy mají za cíl snížit výskyt tohoto efektu, a to zpravidla prostřednictvím aplikování tzv. majoritních filtrů, které mění informační třídu středového pixelu filtru podle dominantního zastoupení informační třídy okolních pixelů. (Halounová, 2005)



Obrázek 10 - Ukázka aplikování majoritního filtru v detailu na úrovni pixelů

Zdroj: Vlastní zpracování

Příkladem této operace může být provedení majoritní filtrace znázorněné na obrázku 10. V tomto případě je postklasifikační úprava realizována pouze filtrem o rozměru 3x3 s cílem odstranit jen osamocené pixely.

## 2.6 Hodnocení přesnosti automatické klasifikace

Klasifikace není v praktickém užití ideální a jednotlivé pixely mohou být špatně predikovány do patřičných informačních tříd. Neméně důležitým krokem, který je součástí celkové klasifikace, je také zhodnocení přesnosti provedené klasifikace. Tato přesnost se nejčastěji vyhodnocuje na základě vytvoření kontrolních bodů o kterých je známa skutečná vypovídající hodnota. Z těchto kontrolních bodů je následně vytvořena tzv. chybová matice (tabulka 1). (Dobrovolný, 1998)

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'					
	T_2'					
	T_3'					
	Σ SLOUPEC					
PZ						

Tabulka 1 - Chybové matice

Zdroj: Vlastní zpracování podle (Dobrovolný, 1998)

Hodnoty na hlavní diagonále (zelené vyznačení) označují správně zařazené pixely v rámci jednotlivých informačních tříd, hodnoty mimo hlavní diagonálu poté představují počet nesprávně začleněných pixelů. Prostor nesprávně zařazených pixelů můžeme rozlišovat na chyby z vynechání (sloupce mimo hlavní diagonálu) a chyby z nesprávného zařazení (řádky mimo hlavní diagonálu). V této souvislosti poté parametr „Σ SLOUPEC“ vyjadřuje skutečný (správný) počet pixelů v jednotlivých třídách a parametr „Σ ŘÁDEK“ poté popisuje, kolik pixelů bylo do dané třídy klasifikováno. Celková přesnost klasifikačního algoritmu je určena jako podíl součtu hodnot hlavní diagonály a počtu celkových kontrolních pixelů. V souvislosti s chybovou maticí můžeme mimo celkovou přesnost také vyjádřit přesnost z hlediska uživatele PU (podíl hodnoty hlavní diagonály a součtu hodnot v řádku) a přesnost z hlediska zpracovatele PZ (podíl hodnoty hlavní diagonály a počtu skutečně správných pixelů). (Dobrovolný, 1998)

V rámci vyhodnocení přesnosti klasifikace se také využívá posouzení tzv. kappa koeficientu, který stanovuje, o jakou procentuální hodnotu je provedení automatické klasifikace lepší



než provedení klasifikace náhodným začleněním. Pro příklad výsledek  $K = 0,5$  udává, že provedená klasifikace byla o 50 % lepší než náhodná klasifikace. (Dobrovolný, 1998)

Koeficient Kappa můžeme definovat podle následující rovnice:

$$K = \frac{N \cdot \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}$$

*Rovnice 2 - Kappa koeficient*

*Zdroj:(Lillesand, 2015)*

kde:

- N – celkový počet kontrolních bodů,
- $x_{ii}$  – kontrolní body na hlavní diagonále,
- $x_{i+}$  – kontrolní body v řádku,
- $x_{+i}$  – kontrolní body ve sloupci.

Fázi automatické klasifikace můžeme na základě výsledku a obecně kategoricky stanoveného rozsahu koeficientu Kappa označit jako úroveň určité shody podle tabulky 2. V případě téměř perfektní shody dosahuje Kappa hodnoty 0,81 a větší. Naopak za malou nebo špatnou shodu lze považovat hodnotu 0,2 a menší.

Hodnota K	Interpretace výsledku
$0,81 \leq K \leq 1,00$	Téměř perfektní
$0,61 \leq K \leq 0,80$	Skvělá
$0,41 \leq K \leq 0,60$	Mírná
$0,21 \leq K \leq 0,40$	Přijatelná
$0,00 \leq K \leq 0,20$	Malá
$K \leq 0,00$	Špatná

*Tabulka 2 - Interpretace výsledku Kappa koeficientu*

*Zdroj: Upraveno podle (Interpretation of Kappa coefficient, 2019)*

### 3 MOMENTÁLNÍ STAV ŘEŠENÉ PROBLEMATIKY

Tato kapitola je věnována rešerši akademických studií a článků zaobírající se současnou problematikou zpracování RGB obrazových dat z UAV a tím i problematikou spojenou s touto diplomovou prací.

V případě mapování krajinného pokryvu s využitím RGB snímků i procesu automatické klasifikace obrazových dat DPZ obecně, nelze jednoznačně definovat správný postup pro provedení automatické klasifikace (postup, který skvěle funguje pro určitá obrazová data, nemusí tak dobře fungovat i pro jiné obrazové záznamy). Jak bylo uvedeno v předchozí kapitole, v rámci samotného procesu klasifikace existuje mnoho přístupů, od algoritmů využívající tradiční koncepty strojové učení až po přístupy vedoucí k hlubokému učení. Klíčovou rolí v celém procesu provedení automatické klasifikaci sehrává výběr adekvátního klasifikátoru.

V souvislosti s kvantifikací a zvýrazněním určitých druhů zemského povrchu pro následný monitoring sehrává v případě obrazových záznamů získaných prostředky UAV, které pracují pouze v režimu viditelné části spektra významnou roli využití RGB vegetačních indexů.

Na základě výše uvedeného jsou jednotlivé rešerše koncipovány dvěma směry:

- výkonost klasifikátorů v procesu automatické klasifikace,
- využitelnost RGB vegetačních indexů.

Autor článku se zabýval použitelností čtyř klasifikátorů (algoritmů strojového učení) nad obrazovými daty získanými prostřednictvím UAV ve viditelné části spektra, tedy RGB snímků. Zájmovou oblastí této studie byla část města Kaohsiung na Taiwanu. Samotné získání RGB snímku bylo realizováno pomocí dronu DJI Phantom 3. Zpracování RGB obrazových dat poté bylo provedeno v softwarovém nástroji ArcGIS Pro. Jako klasifikační metody této studie byli zvoleny: SVM, RF (Random Forest), ML, které představují algoritmy strojového učení pod dohledem. Poslední, čtvrtou klasifikační metodou byla shluková analýza, která představuje algoritmus strojového učení bez dohledu. Cílem studie bylo zhodnocení úspěšnosti výše uvedených klasifikačních algoritmů, které vstupní RGB snímek členili do následujících informačních tříd: les, pastviny, holá půda, zastavěná plocha a silnice. Z použitých metod si nejlépe vedl algoritmus RF, následoval algoritmus SVM a ML. Jako poslední byl z pohledu úspěšnosti vyhodnocen algoritmus, který byl založen na shlukové analýze. Autor, mimo jiné, ve své studii podotkl porovnání mezi výše uvedenými algoritmy a případným modernějším

přístupem realizovaným s využitím CNN. K provedení sémantické segmentace může být zapotřebí poměrně velké množství anotovaných dat, které slouží k efektivnímu natrénování modelu CNN, což v některých situacích může být problematické nebo dokonce nemožné. Nicméně pouze efektivně natrénovaný model vede k optimálnímu výkonu sémantické segmentace. Dalším nutným aspektem k zvažování, je zajisté větší výpočetní náročnost (nároky na výkonné výpočetní komponenty: GPU - Graphics Processing Unit a také CPU - Central Processing Unit) oproti tradičním metodám strojového učení. Autor zde také uvádí, že ne všechny výzkumné projekty vyžadují moderní přístupy. I tradiční koncepty mohou stále poskytovat cenné poznatky a zajímavé výsledky. (Fan, 2023)

Tým vědců ve své studii zkoumal mokřadní vegetace v přírodní rezervaci Honghu. Podnětem této studie bylo zejména sledování a průzkum dynamických změn vyskytujících se jednotlivých druhů mokřadní vegetace v této oblasti. RGB snímky byli pořízeny prostřednictvím dronu: DJI Mavic Pro. V rámci této studie byla nad těmito snímky provedena analýza pomocí objektové klasifikace OBIA s užitím pěti algoritmů strojového učení: Bayes, KNN, SVM, DT („Decision Tree“) a RF. Kromě spektrálních příznaků byla také provedena extrakce vegetačními indexy, charakterem textur a geometrických příznaků generovaných segmentací obrazu. Rozeznáváno bylo celkem 10 klasifikačních tříd, z toho 8 tříd představovalo jednotlivé druhy mokřadní vegetace, 1 vodní plochu a poslední jiné útvary. Výsledek výkonnosti samotných klasifikačních algoritmů strojového učení byl posouzen z hlediska celkové úspěšnosti klasifikace a koeficientu Kappa. Nejvyšší celkovou přesnost poskytl algoritmus RF, který dosáhl celkové přesnosti 89,76 % a koeficient kappa 0,88. Nejhorší úspěšnosti byla evidována u algoritmu KNN s celkovou úspěšností 58,05 % a koeficientu Kappa 0,53. U ostatních využitých algoritmů byla úspěšnost celkové klasifikace v bezprostřední blízkosti algoritmu RF v následujícím pořadí: SVM (celková úspěšnost 88,78 % a Kappa 0,87), DT (celková úspěšnost 86,34 % a Kappa 0,85) a Bayes (celková úspěšnost 84,88 % a Kappa 0,83). V případě rozpoznání vodní plochy se u výše uvedených klasifikátorů jednalo, kromě algoritmu KNN (přesnost rozpoznání vodní plochy 86,67 %) o 100 % přesnost zařazení do této informační třídy. Na celkovou přesnost tedy měli zejména vliv chyby vzniklé v důsledku klasifikace mezi jednotlivými druhy mokřadní vegetace. (Zhou, 2021)

Tým Japonských vědců ve svém článku porovnával schopnost poskytování přesných informací souvisejících s mapování krajinného pokryvu v rámci obrazových záznamů získaných dvěma odlišnými typy UAV. Konkrétněji se jedná porovnání snímků získaných z UAV, které jsou

schopny pracovat pouze ve viditelném spektru a UAV, které jsou vybaveny multispektrální kamerou a jsou tak schopny pracovat ve více pásmech nežli pouze viditelné části. Případovou studií je monitorování oblastí postižených sesuvy půdy regionu Uryu ve městě Atsuma, Japonsko. Vytvoření map krajinného pokryvu bylo provedeno se záměrem k identifikaci vegetace v sesuvných oblastech po dobu několika měsíců. Získání obrazových dat bylo realizováno prostřednictvím dvou různých UAV: DJI Phantom 4 a DJI Phantom 4 Multispectral při celkem čtyřech letových kampaních s časovým rozlišením přibližně jeden měsíc. Z jednotlivých souborů obrazových dat každé kampaně byly vytvořeny ortomozaiky. V rámci klasifikace byly stanoveny tři informační třídy: vegetace, holá půda a tzv. mrtvá hmota, která představovala odumřelé listí, padlé stromy a opadané větve stromů. Pro klasifikaci ortomozaiky byl vybrán klasifikátor SVM. Posouzení výkonu klasifikace bylo provedeno prostřednictvím zhodnocení celkové přesnosti vůči vzorům testovacích dat. Výsledky demonstrovaly vysoké hodnoty celkové přesnosti pro obrazová data získaná v multispektrálním režimu, která v případě vytvořené první až čtvrté ortomozaiky dosahovaly 97,78 %, 95,56 %, 96,67 % a 98,89 %. Pro ortomozaiky vytvořené ze snímání v režimu pouze viditelného spektra byly hodnoty celkové úspěšnosti následující: 94,44 %, 72,22 %, 64,44 % a 90,00 %. (Furukawa, 2021)

Studie se zabývala analyzováním a detekováním časových změn mokřadního ekosystému Neziderského jezera během jednoho vegetačního období. Sběr RGB snímků v této studii byl realizován za použití dronu DJI Mavic 2. Ze získaných snímků byli vytvořeny ortomozaiky, které sloužily jako základ pro klasifikaci krajinného pokryvu a také provedení fenologické analýzy. V této studii bylo jedním z hlavních cílů poskytnutí pracovního postupu klasifikace krajinného pokryvu, která byla realizována sémantickou segmentací prostřednictvím hlubokého učení. Použitý softwarovým nástrojem v tomto případě byl ArcGIS ve verzi 3.0.3 s rozšířením pro nadstavby „Image Analyst“ a také „Deep Learning Libraries“. Pro sémantickou segmentaci byla zvolena architektura CNN: DeppLabV3+. Klasifikační výkon spojený s predikcí modelu byl autory vizualizován formou chybových map, která představují tematickou mapu o dvou kategoriích (správně a nesprávně klasifikovaná data) nad skutečným kontrolním obrazovým záznamem. Chyby klasifikace se v tomto případě vyskytovali zejména podél přechodů mezi informačními třídami. (Buchsteiner, 2023)

Studie se zabývala aplikací rámců hlubokého učení na případové studii mapováním krajinného pokryvu pobřežního mokřadního ekosystému nalézajícího se u města Corpus Christi v USA. Ve této studii je zkoumáno následujících šest architektur hlubokého učení: SegNet, U – Net,

FC – DenseNet, DeepLabV3+, PSPNet a MobileU – NET. Identifikované informační třídy krajinného pokryvu jsou v této práci následující: přílivová rovina, vodní plocha, vegetace a silnice. Přílivová rovina zde představuje oblast vystavenou přílivovým faktorům Mexického zálivu. U ostatních tříd je již jejich význam patrný ze samotného označení. Sběr snímků byl realizován prostřednictvím dronu DJI Phantom 3 vybaveného CMOS RGB snímačem. Celkem bylo získáno přibližně 500 snímků pozorované oblasti, které byly po vyčlenění opakujících se informací redukovány na 300 snímků. Všechna potřebná data pro fázi trénování a validace byla ručně označena na úrovni pixelů pomocí nástroje pro anotaci obrazových dat hlubokého učení v softwaru Matlab. Architektura FC – DenseNet si z pohledu celkové přesnosti vedla nejlépe. Architektura U – NET předčila ostatní architektury v rychlosti trénování modelu a zároveň také dosahovala srovnatelné přesnosti, jak FC – DenseNet. Na základě těchto skutečností můžeme jako nejúspěšnější architekturu využitou v této studii považovat síť U – Net. Mimo jiné, zde autoři studie také poznamenávají úspěšnost predikce architektury DeepLabV3+, která také dosáhla skvělých výsledků. (Pashaei, 2020)

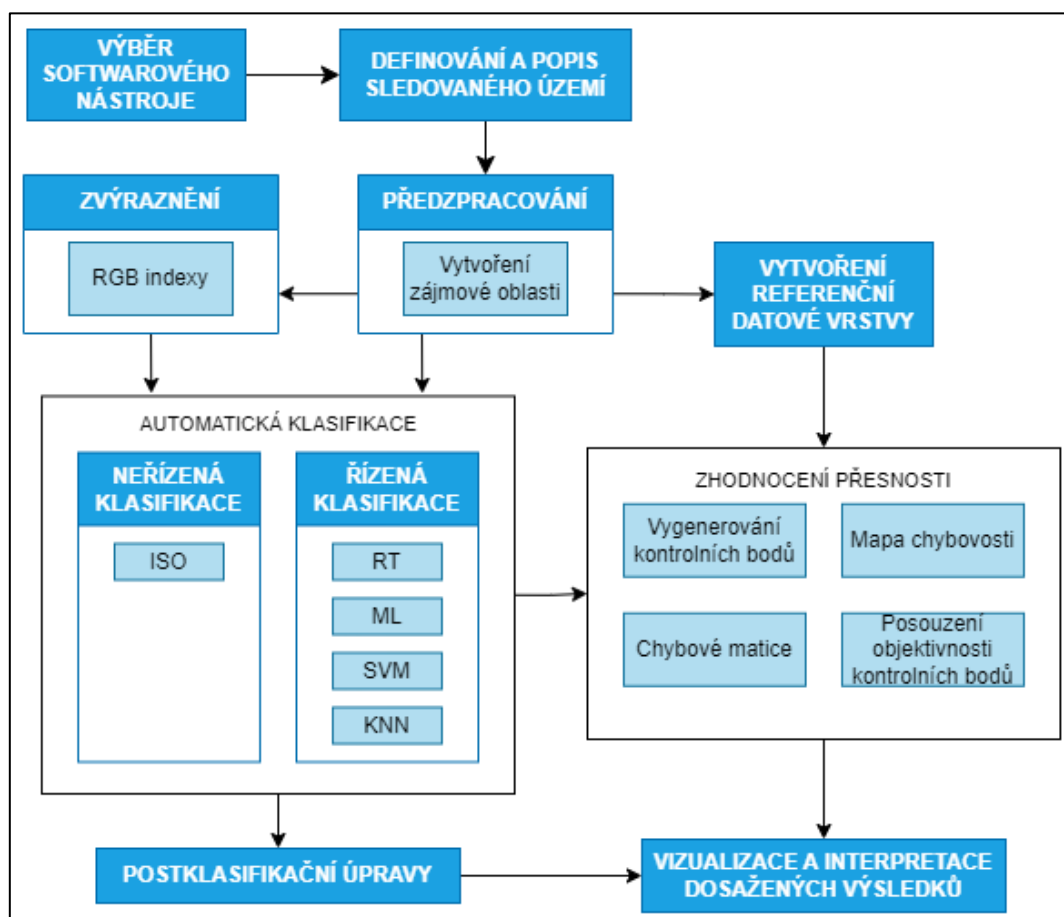
Článek porovnává účinnost identifikace půdního a vegetačního pokryvu zemského povrchu prostřednictvím dat získaných z UAV. V této studii jsou porovnány čtyři vegetační indexy pracující pouze ve viditelné části spektra s vegetačním indexem NDVI získaného prostřednictvím multispektrální kamery, jehož výsledky v případě tohoto článku představují referenční data. Uvažovanými RGB indexy byly v rámci tohoto experimentu: VARI (Visible Atmospheric Resistant Index), TGI (Triangular Greenness Index), ExG (Normalized Excess Green Index) a NGRDI (Normalized Green-Red Difference Index). Pozorovanou oblastí této studie je komerční vinice nacházející se v regionu Maule v Chile. Pořízení obrazových záznamů bylo realizované využitím dvěma UAV: oktokopty založená na PixHawk konceptu a DJI Phantom 3 Advanced, které se řídily předem stanoveným letovým plánem. RGB snímky byly získané prostřednictvím snímače integrovaného v rámci DJI Phantom 3 Advanced. V případě snímků ke stanovení NDVI byla odrazivost spektrálního projevu měřena šestipásmovou multispektrální kamerou Tatracam MCA-6. Porovnání všech indexů bylo realizováno vůči referenční tematické mapě o dvou třídách představující půdu a vegetaci, které v případě NDVI byly vytvořeny jako klasifikovaná hodnota NDVI menší 0,3 jako půda a hodnota NDVI rovna nebo větší 0,3 jako vegetace. Takto vytvořená tematická mapa byla použita jako zdroj referenčních dat. V případě indexů RGB bylo provedeno podobné zpracování, ovšem z důvodu, že vhodný práh nebyl znám byla tato hodnota pro oddělení výše uvedených tříd vzata jako průměr dat pro každý index. Následné porovnání s indexy RGB bylo

realizováno formou výpočtu pixelů odpovídající každé stanovené třídě. Pro referenční tematickou mapu odpovídalo procentuální zastoupení jednotlivých tříd 59,02 % pro půdu a 40,98 % pro zastoupení plodin. Výsledky této studie ukázaly, že je možné identifikovat stejné prostorové vzorce s využitím RGB indexů. Nejlepší účinnost měl index TGI, který byl v procentuálním zastoupení 59,5 % půdy a 40,5 % vyhodnocených pixelů jako plodin. Zbylé RGB indexy vykazovaly podobné procentuální zastoupení okolo 46 % pixelů představující plodiny a 53 % pixelů pro půdu. Pro klasifikovaný index TGI, který v této studii vyšel nejlépe, byla vytvořena chybová matice vůči klasifikovanému indexu NDVI. V rámci tohoto článku autoři také uvádějí výhody využití UAV, které zejména představují vysoké prostorové rozlišení a variabilitu v případě časového rozlišení oproti využití satelitních snímků. (Fuentes-Peailillo, 2018)

Další článek se zabýval využitím RGB indexů jako alternativou k tradičnímu NDVI pro monitorování růstu plodin rýže. V teoretickém popisu této studie je uvedena již řečená skutečnost výhodnosti UAV vůči satelitním platformám a také finanční nákladovost multispektrálních UAV oproti RGB UAV. Využitým UAV prostředkem v této studii byl DJI Phantom 4 Multispectral, který může pracovat ve viditelném spektru nebo multispektrálním režimu. Na pořízená RGB obrazová data byly aplikovány následující indexy: MExG (Modified Excess Green), MGRVI (Modified Green Red Vegetation Index), RGBVI (Red Green Blue Vegetation Index) a GLI (Green Leaf Index), které byli porovnány s indexem NDVI prostřednictvím korelační analýzy. Nejlepší výsledek představoval index MGVRI, který má v rámci Pearsonovi korelace hodnotu  $R^2 = 0,72$ . Nejnižší hodnotu vykazují indexy MExG ( $R^2 = 0,44$ ) a GLI ( $R^2 = 0,46$ ). Index RGBVI dosáhl hodnoty  $R^2 = 0,65$ . Hodnota RMSE byla v rámci těchto indexů následující: MGVRI (RMSE = 0,11), RGBVI (RMSE = 0,21), GLI (RMSE = 0,0,32) a MExG (RMSE = 0,45). (Kazemi, 2023)

## 4 IDENTIFIKACE VODNÍCH PLOCH S VYUŽITÍM RGB SNÍMKŮ

Následující kapitola se zabývá vlastním zpracováním RGB snímků za účelem identifikace druhů povrchů, které se v těchto obrazových datech nachází. Obrázek 11 znázorňuje celý proces vlastního zpracování v podobě vývojového diagramu.



Obrázek 11 - Schéma vlastního zpracování

Zdroj: Vlastní zpracování

V úvodních částech bude proveden výběr vhodného softwarového nástroje. Další část je věnována samotnému popisu sledovaného území, ve které bude podrobněji probrána charakteristika tohoto území včetně formátu získaných obrazových záznamů. Následovat bude fáze předzpracování. Tato fáze obsahuje vytvoření zájmových oblastí, které budou dále využity ve zbývajících krocích. Součástí vlastního procesu zpracování je i vytvoření referenční datové vrstvy, která bude představovat klasifikovaný snímek vytvořený pomocí ruční identifikace povrchu. Tato výsledná tematická mapa manuální

klasifikace bude posléze sloužit jako referenční předloha pro porovnání dosažených výsledků v rámci klasifikace automatické.

V dalším kroku bude provedeno využití RGB spektrálně-poměrových indexů s cílem navýšit množství obsažené informace. Důvodem tohoto navýšení je snaha zvýšení úspěšnosti algoritmů automatické klasifikace, které budou následovat. Klíčová fáze celého zpracování je provedení již zmíněné automatické klasifikace, která bude zahrnovat dva hlavní klasifikační přístupy. První přístup bude představovat provedení neřízené klasifikace, druhým přístupem bude klasifikace řízená. Celkem bude využito pěti klasifikátorů, přičemž prvním klasifikačním algoritmem bude „Iso Cluster“, který jako jediný představuje algoritmus strojového učení bez dohledu, a tedy spadá do neřízené klasifikace. Čtyři zbývající klasifikátory představují algoritmy strojového učení pod dohledem, tedy řízenou klasifikaci. V tomto případě bude použit klasifikátor ML, SVM, RT („Random Trees“) a KNN („K-Nearest Neighbor“).

Zhodnocení procesu automatické klasifikace bude v první řadě provedeno pomocí náhodně vygenerovaných kontrolních bodů s následným vytvořením chybových matic. Tento způsob zhodnocení bude interpretován číselně v podobě celkové úspěšnosti a Kappa koeficientu vypočítaných z těchto chybových matic. Pro vizuální interpretaci zhodnocení úspěšnosti bude provedeno vytvoření tzv. map chybovosti, tedy tematických map o dvou informačních třídách (správně a špatně zařazené pixely). V obou případech se uvedené zhodnocení výsledných klasifikovaných obrazových dat bude opírat o referenční data vzniklá pomocí ruční identifikace. Fáze zhodnocení přesnosti bude jako poslední krok zahrnovat posouzení objektivnosti kontrolních bodů, které byly náhodně vygenerovány. Tato objektivnost bude posuzována vůči hodnotě celkové přesnosti a Kappa koeficientu počítané ze všech pixelů v jednotlivých tematických mapách.

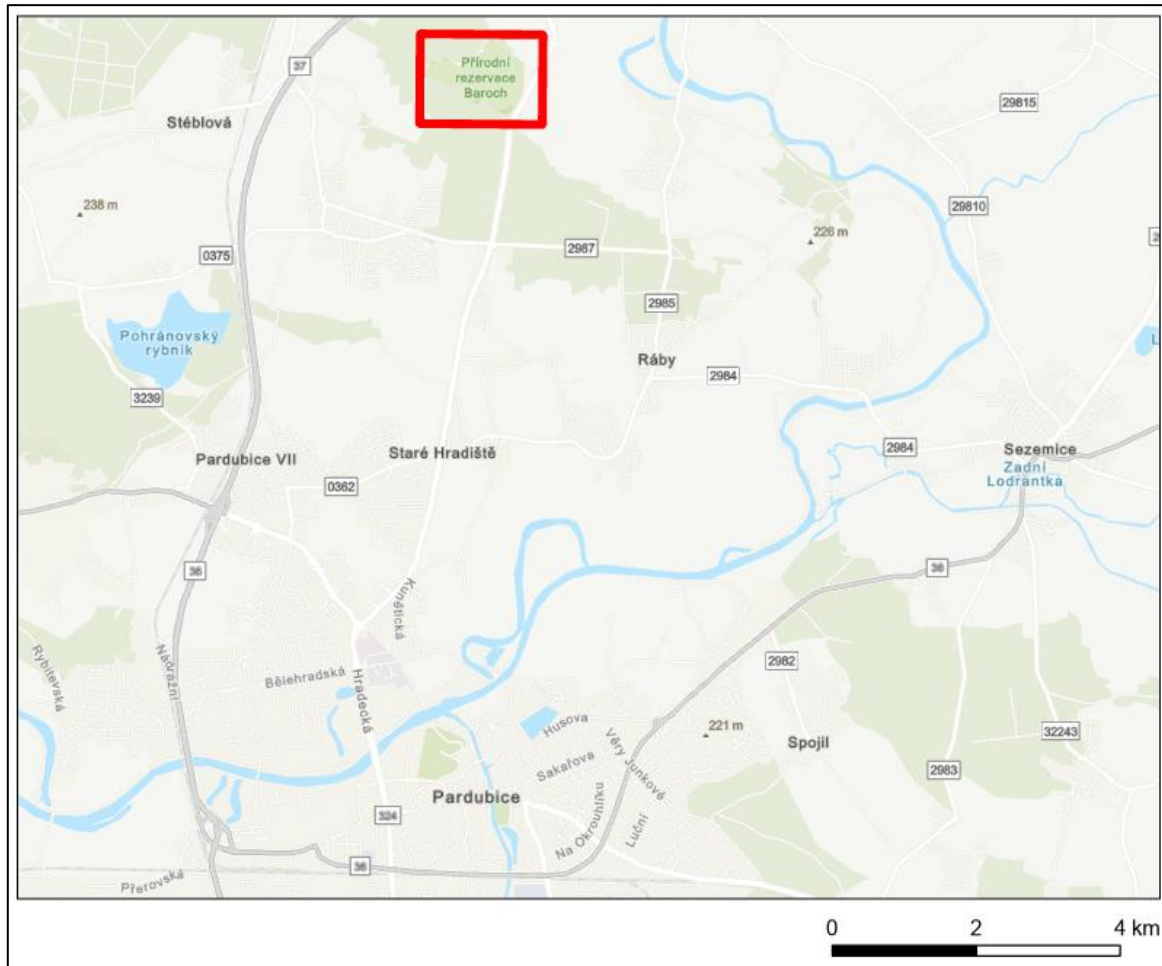
V předposlední fázi vlastního zpracování budou demonstrovány finální postklasifikační úpravy zahrnující výsledky nevhodnější automatické klasifikace. Jako poslední fáze bude provedena vizualizace a interpretace dosažených výsledků.





## 4.2 Charakteristika sledovaného území a vstupní obrazové záznamy

Pozorovaným územím (obrázek 13) je v rámci této diplomové práce přírodní rezervace Baroch, která je situována severní směrem od města Pardubice (50° 05' 47" severní šířky a 15° 47' 01" východní délky) mezi vesnicí Srch a Hrobice.



Obrázek 13 - Umístění sledovaného území

*Zdroj: Vlastní zpracování*

Tato přírodní rezervace je charakteristická uměle vytvořenými mokřadními pásmy poměrně mělkých vodních ploch. Uměle vytvořená mokřadní koryta tvoří v této oblasti drobné ostrovy souše, na kterých se převážně nachází vysoký rostlinný porost. Výše uvedený popis této oblasti blíže vizuálně znázorňuje obrázek 14, který byl pořízen v rámci terénní průzkumu.

RGB obrazová data sledované oblasti byly poskytnuty vedoucím této diplomové práce ve formě mozaiky (obrázek 15 – Kompletní plocha sledovaného území) vytvořeného z celkového počtu 128 obrazových záznamů o velmi vysokém prostorovém rozlišení (1 pixel odpovídá přibližně 1,5 cm skutečné rozlohy) získaných během letu dronu: DJI Phantom 3 v období měsíce

března 2022. Uvedená mozaika je souřadnicového systému WGS84 o rozměru digitálního obrazového záznamu 16 296 x 21 102 pixelů. Celková výpočetní velikost tohoto souboru poté činí 659 MB.



*Obrázek 14 - Terénní průzkum sledovaného území*

*Zdroj: Vlastní zpracování*


#### ▪ **Charakteristika území**

Na základě vizuálního zhodnocení vstupní mozaiky sledovaného území, terénního průzkumu a vzniklé fotodokumentace z tohoto průzkumu, která je znázorněna formou obrázku 14 a také v rámci dalších vypovídajících snímků terénního průzkumu vizualizovaných formou přílohy A můžeme v této sledované oblasti definovat k datu snímání následující druhy povrchů:

- Suchý travní porost, který představuje výskyt vegetačního povrchu tvořeného převážně vysokým rákosem v případě pevniny a shluky převážně také suchých rostlinných útvarů v případě mokřadního koryta.
- Půdní pokryv, který se vyskytuje ve formě holé půdy v rámci pevniny a také jako vysoce podmáčený půdní pokryv některých částech v rámci mokřadního pásu.
- Vodní plocha, která se vyskytuje pouze v mokřadním korytu.

### 4.3 Vymezení zájmové oblasti sledovaného území

Mozaika reprezentující celou plochu sledovaného území zabírá ve výpočetní paměti počítače velikost 659 MB. Pracování se souborem o této velikosti výpočetní paměti je z pohledu nadcházejících využívaných technik časově, a i výpočetně velmi náročné. Z tohoto důvodu bude pro potřeby dalšího zpracování provedeno stanovení menších oblastí zájmu. Tyto oblasti jsou znázorněny formou obrázků 15. V programu „ArcGIS Pro“ byla vytvořena nová vrstva formátu „shapefile“ s následným vytvořením obdélníkových polygonů odpovídající velikosti zájmové oblasti („Výřez 1“ a „Výřez 2“). Pomocí nástroje „Clip Raster“ bylo provedeno oříznutí původní mozaiky na rozsah těchto polygonů. Výběr těchto oblastí byl zvolen tak, aby obsahoval veškeré důležité rysy souvisejících s původní mozaikou (zejména souš, vodní plochu a tvary mokřadního koryta).



Obrázek 15 - Vymezení zájmové oblasti

Zdroj: Vlastní zpracování

#### 4.4 Vytvoření referenční datové vrstvy

Následující podkapitola popisuje vytvoření referenčních tematických map výše uvedených výřezů prostřednictvím ruční identifikace jednotlivých druhů povrchů zastoupených v těchto obrazových datech. Tyto referenční tematické mapy budou posléze sloužit jako vizuální interpretace manuální klasifikace a zároveň také jako vstupy kontrolních bodů do atributu „Ground Truth“, kterými se následně bude posuzovat přesnost algoritmů automatické klasifikace.

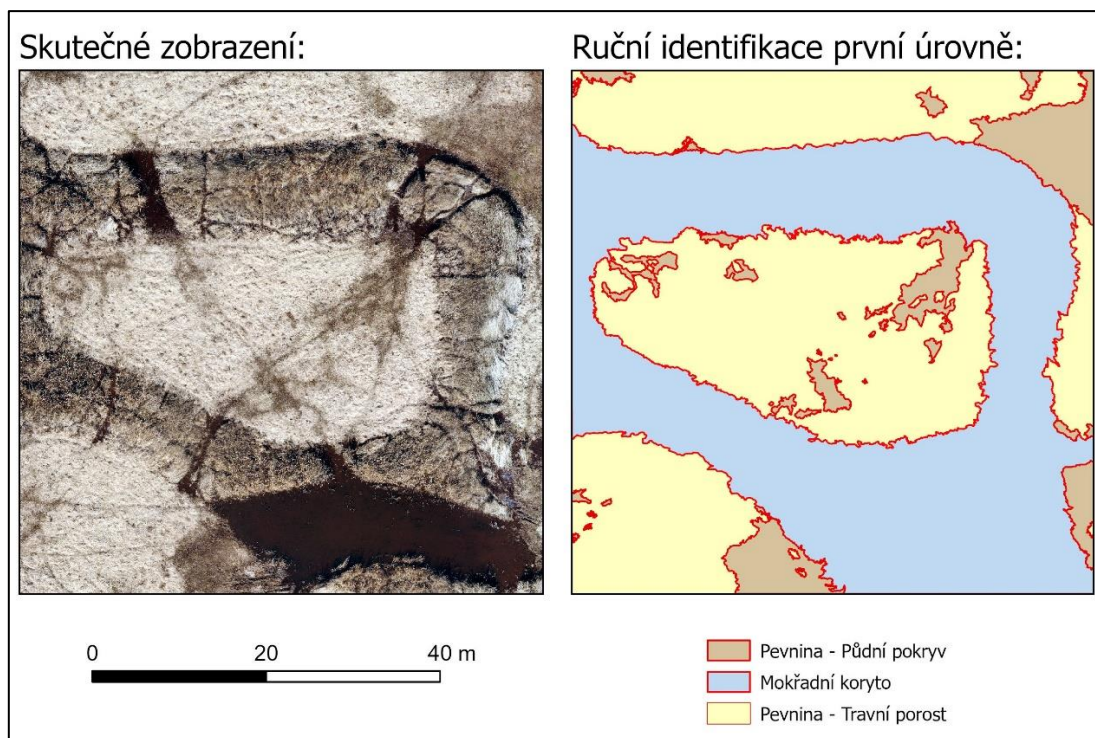
Pro ruční identifikaci budou stanoveny níže uvedené druhy povrchu, které korespondují s popisem sledovaného území v předchozí podkapitole.

- Suchý travní porost,
- půdní pokryv,
- vodní plocha.

Vstupní výřezy i kompletní plocha sledovaného území reprezentuje i přes výskyt pouze tří výše definovaných druhů velmi složitý charakter zemské plochy spočívající ve velmi rozmanitém výskytu drobných ploch všech výše uvedených povrchů. V obou výřezech tak můžeme pozorovat výskyt všech druhů na velmi malé rozloze. Například při detailnějším pozorování můžeme spatřit tmavé objekty mezi poměrně homogenním suchým travním porostem pevniny, tyto objekty představují půdní pokryv. Složitý charakter zemské plochy můžeme spatřit i v případě vizuálního znázornění terénu (obrázek 14) v předchozí podkapitole. V tomto případě můžeme pozorovat výskyt všech uvedených skupin (travní porost, půdní pokryv a vodní plocha) v mokřadním korytu. Na komplikovanosti provedení ruční identifikace těchto výřezů také značně přispívá skutečnost, že získané obrazové záznamy byly vytvořeny ve značném detailu o vysoké prostorové rozlišovací schopnosti (např. v obrazových datech lze pozorovat i stébla travního porostu zasahujících do vodní plochy). Na základě těchto uvedených faktů bude proces ruční identifikace rozdělen do dvou úrovní.

##### ▪ Ruční identifikace povrchu v první úrovni


V rámci první úrovně byla provedena identifikace všech zastoupených ploch vůči celkové velikosti výřezu. K tomuto dosažení byla pro každý povrch vytvořena nová vrstva typů „shapefile“. V těchto nově vzniklých vrstvách bylo provedeno ruční vykreslení polygonů, které korespondují s rozlohou jednotlivých povrchů první úrovně. Výsledek této operace pro první výřez znázorňuje obrázek 16.



Obrázek 16 - Ruční identifikace první úrovně výřezu 1

Zdroj: Vlastní zpracování

Pro rozeznání hranic bylo využito tří vrstev. První vrstva představovala samotný výřez ve skutečné podobě, tedy zobrazení odpovídající barevnému prostoru RGB. Druhá vrstva byla vytvořena transformací RGB barevného modelu do černobílého. Poslední vrstva byla vytvořena převodem barevného prostoru RGB do zobrazení HSV. Následně bylo provedeno již výše uvedené ruční vykreslení všech polygonů. Tyto vrstvy jsou znázorněny formou obrázku 17.



Obrázek 17 - Výřez 1 v jiných barvách zobrazení

Zdroj: Vlastní zpracování

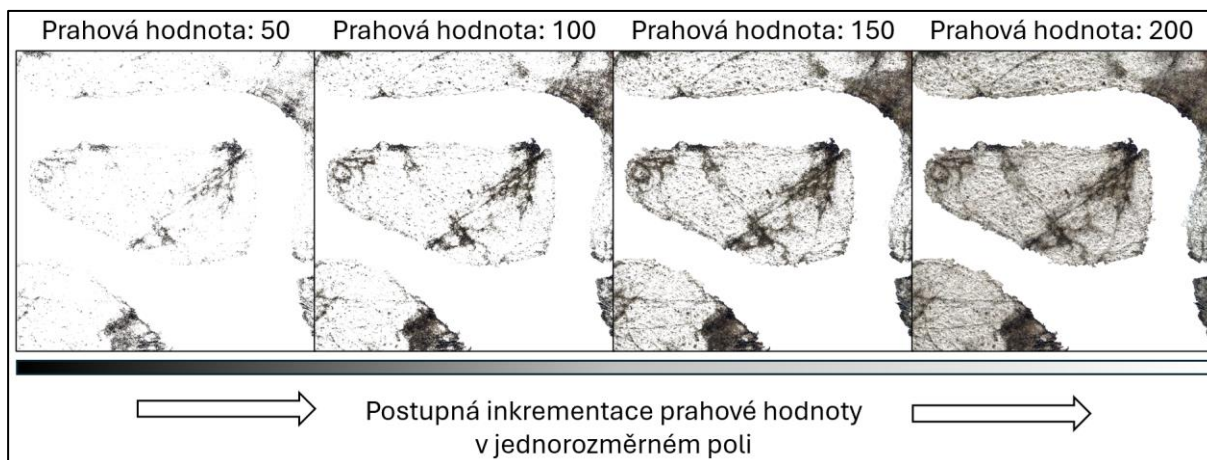
### ▪ Ruční identifikace povrchu druhé úrovně

Druhá úroveň má na rozdíl od první úrovně za cíl identifikovat již výše uvedené rozmanité malé plochy jednotlivých povrchů. Pro toto dosažení se vycházelo zejména z předpokladu, že v získaných polygonech představující pevninu jsou jednotlivé povrchy zastoupeny pouze dvěma druhy, a to suchým travním porostem a půdním pokryvem. Oba uvedené druhy jsou od sebe v rámci polygonů představující pevninu poměrně dobře rozpoznatelné, neboť travní porost se vyznačuje hlavně světlou RGB reprezentací. Naopak půdní pokryv inklinuje k tmavým hodnotám RGB. Toto platí i v případě mokřadního koryta s rozdílem, že v této oblasti se vyskytuje i vodní plocha. Na základě tohoto popisu bylo v rámci druhé úrovně využito zejména bodového zvýraznění v podobě prahování.

Výřezy byly nástrojem „Clip Raster“ oříznuty na rozsah ručně vytvořených polygonů z předchozí úrovně. Tímto byly získány obrazová data jednotlivých polygonů ve skutečném zobrazení o stejné velikosti jako původní výřezy, tedy o velikosti 3061 x 3061 pixelů. Hodnoty mimo polygony byly nastaveny na tzv. „No Data“, která jsou v případě barevného prostoru RGB výpočetně čtena jako černá hodnota (poměr v rámci 8 bitové barevné hloubky představuje hodnotu RGB = [0],[0],[0]). Využití samotného prahování bylo realizováno pomocí jednoduchého skriptu v programovacím jazyku Python. Tento skript načtl obrazový záznam jednotlivých polygonů ve skutečném zobrazení, následně došlo ke konverzi pixelů z barevného prostoru RGB do černobílé reprezentace, kde jsou jednotlivé pixely interpretovány ve stupních šedi. Poté skript našel unikátní hodnoty stupňů šedi (v případě 8 bitové hloubky se jednalo o unikátní hodnoty z rozsahu 0 až 255), které jsou zastoupeny v jednotlivých polygonech a uložil je do jednorozměrného pole. Skript následně provedl vygenerování masky pomocí prahování, kde hodnotou prahu byly jednotlivé prvky jednorozměrného pole. Poté provedl rastrové vymaskování získaných masek vůči skutečnému RGB zobrazení jednotlivých polygonů.

Výsledkem této operace bylo automatické vygenerování nových obrazových záznamů, ve kterých byly zachyceny pouze pixely skutečného zobrazení na základě hodnoty prahování černobílého snímku. Tato operace byla jednotlivě provedena pro všechny definované polygony z první úrovně. Ruční identifikace poté spočívala ve výběru nejreprezentativnějších obrazových záznamů v každé vygenerované sekvenci jednotlivých ploch polygonů. Obrázek 18 znázorňuje tento proces pro polygon „Pevnina – Suchý travní porost“ výřezu 1 po operaci maskování, kdy jsou znázorněny pouze pixely v pravých barvách odpovídající hodnotě masky s prahovou

hodnotou 50, 100, 150 a 200, které se nacházejí v sekvenci unikátních zastoupení stupně šedi 0 až 255 pro již zmíněný polygon „Pevnina – Suchý travní porost“ výřezu 1.



Obrázek 18 - Postupné prahování

*Zdroj: Vlastní zpracování*

Takto uvedený proces byl proveden pro polygony „Pevnina – Půdní pokryv“ a „Pevnina – Suchý travní porost“. Ve kterém se v případě „Pevnina – Půdní pokryv“ hledala nejvhodnější vizualizace malých trsů trávy a drobných travních stébel. Naopak pro polygon „Pevnina – Suchý travní porost“ se hledala nevhodnější reprezentace drobných výčnělků půdního pokryvu.

Pro polygon „Mokřadní koryto“ byla situace trochu komplikovanější z důvodu obsazenosti všech tří povrchů v této oblasti. Vodní plocha vykazuje nejtmaší vizuální interpretaci a v některých oblastech se stává s čím dál menší hladinou o trochu světlejší. Naopak travní porost vykazuje nejsvětlejší odstíny. Mezi tmavým odstínem vodní plochy a světlým odstínem travního porostu se nachází zastoupení půdního pokryvu, které se ze své podstaty spíše blíží tmavším hodnotám. Z tohoto důvodu muselo být prahování polygonu mokřadního koryta rozděleno do dvou typů. První typ prahování byl proveden analogickým postupem jako v případě ostatních výše uvedených polygonů. Druhý typ prahování byl proveden s invertovanou maskou, kdy výsledek maskoval opačné hodnoty masky. Pro případ prvního typu prahování byla provedena selekce nejvhodnější interpretace vodní plochy. V rámci druhého typu prahování se jednalo o výběr nejvhodnější vizualizace suchého travního porostu. Interval mezi dolním (první typ) a horním (druhý typ) prahem byl označen jako prozatím neidentifikovatelný. Následně byl tento interval rozčleněn do vodní plochy, půdního pokryvu a suchého travního porostu.



Selektovaným snímkům z jednotlivých sekvencí prahování byl přidělen informační význam s následným sjednocením všech výsledků do jedné obrazové vrstvy. Takto získaná vrstva byla manuálně doladěna v „ArcGIS Pro“ za využití nástroje: „Pixel Editor“. Doladění se především týkalo kontroly a označení intervalu prozatím neidentifikovatelných pixelů v mokřadním korytu a editací informačních tříd na hranici polygonů. Po této operaci vznikly tematické mapy ruční identifikace pro výřez číslo 1 a výřez číslo 2. Tyto výsledky vizuálně znázorňuje příloha D a příloha E.

#### **4.5 Vytvoření kontrolních bodů pro vyhodnocení přesnosti**

Předtím, než bude v rámci vlastního zpracování přistoupeno k využití jednotlivých algoritmů automatické klasifikace a interpretaci jejich výsledků včetně souvisejícího posouzení přesnosti, bude provedeno vygenerování kontrolních bodů. Kontrolní body představují určité množství pixelů o jednotkové velikosti vygenerovaných do analyzovaných obrazových dat, které jsou v případě vyhodnocení přesnosti klasifikace definovány dvěma atributy. Prvním atributem představuje skutečnou informační třídu, tzv. „Ground Truth“ hodnotu. Druhým atributem představuje hodnotu informační třídy přidělenou klasifikátorem po provedení klasifikace.


Pro výše uvedené byl v softwaru „ArcGIS Pro“ využit nástroj: „Create Accuracy Assessment Points“, který provede náhodné vygenerování zadaného počtu kontrolních bodů do stanoveného vstupu. Vstupním rastrem do tohoto nástroje musí být tematická mapa, která může představovat referenční mapu obsahující skutečné hodnoty informačních tříd nebo výslednou tematickou mapu po provedení klasifikace. Od těchto variant se dále liší, jak velkou mírou zasahuje zpracovatel do kontrolní činnosti. V případě první varianty je ke kontrolním bodům při jejich vygenerování zároveň také přidělena „Ground Truth“ hodnota na základě referenční tematické mapy. V rámci druhé možnosti jsou kontrolní body vygenerovány z výsledku provedené klasifikace, zpracovatel poté v případě těchto bodů musí provést ruční kontrolní činnost a přidělit „Ground Truth“ hodnotu manuálně.

Nástroje pro vytvoření kontrolních bodů také dovoluje nastavit strategii náhodného generování, která může být:

- Stratified Random,
- Equalized Stratified Random,
- Random.

V prvním případě bude vygenerované množství kontrolních bodů pro každou třídu úměrné velikosti zastoupení této třídy v tematické mapě. V druhém případě je celkový počet

kontrolních bodů rovnoměrně rozdělen do všech tříd. Posledním případem jsou kontrolní body, kterou jsou náhodně rozdělené bez jakékoliv souvislosti s třídami. Použití nástroje pro účely vlastního zpracování bylo provedeno s variantou referenční tematické mapy na vstupu. Strategie náhodného generování byla zvolena na „Random“ s navýšením výchozího počtu kontrolních bodů (z 500 na 1 000 kontrolních bodů). Vygenerované kontrolní body pro první výřez znázorňuje obrázek 19. Tyto body budou také v obou výřezech manuálně překontrolovány. Důvodem této kontroly je minimalizace a případné nalezení chyb, které mohli vzniknout v rámci procesu ruční identifikace i přes finální editaci pixelů. Kontrolní body budou následně s využitím nástroje „Update Accuracy Assessment Points“ aktualizovány o hodnoty informačních tříd, které byly přiděleny jednotlivými klasifikátory.



Obrázek 19 - Vygenerování kontrolních bodů do výřezu 1

*Zdroj: Vlastní zpracování*

## 4.6 Zvýraznění množství informace v obrazových datech

Následující podkapitola popisuje snahu o docílení navýšení množství informace v obou stanovených výřezech. Na oba výřezy bylo aplikováno několik RGB vegetačních indexů pracujících pouze s pásmy viditelného spektra, tedy hodnotou: R – červeného, B – zeleného a B – modrého kanálu. RGB indexů existuje poměrně značné množství a ve většině případů tyto indexy zvýrazní jen konkrétní druh povrchu. V rámci vlastního zpracování byl proveden výběr následující indexů, které byly použity na oba vstupní výřezy: ExGI, GLI, NGRDI, RGBVI, TGI a VARI. Následně byly vyselektovány indexy, ve kterých se nejvíce odrazilo zesílení zvýraznění jednotlivých povrchů. Tento výběr byl posouzen pouze na základě vizuálního zhodnocení. Výsledky aplikace těchto RGB indexů jsou znázorněny formou obrázku 20 pro výřez 1 a obrázku 21 pro výřez 2. Tyto indexy jsou následující:

- Triangular Greenness Index (TGI)

$$TGI = G - (R \cdot 0,39) - (B \cdot 0,61)$$

*Rovnice 3 - Index TGI*

*Zdroj: (Fuentes-Peailillo, 2018)*

- Normalized Green Red Difference Index (NGRDI)

$$NGRDI = \frac{(G - R)}{(G + R)}$$

*Rovnice 4 - Index NGRDI*

*Zdroj: (Fuentes-Peailillo, 2018)*

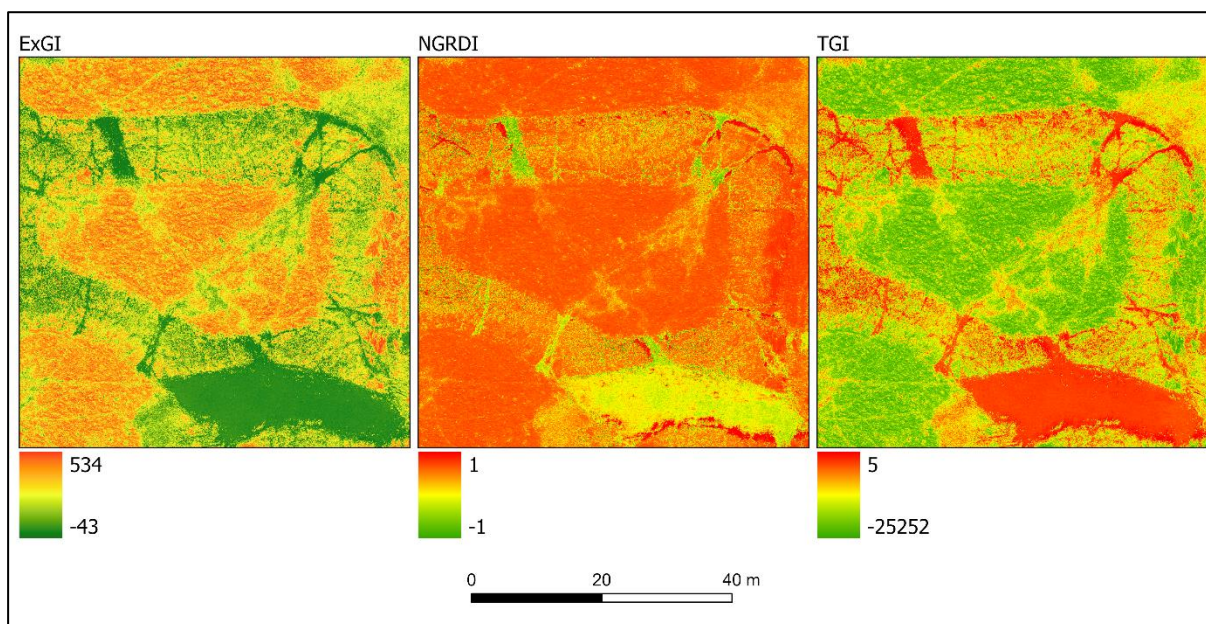
- The Excess Green Index (ExGI)

$$ExGI = (2 \cdot G) - (R - B)$$

*Rovnice 5 - Index ExGI*

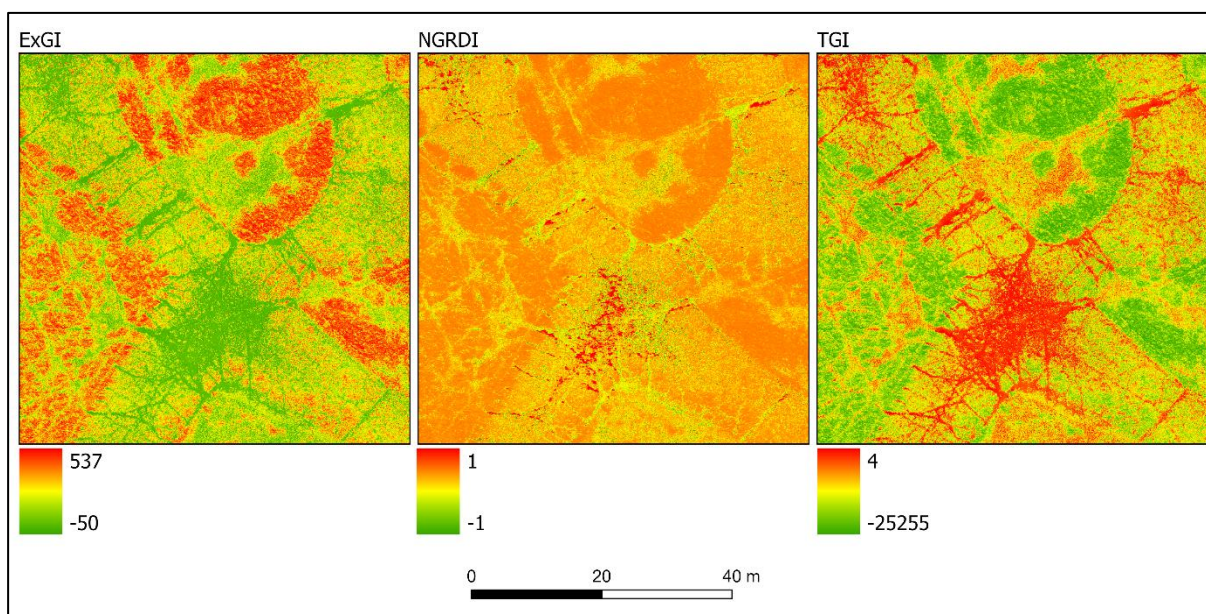
*Zdroj: (Komárková, 2020)*

K samotnému výpočtu v softwarovém nástroji „ArcGIS Pro“ můžeme pro docílení vytvoření RGB indexů využít nástroj „Band arithmetic function“ z karty „Raster function“. Tento nástroj mimo vestavěné indexy také zahrnuje možnost využití definování vzorce indexu od uživatele. Pro případ uživatelsky zadaných vzorců jsou povolenými operátory pouze základní matematická symboliky: sčítání, odčítání, násobení a dělení. V případě potřeby využití matematicky složitějších funkcí může být využito nástroje „Raster Calculator“ z rozšíření „Spatial analyst“ nebo také „Image analyst“. Pro případ využití výše definovaných vzorců pro vytvoření RGB indexů byl použit první zmíněný nástroj, který dostatečně pokrývá symboliku výše uvedeného.



Obrázek 20 - Ukázka aplikování RGB vegetačních indexů pro výřez 1

Zdroj: Vlastní zpracování



Obrázek 21 - Ukázka aplikování RGB vegetačních indexů pro výřez 1

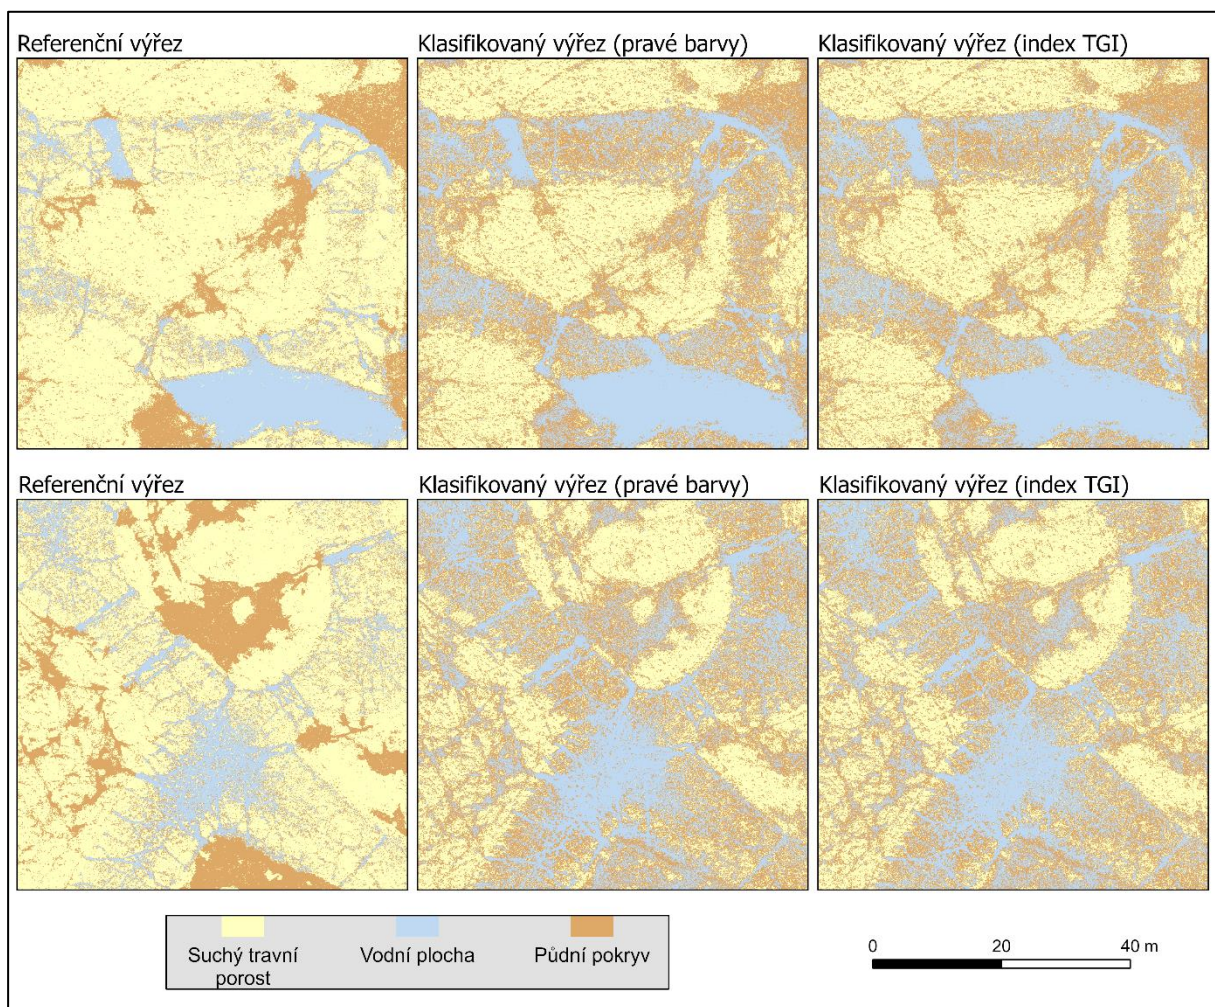
Zdroj: Vlastní zpracování

## 4.7 Neřízená klasifikace

Jak bylo popsáno v úvodní části vlastního zpracování, přístup neřízené klasifikace je realizován prostřednictvím klasifikačního algoritmu „Iso Cluster“. Tento klasifikátor je založena na iterativně optimalizačním procesu shlukování jednotlivých pixelů v rastrovém datovém

souboru do předem stanoveného počtu shluků. Proces iterativní optimalizace spočívá v přepočítávání centroidů jednotlivých klastrů po každém přiřazení všech jednotlivých pixelů do shluků. Výsledné finální vytvořené klastry poté představují jednotlivé klasifikační třídy, kterým musí být přidělen informační význam.

V „ArcGIS Pro“ byl z Toolboxu „Spatial Analyst“ v kategorii „Segmentation and Classification“ vybrán klasifikátor „Iso Cluster“. Tento klasifikátor byl mimo parametr „Max Number Of Classes“ ponechán ve výchozím nastavení. Měněný parametr, který stanovuje množství výsledných informačních tříd byl nastaven na žádaný počet klasifikačních tříd, tedy hodnotu 3.



Obrázek 22 - Neřízená klasifikace Iso Cluster

Zdroj: Vlastní zpracování

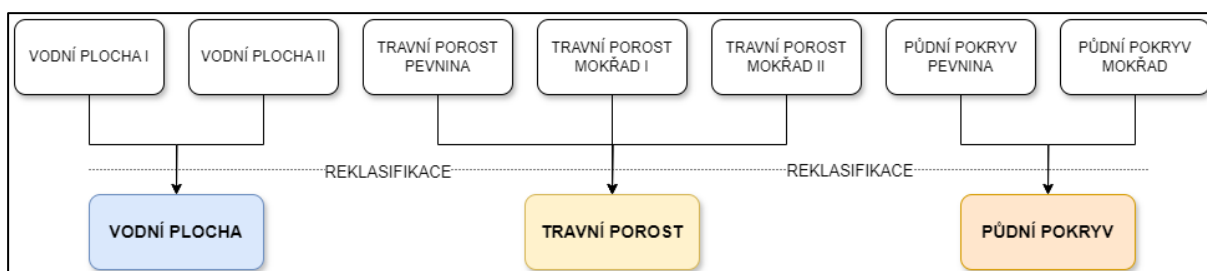
Výsledky aplikace tohoto klasifikátoru jsou pro jednotlivé vstupní výřezy (dva výřezy oblasti v pravých barvách a dva výřezy odpovídající zvýrazněním RGB indexem TGI) znázorněny

formou obrázku 22. Mimo tuto vizuální interpretaci bylo provedeno vytvoření chybových matic z kontrolních bodů, které jsou znázorněny v rámci přílohy H (chybové matice 1 až 4).

Prostřednictvím zhodnocení pouhé formy vizuální interpretace (obrázek 22) jsou patrné poměrně značné rozdíly mezi referenčními a klasifikovanými výřezy. Tyto odlišnosti jsou zejména patrné mezi vodní plochou a půdním pokryvem v rámci pevniny, kdy můžeme pozorovat výskyt vody místo holé půdy. V případě mokřadního koryta můžeme pozorovat značnou absenci suchého travního porostu, kterého v rámci klasifikovaných výsledků nahradil zejména půdní pokryv a také částečně vodní plocha. Uvedené vizuální zhodnocení koresponduje s výsledky chybových matic, ve kterých můžeme v této souvislosti pozorovat nízké procentuální hodnoty přesností z pohledu uživatele (PU) a přesností z pohledu zpracovatele (PZ). Ze vzniklých tematických map můžeme dále konstatovat, že skutečný výskyt vodní plochy byl v rámci provedené klasifikace identifikován správně, to potvrzuje i výsledek 100 % přesnosti z pohledu zpracovatele (PZ) ve všech chybových maticích. Ovšem očekávaný výsledek výskytu vodní plochy byl ve větší míře zkreslen chybnou klasifikací z výše uvedených důvodů. O tomto vypovídá i přesnost z pohledu uživatele (PU) chybových matic, která se pohybovala v rozmezí 44,52 % (nejhorší hodnota) až 56,04 % (nejlepší hodnota).

#### 4.8 Příprava trénovacích dat pro provedení řízené klasifikace

Vzhledem k charakteristice povrchu byla trénovací množina pro klasifikaci výřezů zachycující oblast v pravých barvách rozdělena na sedm informačních tříd, které budou následně reklasifikovány do tří tříd reprezentující tři sledované druhy povrchů. Toto uskupení znázorňuje obrázek 23.




Obrázek 23 - Dekompozice hlavních sledovaných tříd v rámci řízené klasifikace

*Zdroj: Vlastní zpracování*

Pro vytvoření trénovací množiny byla využito nástroje „Traning Sample Manager“ implementovaného v „ArcGIS Pro“ na kartě „Imagery“ v sekci „Classification Tools“.

V rámci tohoto nástroje bylo vytvořeno nové schéma zahrnující výše uvedený seznam podtříd. Následně bylo pomocí polygonů provedeno vytvoření jednotlivé trénovací plochy.

Celkem bylo v rámci vytvoření trénovacího datasetu pro výřez 1 označeno 33 trénovacích ploch, které jsou nepravidelně rozděleny na sedm podtříd. Všechny tyto označené plochy představují celkový počet 9 939 pixelů, v průměru tak představuje 1 trénovací plocha 301 pixelů. Malý rozměr trénovacích ploch byl zvolen z důvodu jistější eliminace stejných RGB hodnot v rozdílných třídách, které by vzhledem k charakteristice území a obrazových záznamů o vysokém prostorovém rozlišení mohly nastat. Kompletní trénovací množinu znázorňuje pro výřezu 1 obrázek 24. Vzhledem k poměrně značné nepřehlednosti těchto ploch vůči celému rozsahu pozorovací scény plynoucí z obrázku 24 bude v následujícím textu tento trénovací dataset popsán detailněji jednak formou textového popisu a i vizuální interpretace v podobě jednotlivých dlaždic zachycující vytvořené trénovací polygony.




Obrázek 24 - Trénovací plochy výřezu 1 v pravých barvách

Zdroj: Vlastní zpracování

- **Podtřídy stanovující půdní pokryv**

Půdní pokryv byl rozčleněn na dvě podtřídy v závislosti na výskytu, buď jako součást mokřadního koryta („Půdní pokryv mokřadu“) nebo jako součást pevniny („Půdní pokryv pevniny“). Pro „Půdní pokryv mokřadu“ je oproti druhé podtřídě typický tmavší projev barevných odstínů. Naopak podtřída „Půdní pokryv pevniny“ má poměrně různorodější barevný projev. Trénovací plochy pro tyto podtřídy jsou znázorněny na obrázku 25.



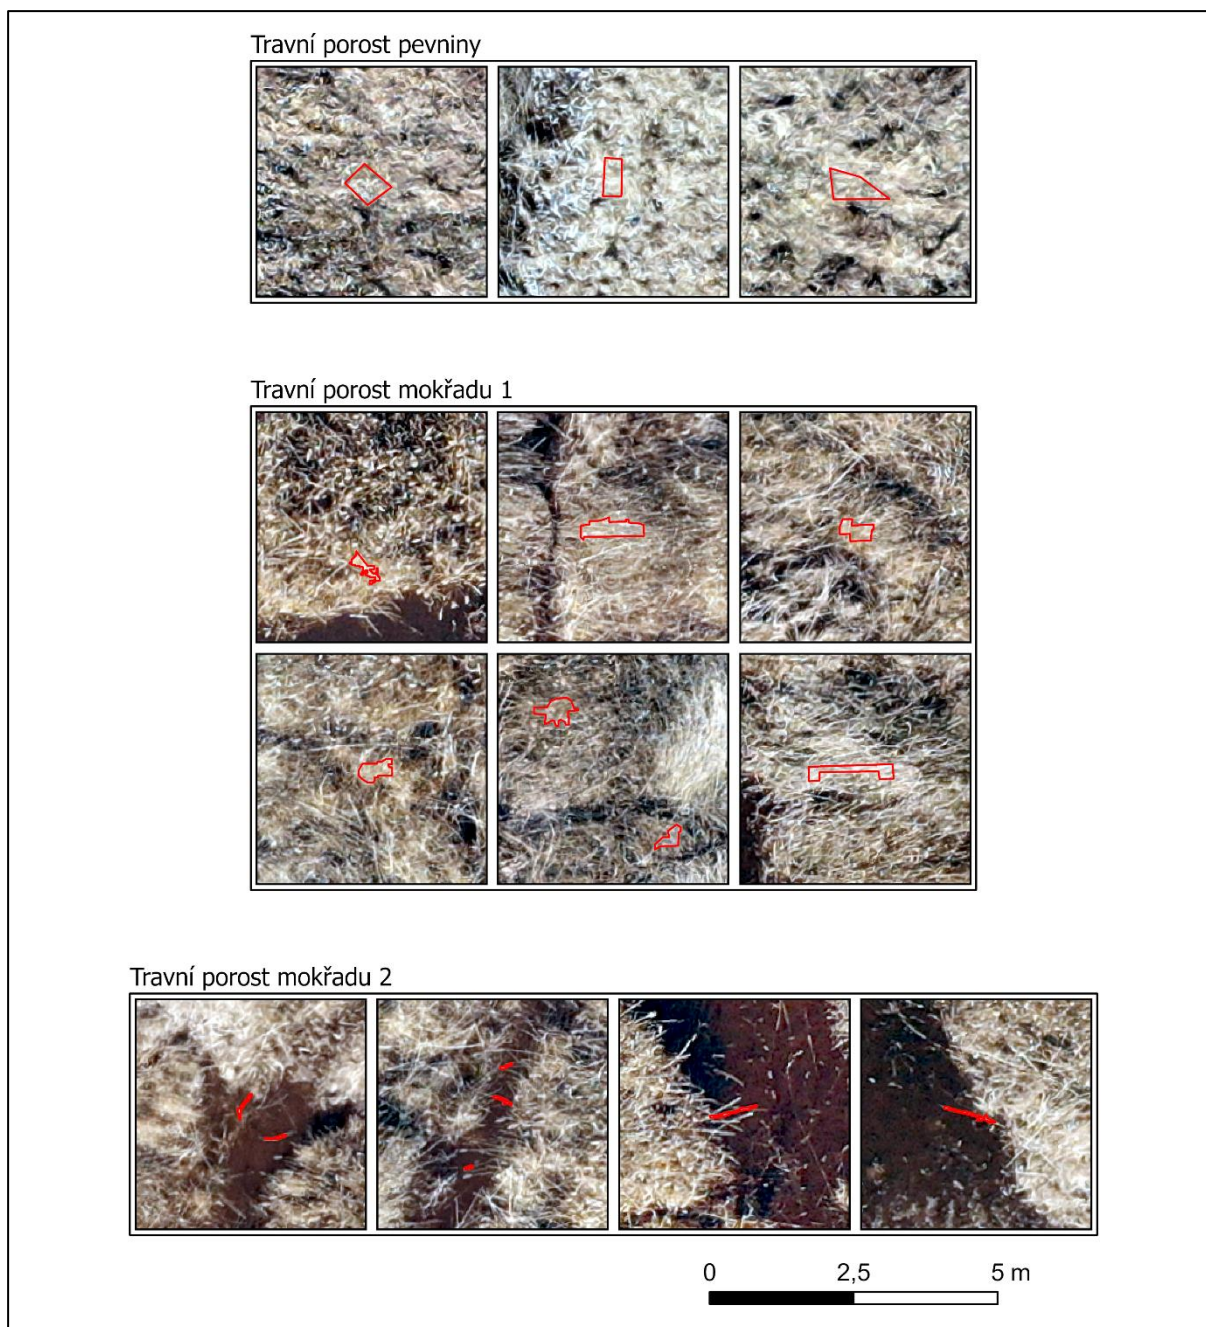
Obrázek 25 - Podtřídy půdního pokryvu

Zdroj: Vlastní zpracování

- **Podtřídy stanovující travní porost**

Pro travní porost je vyčleněná samostatná podtřída v případě pevniny. Zbylé dvě podtřídy představují travní porost mokřadního koryta, který v rámci podtřídě „Travní porost mokřadu 1“ označuje větší shluky travního porostu v mokřadu. Druhá podtřída „Travní porost mokřadu 2“ je poté určen k označení drobných stébel travního porostu zasahující převážně do vodní plochy. Tento popis znázorňuje v rámci vytvořených trénovacích ploch obrázek 26.





Obrázek 26 - Podtřídy suchého travního porostu


Zdroj: Vlastní zpracování

- **Podtřídy stanovující vodní plochu**


Podtřída: „Vodní plocha 1“ představují hlubší vodní hladinu, kterou můžeme v obou výřezech pozorovat jako výskyt velmi tmavého (černého) povrchu. Z hlubší hladiny přechází plynule vodní sloupec do menší hladiny, v tomto případě můžeme vodní plochu na obrazových záznamech pozorovat jako přechod z černé do tmavě hnědé. Právě tmavě hnědá představuje

nižší vodní hladinu stanovenou jako „Vodní plocha 2“. Trénovací plochy v případě těchto podtříd jsou uvedeny formou obrázku 27.

Vodní plocha 1



Vodní plocha 2



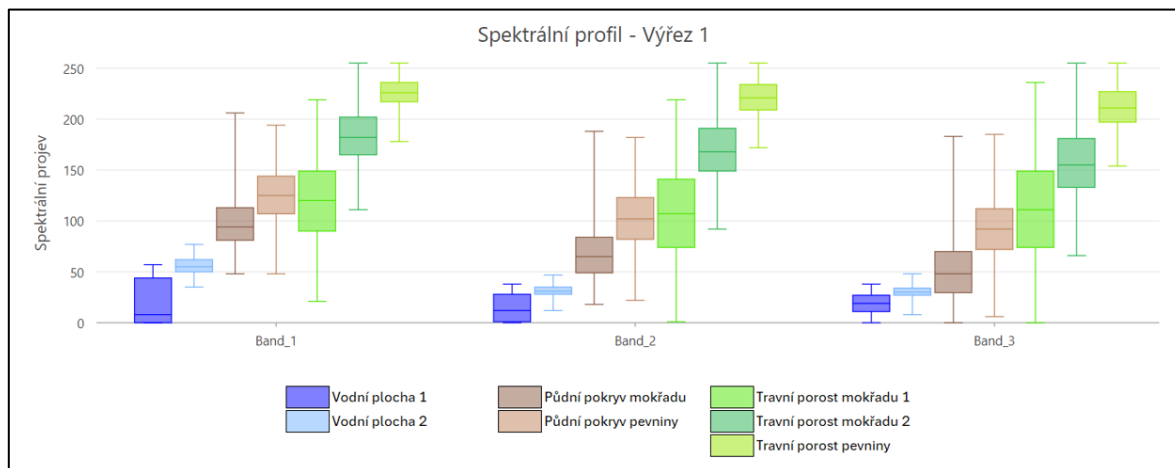
Obrázek 27 - Podtřídy vodní plochy

Zdroj: Vlastní zpracování

#### ▪ Spektrální profil trénovacího souboru

Charakteristika výše vytvořené trénovací množiny pro výřez 1 je provedena prostřednictvím krabicových grafů v jednotlivých pásmech viditelného spektra znázorňující obrázek 28. Tyto grafy ukazují hlavní problematiku zpracování obrazových záznamů získaných prostřednictvím UAV, které pracují pouze ve viditelné části spektra. Tento problém spočívá v překrývání intervalů spektrálního projevu jednotlivých trénovacích ploch. Nejvhodnějším příkladem je v tomto případě porovnání spektrálního projevu trénovací plochy označené jako „Půdní pokryv pevniny“ a „Travnímu porostu mokřadu 1“. Z pohledu DPZ by tyto trénovací plochy měly reprezentovat v určité části intervalu spektrálního projevu

obdobný druh povrch. Tato charakteristika signatur by tak vedla k závěru, že jsou definované trénovací plochy špatně stanovené a pro jeden povrch jsou vytvořené dvě trénovací plochy. Při vizuálním posouzení těchto trénovacích vzorů „Půdního pokryvu pevniny“ (obrázek 25) a „Travního porostu mokřadu 1“ (obrázek 26) je ovšem jasně zřejmé, že trénovací plochy jsou definované korektně.

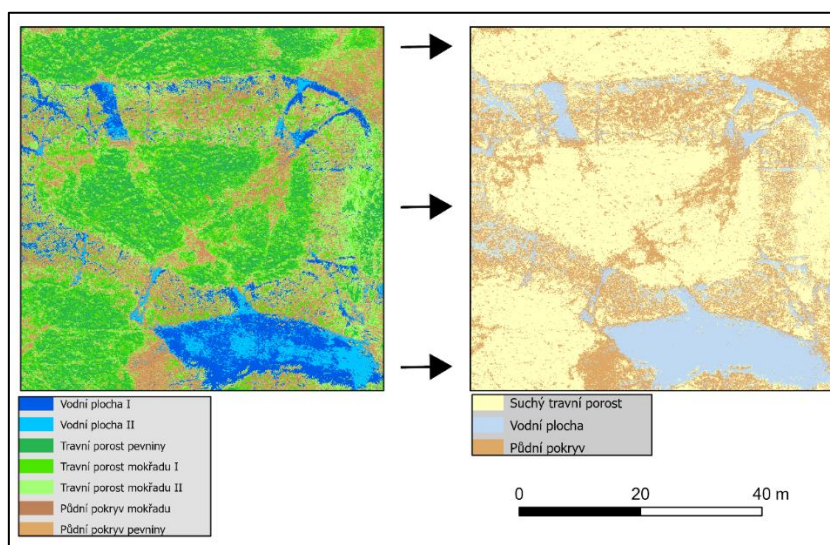


Obrázek 28 - Spektrální profil trénovacích ploch výřezu 1 v pravých barvách

Zdroj: Vlastní zpracování

### ▪ Reklasifikace

Jak bylo zmíněno v rámci popisu vytvoření trénovacích ploch pro výřezy v pravých barvách, výsledky klasifikovaných výřezů budou podrobeny následné modifikaci v podobě reklasifikace do menšího počtu o třech třídách, které budou charakterizovat sledované povrchy.



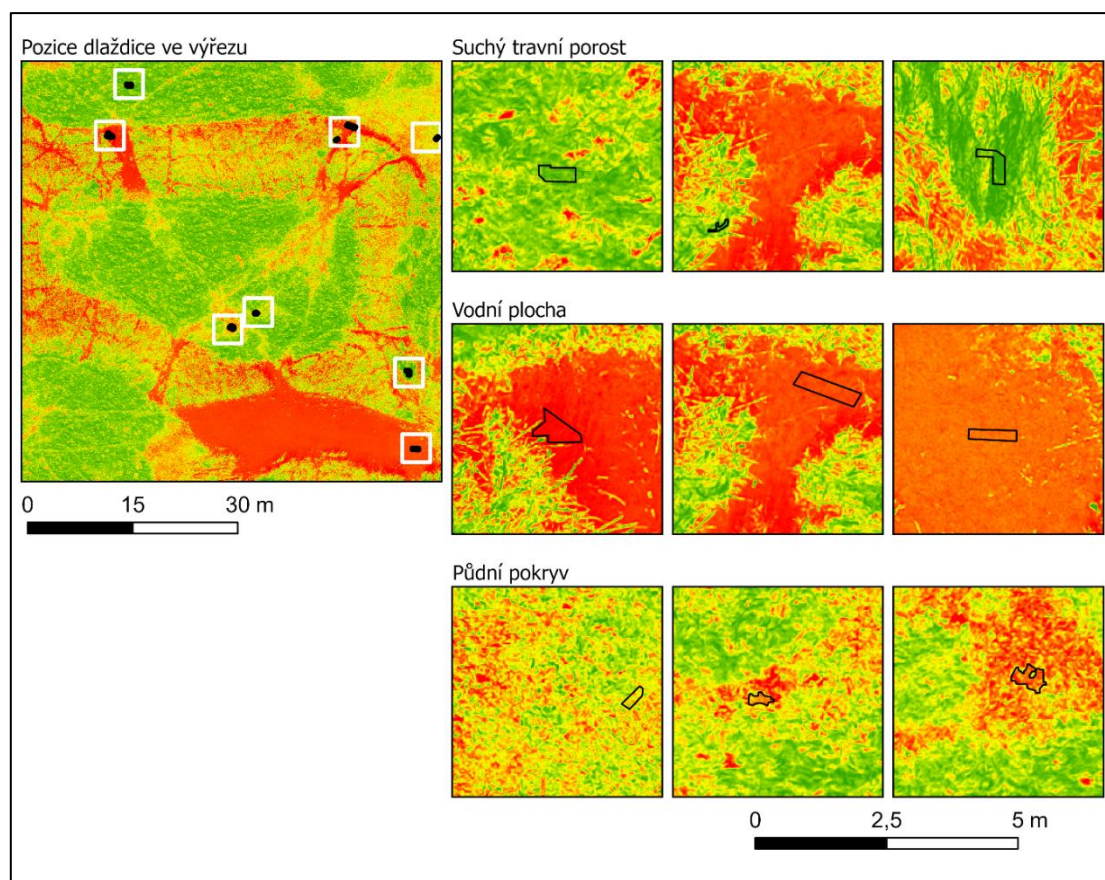
Obrázek 29 - Proces reklasifikace

Zdroj: Vlastní zpracování

Obrázek 29 znázorňuje tento proces v případě klasifikovaného výřezu 1 pomocí klasifikátoru ML nad kterým je následně provedena reklasifikace pro stanovený rozsah tříd.

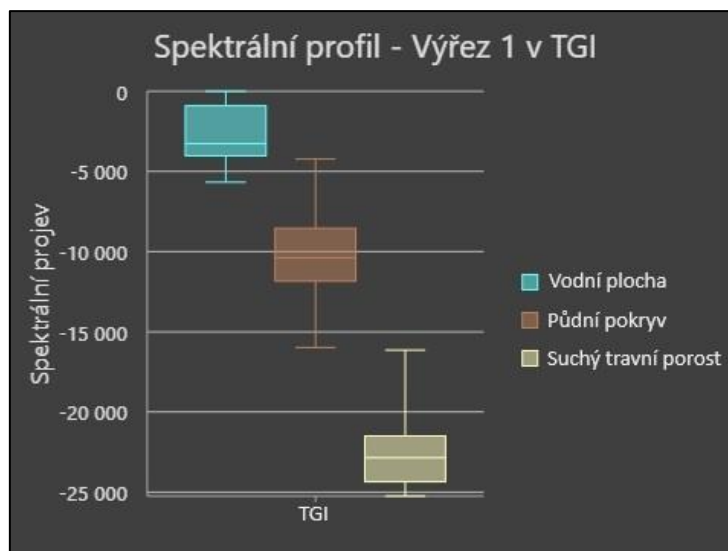
- **Trénovací plochy pro výřezy po zvýraznění indexem TGI**

Trénovací plochy pro výřezy 1 zvýrazněné s využitím RGB indexu TGI byly vzhledem k již provedeným modifikacím kategorizovány do tří tříd trénovacích vzorů. Tyto třídy reflektují sledované povrchy: Suchý travní porost, vodní plocha a půdní pokryv. V rámci tohoto vytvoření bylo nejobtížnějším stanovení trénovacích vzorů pro půdní pokryv, který v případě zvýrazněného výřezu měl nejhorší vizuální interpretaci. Obrázek 30 znázorňuje definované trénovací vzory a Obrázek 31 popisuje spektrální profil těchto trénovacích ploch.



Obrázek 30 - Trénovací plochy výřezu 1 v indexu TGI

Zdroj: Vlastní zpracování



Obrázek 31 - Spektrální profil výřezu 1 v indexu TGI

Zdroj: Vlastní zpracování

## 4.9 Řízená klasifikace

Přístup řízené klasifikace zahrnuje využití čtyřech klasifikátorů. V rámci této podkapitoly bude provedena vizuální interpretace všech výsledků získaných prostřednictvím těchto klasifikačních algoritmů a popisu jejich aplikování v softwaru „ArcGIS Pro“.

Vzhledem k poměrně nepatrným vizuálním odlišnostem zpravidla stejné povahy vyskytujících se ve všech výsledcích řízené klasifikace nebude provedeno jejich jednotlivé zhodnocení. Toto zhodnocení bude provedeno až v rámci následující podkapitoly věnované posouzení výkonnosti všech využitých klasifikačních algoritmů na základě celkové přesnosti a také pomocí Kappa koeficientu.

Celkově ovšem můžeme o těchto výsledcích a jejich vizuální intepretace konstatovat následující.

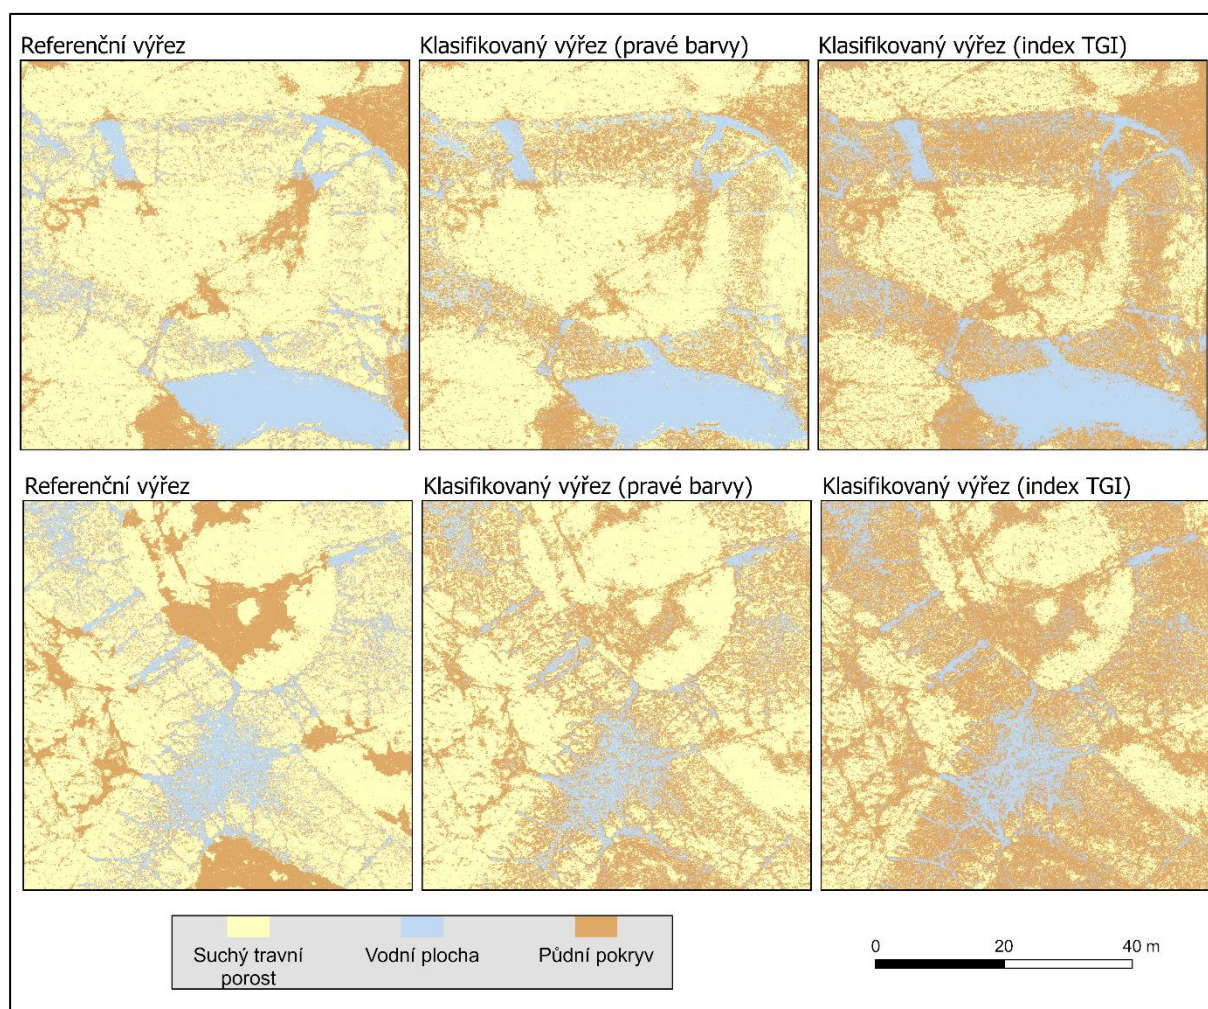
- Klasifikační algoritmy řízené klasifikace dopadly ve výsledku lépe než klasifikátor „Iso Cluster“ neřízené klasifikace.
- Ve výsledcích výřezu v pravých barvách byla pouhou vizuální interpretací pozorována lepší výkonost klasifikace než v případě výřezů zvýrazněných prostřednictvím RGB indexu TGI. To byl oproti neřízené klasifikaci rozdílný aspekt.
- Ve výsledných tematických mapách řízené klasifikace, kde vstupem byl výřez v pravých barvách se převážně projevovala absence suchého travního porostu na úkol chybně klasifikovaných pixelů jako půdního pokryvu.
- Výše uvedená absence byla pozorována výsledcích i při vstupu výřezu v zobrazení pomocí RGB indexu TGI. Tato absence byla v tomto případě u všech výsledků ještě více negativně zesílená.

Ke všem následujícím výsledným klasifikovaným výřezům bylo také provedeno vytvoření matic chybovosti, které jsou znázorněny formou přílohy H (chybová matice 5 až 20). Chybové matice ovšem byly vytvořeny zejména z důvodu výpočtu celkové přesnosti a koeficientu Kappa, jejichž hodnoty budou využity v následující podkapitole. V tomto důsledku zde nebudou dále uvažovány.

### ▪ Klasifikace Maximum Likelihood

Klasifikátor je založen na předpokladu normálního rozdělení všech shluků představující seskupení trénovací plochy odpovídajících informačních tříd klasifikačního schématu. Na základě předpokladu normality se vypočítá pravděpodobnost příslušnosti k danému rozdělení. Jednotlivé pixely jsou poté přiřazeny do informačních tříd podle nejvyšší pravděpodobnosti. (Lillesand, 2015)

V rámci použití klasifikátoru v „ArcGIS Pro“ byly vstupní parametry ponechány ve výchozích hodnotách.



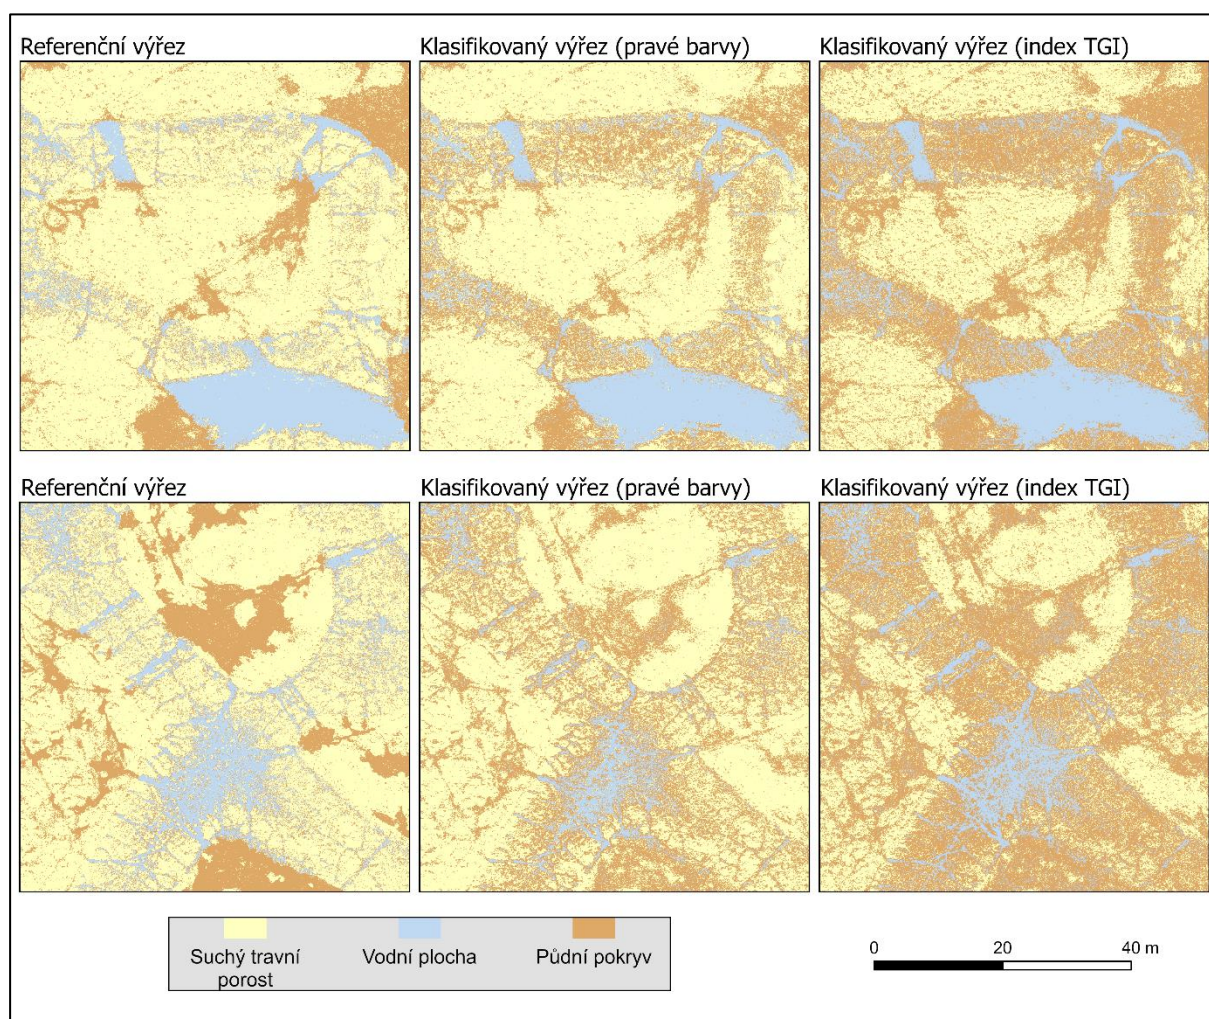
Obrázek 32 - Klasifikace Maximum Likelihood

Zdroj: Vlastní zpracování

### ▪ Klasifikátor SUPPORT VECTOR MACHINE

Klasifikátor se snaží nalézt hyperroviny, které nejlépe separují jednotlivé informační třídy v příznakovém prostoru. K identifikaci těchto rovin se používá vzdálenost mezi nejbližšími prvky odlišných informačních tříd, které jsou označovány jako podpůrné vektory. (Al-doski, 2013) Maximální rozdíl vzdálenosti mezi podpůrnými vektory jsou optimální hyperroviny. (Fan, 2023)

Při použití klasifikátoru v „ArcGIS Pro“ byl jediný vstupní parametr „Maximum Number of Samples per Class“ ponechán ve výchozí hodnotě 500.



Obrázek 33 - Klasifikátor Support Vector Machine

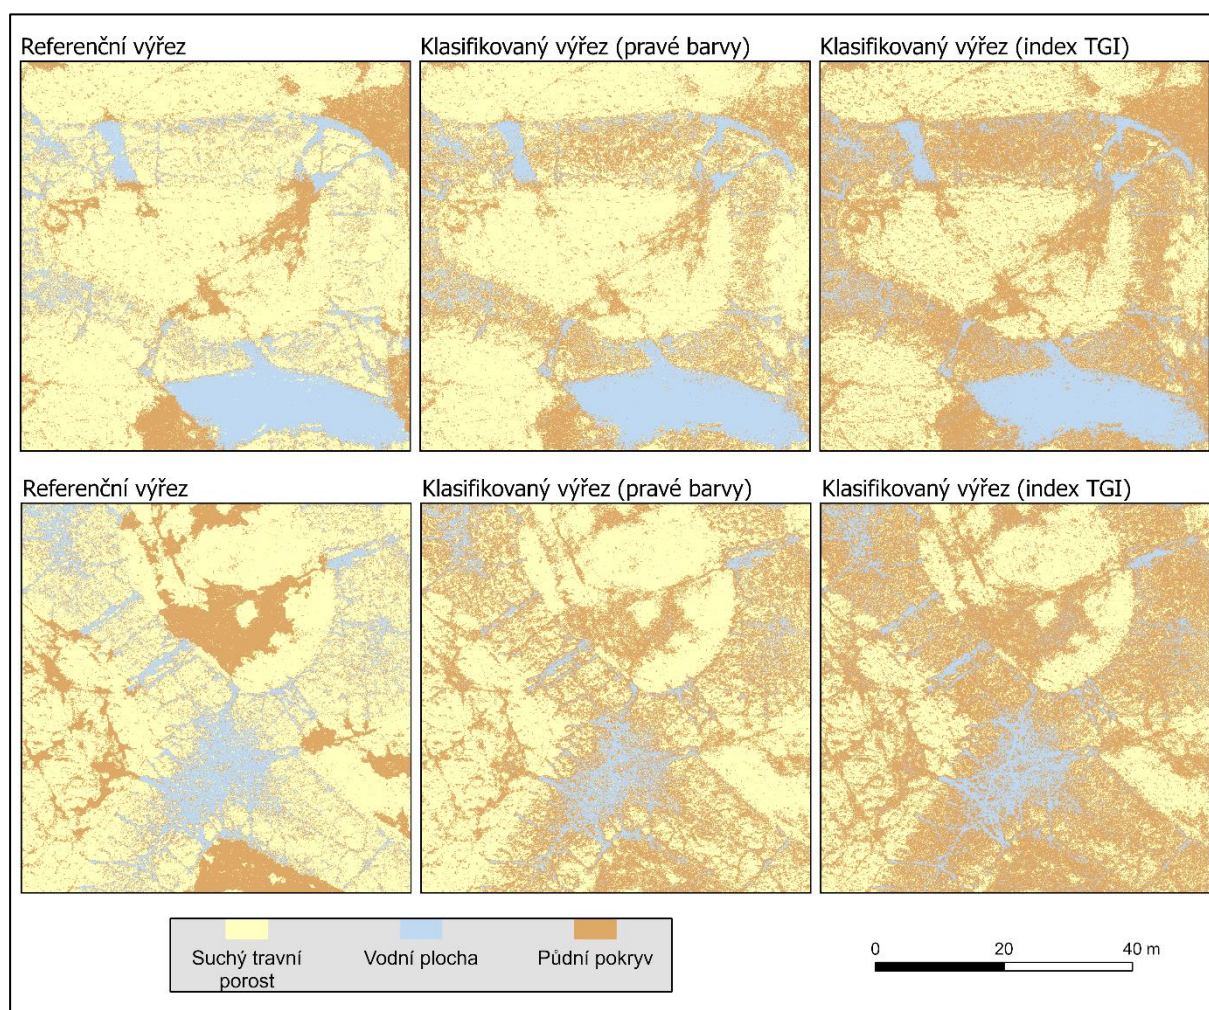
Zdroj: Vlastní zpracování



### ▪ Klasifikátor RANDOM TREES

Klasifikátor je založen na vytvoření stanoveného počtu tzv. rozhodovacích stromů, který se následně učí na různorodých podskupinách shluků trénovacích ploch. Jednotlivé rozhodovací stromy vytvářejí dílčí závěry a jsou využity jako většinový hlas ke stanovení klasifikace. (ESRI, 2021)

V rámci použití klasifikátoru v „ArcGIS Pro“ byl vstupní parametr „Maximum Number of Trees“ změněn z defaultní hodnoty 50 na hodnotu 75 a „Maximum Tree Depth“ z výchozí hodnoty 30 na hodnotu 45. Ostatní parametry byly zachovány v původním nastavení.



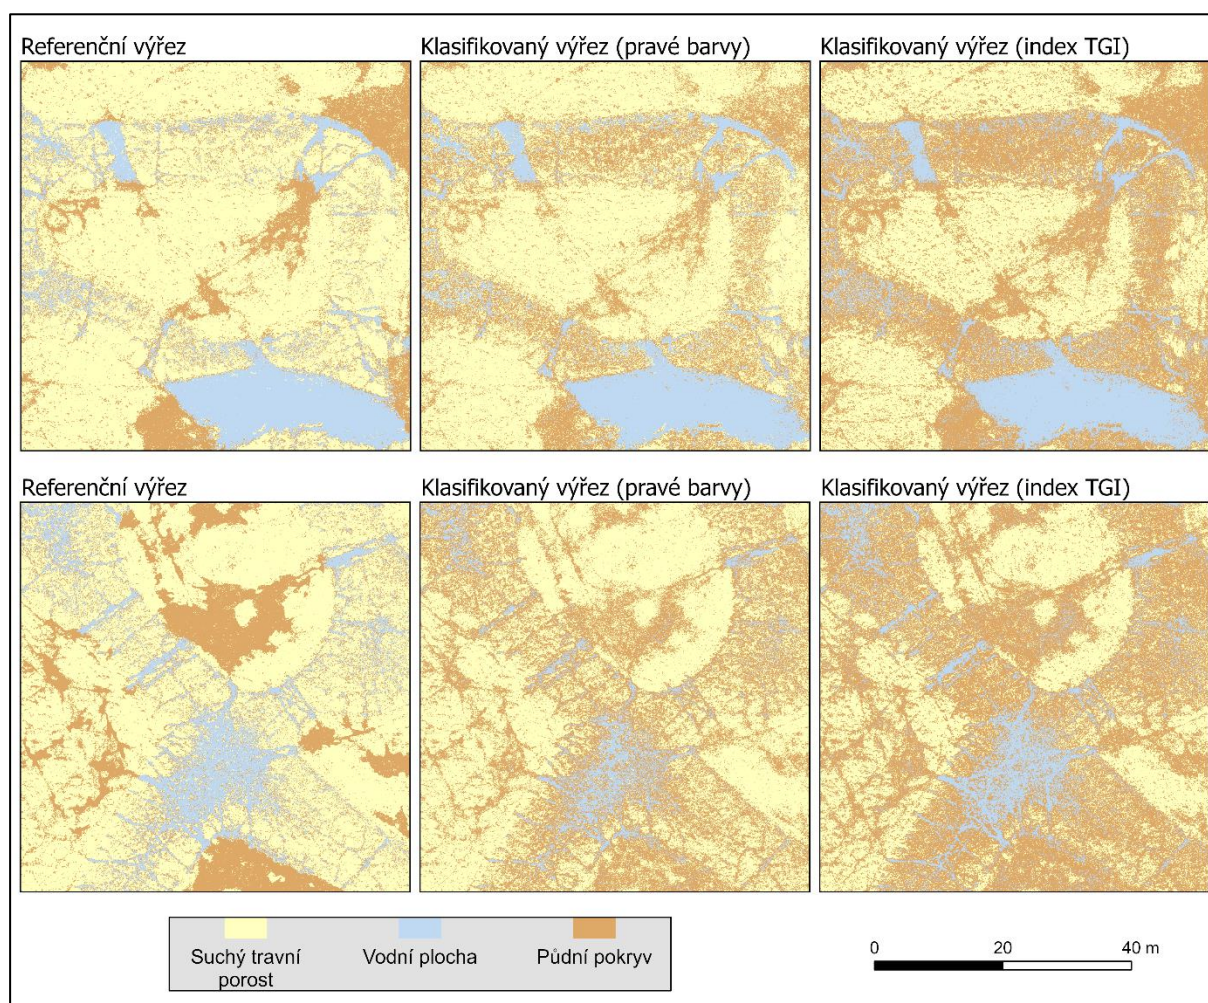
Obrázek 34 - Klasifikace Random Trees

Zdroj: Vlastní zpracování

### ▪ Klasifikátor K-NEAREST NEIGHBOR

Klasifikátor využívá modifikovaného principu určení informační třídy podle výpočtu minimální vzdálenosti centroidů, který je rozšířen o zohlednění početního zastoupení informačních tříd okolních pixelů vůči pixelu právě klasifikovanému. Tento klasifikační algoritmus, tak pro aktuální klasifikovaný obrazový bod a stanovený počet K okolních pixelů rozhodne o náležitosti podle dominance informačních tříd sousedních pixelů. (Dobrovolný, 1998)

Při použití klasifikátoru v „ArcGIS Pro“ byly všechny parametry zachovány vůči výchozímu nastavení. Zároveň také byla provedena změna vstupního parametru KNN, který stanovuje počet okolních pixelů K. Oproti výchozí hodnotě 1 bylo provedeno nastavení na hodnotu 2 a poté také na hodnotu 3. V těchto případech výsledek klasifikace vykazoval vizuálně čím dál větší nepřesnosti.




Obrázek 35 - Klasifikace K-Nearest Neighbor

Zdroj: Vlastní zpracování

## 4.10 Posouzení výsledků využitých klasifikátorů

Tato podkapitola je věnována zhodnocení dosažených výsledků získaných prostřednictvím využitých klasifikátorů. Zohledňujícím parametrem je v této souvislosti celková přesnost a koeficient Kappa vypočtených z chybových matic na základě stanovených kontrolních bodů. Tyto dva parametry jsou v následujícím textu graficky znázorněny napříč všemi pěti klasifikačními algoritmy při všech čtyřech vstupních výřezech (dva výřezy v pravých barvách a dva výřezy ve zvýraznění pomocí indexu TGI).

- **Zhodnocení celkové přesnosti zařazení stanovaného prostřednictvím kontrolních bodů**



Obrázek 36 - Graf celkové přesnosti jednotlivých výsledků


*Zdroj: Vlastní zpracování*

Shrnutí celkové přesnosti jednotlivých klasifikátorů je znázorněno formou obrázku 36. Z tohoto grafu je patrné, že celková přesnost má vyšší hodnotu v případě výřezů, kde vstupem jsou výřezy v pravých barvách RGB. Rozdíl celkové úspěšnosti byl mezi výřezy v pravých barvách a výřezy v zobrazení TGI v případě neřízené klasifikace poměrně nepatrný, ovšem tento rozdíl zesílil v případě využití řízené klasifikace. Této skutečnosti odpovídají všechny využití klasifikátory řízené klasifikace. Z pohledu celkové přesnosti se tak ukazuje,

že vhodnějším způsobem je využití vstupních obrazových dat v pravých barvách. V případě obrazových dat, kde budeme uvažovat pouze vstupní charakter dat v pravých barvách, můžeme konstatovat, že řízené klasifikační algoritmy si vedly oproti neřízeným daleko lépe. V případě všech těchto klasifikátorů pod dohledem byla při prvním výřezu překonána hranici 80 %. V případě výřezu 2 se přesnost k hranici 80 % přibližovala. Na základě výše uvedeného můžeme konstatovat, že jako nevhodnějším klasifikátorem se jeví využití ML. Hned za tímto klasifikátorem jsou nevhodnějšími klasifikátory SVM a RT.

▪ **Zhodnocení Kappa koeficientu stanovaného prostřednictvím kontrolních bodů**

Shrnutí koeficientu Kappa jednotlivých klasifikátorů je znázorněno formou obrázku 37. Trend výsledných hodnot koeficientu Kappa téměř analogicky odpovídá průběhu celkové přesnosti v obrázku 36. Obdobně bylo prokázáno, že vstupy obrazových dat v pravých barvách překonaly obrazové záznamy zvýrazněné pomocí indexu TGI. Zároveň také můžeme konstatovat, že mezi nevhodnější klasifikátory můžeme zařadit ML, SVM a RT.



Obrázek 37 - Graf Kappa koeficientu jednotlivých výsledků

Zdroj: Vlastní zpracování

Budeme-li uvažovat tabulku 2 z teoretické části definující interval koeficientu Kappa a k němu odpovídající stanovisko výsledku klasifikace. Můžeme konstatovat, že právě výsledky výše uvedených klasifikátorů spadají do intervalu 0,61 až 0,8. Výsledek klasifikace, tak můžeme označit jako skvělou shodu.

#### ▪ **Závěrečné shrnutí a stanovení nejvhodnějšího klasifikátoru**


Všechny tři klasifikátory stanovené jako nejvhodnější k provedení klasifikace formou vlastního zpracování vykazují v případě obou výřezů v pravých barvách podobné výsledky s drobnými odchylkami. Vzhledem k tomuto vyplývá pro výřez 1 nejvhodnější klasifikátor RT s hodnotou celkové přesnosti 85,4 % a Kappa koeficientu 72,89 % a pro výřez 2 nejvhodnější klasifikátor ML s hodnotou celkové přesnosti 81,30 % a Kappa koeficientu 65,28 %. Pro jednotlivé výřezy, tak vychází odlišná nevhodnější volba.

Pro účely rozhodnutí o nejvhodnějším klasifikátoru byl proveden maticový součet chybových matic pro první a druhý výřez v rámci jednotlivých klasifikačních algoritmů. Z tohoto maticové součtu byl proveden přepočítání celkové přesnosti a Kappa koeficientu. Na základě tohoto byl jako nejvhodnější klasifikátor stanoven ML s hodnotou přesnosti 83,10 % a Kappa 68,69 %. Hned za tímto algoritmem je RT s přesností 81,95 % a Kappa 66,85 % a SVM se stejnou přesností jako RT ale lehce odlišnou hodnotou Kappa 66,57 %.

#### ▪ **Vizuální interpretace chybových map**


Následující obrázek 38 a obrázek 39 představuje vizuální interpretaci přesnosti prostřednictvím tzv. map chybovosti, které vytváří tematickou mapu o dvou hodnotách. A to správně (zelených) a špatně (červených) klasifikovaných pixelech. Pro tento účel byl vytvořen skript v jazyku Python, který postupně porovnával hodnotu každého pixelu odpovídajících pozic ve výsledném rastru po výsledku automatické klasifikace vůči rastru vzniklého ruční identifikací. Na základě rovnosti, resp. nerovnosti stanovoval výslednou hodnotu pixelu v chybové mapě.

Vzhledem k početnému zastoupení možných vytvoření chybových map, jejichž počet je úměrný počtu provedení jednotlivých klasifikací a také ke skutečnosti, že v mnoha případech vykazují výsledky jednotlivých klasifikací poměrně blízké hodnoty celkové přesnosti a koeficientu Kappa by vizuální interpretace formou chybových map přinášely obdobné informace. Na tomto základě je touto formou vizualizována pouze nejvhodnější klasifikace ML při vstupních výřezech v pravých barvách (obrázek 38). Další chybovou mapou je nejméně vhodná klasifikace „Iso Cluster“ při vstupních výřezech zvýrazněných pomocí indexu TGI (obrázek 39).



Obrázek 38 - Chybová mapa klasifikace Maximum Likelihood výřezů v pravých barvách

*Zdroj: Vlastní zpracování*



Obrázek 39 - Chybová mapa klasifikace Iso Cluster výřezů v indexu TGI

*Zdroj: Vlastní zpracování*

V případě chybové mapy demonstrující nejvhodnější klasifikace (obrázek 38) můžeme pozorovat poměrně skvělé klasifikování větších vodních útvarů a suchého travního porostu. Největší problém spojený s klasifikací pixelů nastával v rámci mokřadního koryta a také v některých oblastech půdního pokryvu pevniny. Právě v těchto oblastech byl vyšší výskyt pixelů s podobným spektrálním projevem, ale jiným informačním významem.

Z chybové mapy nejméně vhodné klasifikace (obrázek 39) je patrný obdobný problém, který je ovšem v tomto případě daleko razantnější. Obě znázorněné chybové mapy v souhrnu potvrdily problematiku výskytu silných korelačních vazeb různých druhů povrchu v rámci viditelného spektra, které se v tomto případě nachází zejména v oblasti mokřadního koryta, kde je stanoven výskyt tří informačních tříd.

#### **4.11 Vyhodnocení použité metriky založené na kontrolních bodech**

Pro hodnocení přesnosti klasifikace bylo do obou analyzovaných výřezů promítnuto náhodné vygenerování kontrolních bodů, jejichž hodnoty následně utvářely chybové matice a stanovovaly tak metriku hodnocení přesnosti klasifikačních algoritmů vůči referenční ruční identifikaci. Posuzována v tomto ohledu byla zejména celková dosažená přesnost a kappa koeficient. Následující text je zaměřen na vyhodnocení této metriky založené na těchto náhodných kontrolních bodech v podobě ověření její objektivnosti. Toto posouzení bude provedeno na základě metriky, která byla vypočítána výše uvedenými kontrolními body vůči kontrolní matici z celkového počtu pixelů.

Pro vytvoření kontrolní metriky založené na celkovém počtu pixelů v jednotlivých rastrech bylo využito jednoduchého skriptu v jazyku Python. Princip tohoto skriptu je založen na skutečnosti, že veškeré vytvořené rastry vznikly z původního vstupního výřezu, a tak mají všechny obrazové záznamy stejný rozměr. Skripty bude postupně procházet jednotlivé pixely rastrů vytvořených pomocí klasifikačních algoritmů a sledovat jejich informační třídu vůči referenčnímu výřezu vzniklého ruční identifikací. Podle hodnot informačních tříd bude následně provádět inkrementaci v chybové matici. Výsledkem bude automatické vytvoření chybové matice o všech 9 369 721 pixelech (rozměru rastru 3061 x 3061). Z této matice bude následně vypočítána celková přesnost a kappa koeficient.

- **Popis Python skriptu**

Jádro skriptu tvoří vnořený for cyklus (obrázek 40), který postupně prochází pixely referenčního a klasifikovaného výřezu, tyto hodnoty ukládá do proměnných „rgb\_hodnota\_1“ a „rgb\_hodnota\_2“. Následně jsou tyto hodnoty porovnány s RGB hodnotami informačních tříd. Toto porovnání je zde z důvodu, že obrazová data z „ArcGIS Pro“ jsou pro pohodlnější manipulaci z pohledu zpracovatel (hlavně z vizuálního důvodu) exportována s použitím RGB vykreslovače, a tudíž nenesou hodnotu informační třídy (například vodní plocha), ale RGB hodnotu (například pro vodní plochu světle modrá o RGB = [191],[217],[242]), kterou je tato

třída v „ArcGIS Pro“ vykreslena. Větvené podmínky tedy zajistí zpětný převod z RGB hodnot do hodnot informačních tříd.

Hodnoty informačních tříd následně adresují index chybové matice, který je inkrementován o jedna. Chybová matic je na začátku skriptu inicializována jako nulová o rozměru počtu informačních tříd.

```
for y in range(y_smer_img_1):
    for x in range(x_smer_img_1):
        rgb_hodnota_1 = img_1[y][x]
        rgb_hodnota_2 = img_2[y][x]

        if all(rgb_hodnota_1 == trida_1):
            grnd_truth_hodnota = 0
        elif all(rgb_hodnota_1 == trida_2):
            grnd_truth_hodnota = 1
        elif all(rgb_hodnota_1 == trida_3):
            grnd_truth_hodnota = 2

        if all(rgb_hodnota_2 == trida_1):
            classified_hodnota = 0
        elif all(rgb_hodnota_2 == trida_2):
            classified_hodnota = 1
        elif all(rgb_hodnota_2 == trida_3):
            classified_hodnota = 2

        i = classified_hodnota
        z = grnd_truth_hodnota

        chybova_matic[i][z] = chybova_matic[i][z] + 1
```

Obrázek 40 - Vnořený FOR cyklus

*Zdroj: Vlastní zpracování*

Následně byly pomocí knihovny „Numpy“ vypočítány požadované hodnoty celkové přesnosti a kappa koeficientu definovaného podle rovnice (1) v teoretické části této diplomové práce. Tento výpočet znázorňuje obrázek 41.

```
# Celkový součet pixelů
celkovy_soucet = numpy.sum(chybova_matic)

# Součet hlavní diagonály
soucet_diagonaly = numpy.trace(chybova_matic)

radek_1 = numpy.sum(chybova_matic[0,:])
radek_2 = numpy.sum(chybova_matic[1,:])
radek_3 = numpy.sum(chybova_matic[2,:])
sloupec_1 = numpy.sum(chybova_matic[:,0])
sloupec_2 = numpy.sum(chybova_matic[:,1])
sloupec_3 = numpy.sum(chybova_matic[:,2])

# Výpočet celkové přesnosti
presnost = round(((soucet_diagonaly / celkovy_soucet)*100),2)

# Výpočet Kappa koeficientu
promenna_k = (radek_1*sloupec_1)+(radek_2*sloupec_2)+(radek_3*sloupec_3)
kappa_citatel = (celkovy_soucet*soucet_diagonaly)-promenna_k
kappa_jmenovatel = (celkovy_soucet*celkovy_soucet)-promenna_k
kappa = (kappa_citatel/kappa_jmenovatel)*100
```

Obrázek 41 - Výpočet celkové přesnosti a Kappa koeficientu

*Zdroj: Vlastní zpracování*



Výsledkem bylo automatické vytvoření všech chybových matic, které byly vepsané do konzole. Obrázek 42 znázorňuje porovnání metrik pro řízenou klasifikaci ML v případě výřezu 1 v pravém zobrazení RGB vůči referenční ruční identifikaci. V tomto případě byly zjištěny téměř totožné výsledky s nepatrnou odchylkou vůči metrice založené na kontrolních bodech v „ArcGIS Pro“, které je ovšem v tomto případě malého rozdílu zanedbatelné. V případě ostatních výsledků automatické klasifikace bylo zjištěno obdobné.

OBJECTID *	ClassValue	C_1	C_2	C_3	Total	U_Accuracy	Kappa	
1	1	C_1	555	0	35	590	0,940678	0
2	2	C_2	0	144	5	149	0,966443	0
3	3	C_3	102	9	150	261	0,574713	0
4	4	Total	657	153	190	1000	0	0
5	5	P_Accuracy	0,844749	0,941176	0,789474	0	0,849	0
6	6	Kappa	0	0	0	0	0	0,720362

```

[[5.235600e+06 3.195220e+05 1.650800e+04]
 [9.515020e+05 1.396110e+06 8.327900e+04]
 [3.790000e+02 6.922400e+04 1.297597e+06]]
Celková přesnost: 84.63
Kappa koeficient: 71.33

```

Obrázek 42 - Ukázka porovnání metrik

Zdroj: Vlastní zpracování

## 4.12 Postklasifikační úpravy

Jak bylo uvedeno v teoretické části, postklasifikační úpravy jsou zpravidla realizovány formou majoritizace jednotlivých pixelů vůči okolním obrazovým bodům. V případě uvažování již také zmíněné charakteristiky sledovaného území a formátu vstupních obrazových dat, které jsou o vysokém rozlišení, můžeme v obou vytvořených výřezích před klasifikací pozorovat i velmi malé seskupení pixelů představující například výčnělky stébel suchého travního porostu do vodní plochy. Této skutečnosti byla podřízena i ruční identifikace, která byla rozdělena do dvou úrovní. Na základě těchto skutečností je poměrně pravděpodobné, že majoritizační operace v rámci postklasifikační úprav mohou negativně ovlivnit výsledné klasifikované výřezy a degradovat tak původně správné výsledky.

Následující text proto bude popisovat vhodnost aplikování postklasifikační úprav vzhledem k výše uvedené složitosti vstupní obrazových dat. Toto posouzení bude provedeno na základě aplikování několika majoritních filtrů s odlišnými vstupními parametry a následného zhodnocení celkového počtu provedených změn ke kterým bude v procentuální hodnotě těchto změn vyjádřeno správné a nesprávné množství pixelů klasifikovaného výřezu před a po průběhu majoritního filtru vůči výřezu ruční identifikace.

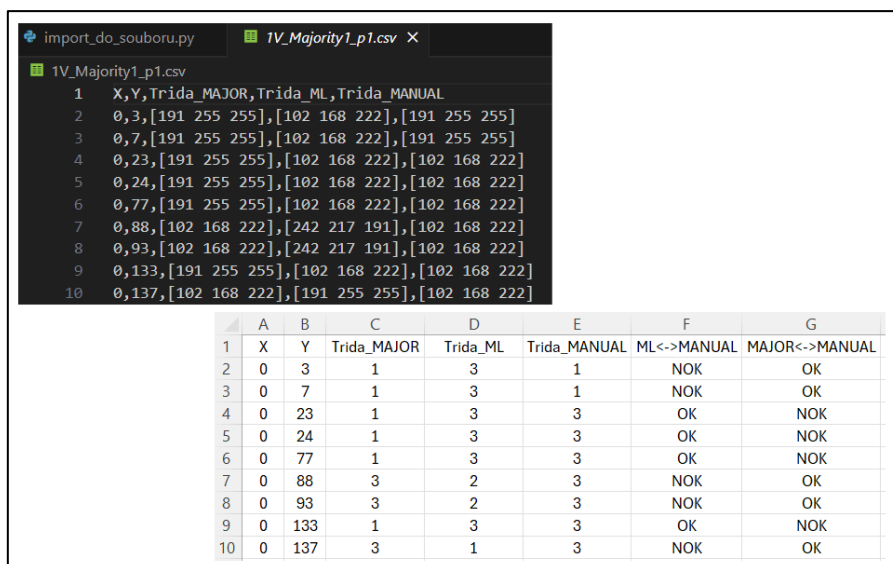
Pro objektivní posouzení bude využito dvou odlišných filtrů rozdílné logiky majoritizace, které budou na klasifikované výřezy aplikovány ve třech kaskádních průchodech, kde vstupy budou výstupy z předešlého aplikování majoritního filtru (příčemž vstup do prvního průchodu bude výsledek automatické klasifikace).

Oba typy filtrů byly vytvořeny pomocí nástroje „Majority Filter“ nacházející se v toolboxu „Spatial Analyst“ v softwaru „ArcGIS Pro“. U těchto filtrů byl definován parametr „Number of neighbors to use“ a „Replacement threshold“. První parametr udává počet okolních pixelů, které se mají uvažovat v jádře filtru. Druhý parametr stanovuje logiku majoritizace.

První filtr byl nastaven s parametrem „Four“ a „Half“. Jádrem prvního filtru tak budou čtyři ortogonální okolní pixely vůči pixelu sledovanému a k majoritizace bude docházet v případě, kdy bude mít alespoň polovina pixelů stejnou hodnotu. Druhý filtr je nastaven s parametry „Eight“ a „Majority“. Jádrem filtru, tak bude osm okolních pixelů a k majoritizace bude docházet v případě, kdy je většina pixelů stejné hodnoty. Vstup do první kaskády budou výsledky získané prostřednictvím nejvhodnější provedené klasifikace, tedy ML v pravých barvách výřezů.

Po provedení všech průběhů majoritních filtrů byly tyto výsledky exportovány z ArcGIS Pro. Následně byl nad těmito výstupy realizován skript v Pythonu. Tímto skriptem bylo provedeno postupné načtení všech výsledků majoritní filtrace, klasifikovaných výřezů před postklasifikačními úpravami a referenčních výřezů ruční identifikace. Poté běh kódu sledoval jednotlivé změny pixelů před a po aplikování majoritních filtrů. Tyto změny zapisoval do CSV souboru v podobě adresace pixelu v rastru a třech atributů představující RGB hodnotu pixelu ve všech třech načtených snímcích na odpovídajících pozicích. Výsledkem byl kompletní výpis všech pixelových změn jednotlivých výsledků kaskádní aplikace majoritních filtrů.

Soubory CSV byly načteny do MS Excel a pro snazší výpočet převedeny z RGB hodnoty do odpovídajících informačních tříd. Následně bylo dopočítáno, zda platí rovnost tříd mezi výsledkem automatické klasifikace a výsledkem ruční identifikace (sloupec: ML <-> MANUAL). A také rovnost mezi výsledkem majoritní filtrace a ruční identifikace (sloupec: MAJOR <-> MANUAL). Tento popis znázorňuje v podobě získávaných dat obrázek 43.



Obrázek 43 - Export a import CSV souborů

Zdroj: Vlastní zpracování

Výše popsané výsledky byly dány do souhrnu, který demonstruje tabulka 3. V rámci všech majoritních operací bylo provedeno poměrně značné modifikování pixelů, tento údaj poskytuje sloupec „Δ“. Tyto změny před provedením majoritizace korespondovaly s daty ruční identifikace zhruba v poměru 55 % správně začleněných pixelu (OK\_ML) a 45 % špatně začleněných pixelů (NOK\_ML). Oproti tomu poměr těchto změn po jednotlivých průchodech majoritního filtru pohyboval v rozsahu 39 – 47 % správně začleněných pixelů (OK\_MAJOR) a 52 – 62 % špatně začleněných pixelů (NOK\_MAJOR).

Výřez	Majoritní filtr	Průchod	Δ [počet pixelů]	OK_ML [%]	NOK_ML [%]	OK_MAJOR [%]	NOK_MAJOR [%]
1	První	I.	258 116	57,08	42,92	39,65	60,35
		II.	290 166	57,47	42,53	38,50	61,50
		III.	312 254	57,97	42,03	37,81	62,19
	Druhý	I.	289 279	54,17	45,83	43,31	56,69
		II.	423 215	56,11	43,89	40,84	59,16
		III.	505 672	57,19	42,81	39,49	60,51
2	První	I.	364 755	55,99	44,01	42,21	57,79
		II.	397 359	55,53	44,47	42,12	57,88
		III.	434 267	56,19	43,81	41,31	58,69
	Druhý	I.	365 918	51,83	48,17	47,48	52,52
		II.	531 787	53,21	46,79	45,88	54,12
		III.	632 467	54,04	45,96	44,90	55,10

Tabulka 3 - Porovnání správně klasifikovaných pixelů před a po majoritní filtraci

Zdroj: Vlastní zpracování


#### ▪ **Závěrečné shrnutí postklasifikačních úprav**

Výpisem unikátních hodnot z klasifikovaného snímku bylo zjištěno, že veškeré pixely byly v rámci využití klasifikace ML zařazeny do určitých tříd a žádný pixel nebyl opomenut a tím pádem neklasifikován. Postklasifikační úpravy realizované prostřednictvím majoritních filtrů ukázaly, že v případě jejich aplikace dochází ke snížení správně klasifikovaných pixelů (OK\_ML je větší než OK\_MAJOR) a tedy i k útlumu výkonnosti klasifikátoru.

Na základě výše uvedeného nebudou v rámci výsledného hodnocení dosažených výsledků tyto postklasifikační úpravy uvažovány. Vstupem pro výsledné zhodnocení a provedení analýzy zastoupení jednotlivých druhů povrchů proto zůstává přímý výsledek nejvhodnější klasifikace.

### **4.13 Výsledné zhodnocení dosažených výsledků**

Nad sledovaným územím přírodní rezervace Baroch představující výřez 1 a výřez 2 bylo v rámci vlastního zpracování zjištěno, že nevhodnějším vstupem pro automatickou identifikaci krajinného pokryvu je klasifikátor ML při vstupních obrazových záznamech v pravých barvách. Tento klasifikátor dosahoval v rámci obou výřezů průměrné celkové přesnosti 83,10 % a Kappa koeficientu 68,69 %. Tyto výsledky můžeme označit jako skvělou shodu (viz. interpretace výsledku Kappa koeficientu podle tabulky 2 v teoretické části). Při těchto výsledcích je nutno zohlednit negativní vliv některých zásadních faktorů, jako je velmi složitá charakteristika sledovaného území, zejména v případě mokřadního koryta. Dále také vysoké prostorové rozlišení zachycující v některých případech velmi malý prostorový detail a formát obrazových záznamů získaných pouze ve viditelné části spektra. V kombinaci všech těchto aspektů můžeme v souvislosti s výsledkem klasifikace zaujmout uspokojivé stanovisko. Prostřednictvím obrázku 44 je vyjádřeno procentuální zastoupení všech uvažovaných druhů povrchů v rámci výsledku ruční identifikace a nejvhodnější klasifikace ML. Z tohoto grafu můžeme pozorovat, že jednotlivé informační třídy automatické klasifikace kopírovaly trend procentuálního zastoupení ruční identifikace. V případě sledovaných vodní ploch byla v prvním výřezu vodní plocha detekována s velmi nepatrným a zanedbatelným rozdílem 0,32 %. V případě výřezu 2 byl tento rozdíl o něco větší, na hodnotě 3,31 %. V obou klasifikovaných výřezech nastalo poddimenzování ve formě menšího procentuálního zastoupení vodní plochy než v ruční identifikaci.



Obrázek 44 - Graf procentuálního zastoupení sledovaných povrchu

*Zdroj: Vlastní zpracování*

Těmto procentuálním zastoupení odpovídá v případě prostorového rozlišení o velikosti pixelu 1,5 cm tabulka 4. Vodní plocha tímto způsobem byla detekována na rozloze 205,08 m<sup>2</sup> a 124,08 m<sup>2</sup>.

	<b>Rozloha [m<sup>2</sup>]</b>			
	Výřez 1		Výřez 2	
	Manuální	ML	Manuální	ML
Suchý travní porost	928,12	835,74	879,58	815,32
Půdní pokryv	267,73	364,63	355,21	466,06
Vodní plocha	209,61	205,08	170,67	124,08

Tabulka 4 - Rozloha sledovaných povrchů

*Zdroj: Vlastní zpracování*

## ZÁVĚR

Cílem této diplomové práce byla identifikace malých vodních ploch na RGB obrazových datech s velmi vysokým prostorovým rozlišením, která byla získána prostřednictvím bezpilotních leteckých prostředků. Pro tento účel byly provedeny manipulace s obrazovými záznamy zahrnující klíčové kroky digitálního zpracování obrazu v rámci dálkového průzkumu Země.

Vstupní datový soubor představovala mozaika vzniklá z obrazových záznamů získaných během leteckého snímkování přírodní rezervace Baroch nedaleko města Pardubic v měsíci březnu 2022 s využitím bezpilotního leteckého prostředku DJI Phantom 3.

V rámci předpřípravy obrazových dat bylo provedeno vytvoření dvou výřezu ze zmíněné mozaiky, které vstupovaly do dalších fází zpracování. Na takto stanovených výřezech byla provedena dvouúrovňová manuální klasifikace vyskytujících se druhů povrchů za účelem vytvoření referenční datové vrstvy v podobě tematické mapy, která posléze sehrávala roli při posuzování výkonnosti algoritmů automatické klasifikace. V případě první úrovně manuální identifikace proběhlo ruční stanovení oblastí o převládajícím výskytu pouze jednoho povrchu. Druhá úroveň poté zahrnovala sekvenční prahování v rámci stanovených dílčích oblastí první úrovně. Víceúrovňový přístup zahrnující i sekvenční prahování byl zvolen z důvodu značně složité charakteristiky sledované oblasti a vysokého prostorového rozlišení pořízených obrazových dat.

V další fázi zpracování bylo provedeno aplikování RGB vegetačních indexů (ExGI, NGRDI a TGI) na výřezy v pravých barvách s cílem navýšit množství obsažené informace a tím i případně posílit úspěšnost algoritmů automatické klasifikace. Na základě vizuálního posouzení byl vybrán nejvhodnější výsledek (zvýraznění pomocí TGI) z této množiny zvýraznění, který se připojil k výřezům v pravých barvách a vstupoval tak do fáze automatické klasifikace.

Dále v rámci automatické klasifikace bylo využito celkem pěti klasifikačních algoritmů (Iso Cluster, Maximum Likelihood, Support Vector Machine, Random Trees a K-Nearest Neighbor), které představovaly přístup neřízené a řízené automatické klasifikace. Výstupy automatické klasifikace byly interpretovány prostřednictvím kartografické projekce za účelem vizuálního znázornění výsledků. Hodnotícím hlediskem výkonnosti klasifikátorů byl výpočet celkové přesnosti a Kappa koeficientu, který byl počítán z chybových matic vygenerovaných z atributů náhodných kontrolních bodů vytvořených nástrojem „Create Accuracy Assessment Points“. Mimo tuto hodnotící metriku bylo provedeno vizuální znázornění map chybovosti pro výsledky nejúspěšnějšího a nejhoršího klasifikátoru.

V další části bylo provedeno samotné posouzení objektivnosti metriky založené na náhodném vygenerování kontrolních bodů, která byla zhodnocena vůči metrice založené na všech pixelech. Hodnotícím hlediskem, zde byl výsledek celkové přesnosti a Kappa koeficientu obou metrik. Předposlední část zpracování pojednávala o adekvátnosti aplikování postklasifikačních úprav vzhledem k charakteru zpracovávaných dat, tedy obrazových dat o vysokém prostorovém rozlišení.

Závěr diplomové práce poté obsahoval zhodnocení dosažených výsledků včetně analýzy detekce jednotlivých druhů krajinného pokryvu. Toto bylo uskutečněno prostřednictvím vizualizace procentuálních zastoupení jednotlivých druhů sledovaných povrchů a také formou rozlohy při stanoveném prostorovém rozlišení.

## POUŽITÁ LITERATURA

- [1] AGAPIOU, Athos, Vasiliki LYSANDROU a Diofantos HADJIMITSIS, 2017. Optical Remote Sensing Potentials for Looting Detection. *Geosciences* [online]. 7(4) [cit. 2024-04-04]. ISSN 2076-3263. Dostupné z: doi:10.3390/geosciences7040098
- [2] AL-DOSKI, Jwan, Shattri MANSOR a Helmi SHAFRI, 2013. Image Classification in Remote Sensing. *Journal of Environment and Earth Science* [Online]. IISTE, 3(10), 8 [cit. 2024-03-28]. ISSN 2225-0948. Dostupné z: <https://core.ac.uk/download/pdf/234663192.pdf>
- [3] BUCHSTEINER, Claudia, Pamela Alessandra BAUR a Stephan GLATZEL, 2023. Spatial Analysis of Intra-Annual Reed Ecosystem Dynamics at Lake Neusiedl Using RGB Drone Imagery and Deep Learning. *Remote Sensing* [online]. 15(16) [cit. 2024 01-21]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs15163961
- [4] CANADA CENTRE FOR REMOTE SENSING, 2015. Fundamentals of Remote Sensing - Introduction. *Government of Canada* [Online]. 2015-11-19 [cit. 2024-01-21]. Dostupné z: <https://natural-resources.canada.ca/science-and-data/research-centres-and-labs/canada-centre-remote-sensing/21749>
- [5] Classify pixels, 2024. In: ESRI. *ArcGIS Pro* [Online]. [cit. 2024-03-28]. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/image-analyst/classify-pixels.htm>
- [6] DIEZ, Yago, Sarah KENTSCH, Motohisa FUKUDA, Maximo Larry Lopez CACERES, Koma MORITAKE a Mariano CABEZAS, 2021. Deep Learning in Forestry Using UAV-Acquired RGB Data: A Practical Review. *Remote Sensing* [online]. 13(14) [cit. 2024-01-21]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs13142837
- [7] DOBROVOLNÝ, Petr, 1998. *Dálkový průzkum Země: digitální zpracování obrazu*. 1998. Brno: Masarykova univerzita. ISBN 80-210-1812-7.
- [8] ESRI, 2021. How Random trees classification and regression algorithm works. ESRI. *ArcGIS Pro* [Online]. [cit. 2024-04-05]. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/geoai/how-random-trees-classification-and-regression-works.htm>
- [9] ESRI, 2024. Pixel Classification. ESRI. *ArcGIS Pro 3.2*. [Online]. [cit. 2024-01-21]. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/pixel-classification.htm>
- [10] FAN, Ching Lung, 2023. Ground surface structure classification using UAV remote sensing images and machine learning algorithms. *Applied Geomatics* [online]. 15(4), 919-931 [cit. 2023-12-29]. ISSN 1866-9298. Dostupné z: doi:10.1007/s12518-023-00530-x



- [11] FUENTES-PEAILILLO, F., S. ORTEGA-FARIAS, M. RIVERA, M. BARDEEN a M. MORENO, 2018. Comparison of vegetation indices acquired from RGB and Multispectral sensors placed on UAV. *2018 IEEE International Conference on Automation/XXIII Congress of the Chilean Association of Automatic Control (ICA-ACCA)* [online]. IEEE, 1-6 [cit. 2024-04-04]. ISBN 978-1-5386-5586-3. Dostupné z: doi:10.1109/ICA-ACCA.2018.8609861
- [12] FURUKAWA, Flavio, Loretta Andrew LANENG, Hiroaki ANDO, Nobuhiko YOSHIMURA, Masami KANEKO a Junko MORIMOTO, 2021. Comparison of RGB and Multispectral Unmanned Aerial Vehicle for Monitoring Vegetation Coverage Changes on a Landslide Area. *Drones* [online]. **5**(3) [cit. 2024-04-04]. ISSN 2504-446X. Dostupné z: doi:10.3390/drones5030097
- [13] GIDUDU, Anthony, Greg HULLEY a Marwala TSHILIDZI, 2007. Classification of Images Using Support Vector Machines. *ArXiv* [Online]. University of the Witwatersrand, 6 [cit. 2024-04-29]. Dostupné z: doi:10.48550/arXiv.0709.3967
- [14] HALOUNOVÁ, Lena a Karel PAVELKA, 2005. *Dálkový průzkum Země*. 2005. Praha: Vydavatelství ČVUT. ISBN 80-010-3124-1.
- [15] HORÁK, Jiří, 2014. *DÁLKOVÝ PRŮZKUM ZEMĚ (E-learningová podpora)* [Online]. Ostrava: Vysoká škola báňská – Technická univerzita Ostrava [cit. 2024-03-28]. Dostupné z: <https://homel.vsb.cz/~hor10/Vyuka/DPZ/DPZ%202014.pdf>
- [16] IBM, 2019. The basics of image processing and OpenCV. IBM. *IBM Developer* [Online]. [cit. 2024-04-04]. Dostupné z: <https://developer.ibm.com/articles/learn-the-basics-of-computer-vision-and-object-detection/>
- [17] Interpretation of Kappa coefficient, 2019. In: *ResearchGate* [Online]. [cit. 2024 03 28]. Dostupné z: [https://www.researchgate.net/figure/Interpretation-of-Kappa-coefficient\\_tbl1\\_332593787](https://www.researchgate.net/figure/Interpretation-of-Kappa-coefficient_tbl1_332593787)
- [18] Introduction to image and raster data, 2024. In: ESRI. *ArcGIS Pro* [Online]. [cit. 2024- 03-28]. Dostupné z: <https://pro.arcgis.com/en/pro-app/3.1/help/data/imagery/introduction-to-raster-data.htm>
- [19] KAZEMI, F. a E. GHANBARI PARMEHR, 2023. EVALUATION OF RGB VEGETATION INDICES DERIVED FROM UAV IMAGES FOR RICE CROP GROWTH MONITORING. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* [online]. X-4/W1-2022, 385-390 [cit. 2024-04-04]. ISSN 2194-9050. Dostupné z: doi:10.5194/isprs-annals-X-4-W1-2022-385-2023
- [20] KOMÁRKOVÁ, Jitka, Jakub JECH a Pavel SEDLÁK, 2020. Comparison of Vegetation Spectral Indices Based on UAV Data: Land Cover Identification Near Small Water Bodies. *2020 15th Iberian Conference on Information Systems and Technologies (CISTI)* [online]. IEEE, 1-4 [cit. 2024-04-05]. ISBN 978-989-54659-0-3. Dostupné z: doi:10.23919/CISTI49556.2020.9140899

- [21] LILLESAND, Thomas, Ralph KIEFER a Jonathan CHIPMAN, 2015. *Remote sensing and image interpretation*. 2015. Hoboken, New Jersey: John Wiley. ISBN 978-1-118-34328-9.
- [22] MEHMOOD, Maryam, Ahsan SHAHZAD, Bushra ZAFAR, Amsa SHABBIR, Nouman ALI a Afaq AHMAD, 2022. Remote Sensing Image Classification: A Comprehensive Review and Applications. *Mathematical Problems in Engineering* [Online]. 2022, 1-24 [cit. 2024-03-28]. ISSN 1563-5147. Dostupné z: doi:10.1155/2022/5880959
- [23] PASHAEI, Mohammad, Hamid KAMANGIR, Michael J. STAREK a Philippe TISSOT, 2020. Review and Evaluation of Deep Learning Architectures for Efficient Land Cover Mapping with UAS Hyper-Spatial Imagery: A Case Study Over a Wetland. *Remote Sensing* [online]. 12(6) [cit. 2024-01-21]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs12060959
- [24] RGB vs HSV, 2018. In: *Medium* [Online]. [cit. 2024-03-28]. Dostupné z: <https://medium.com/neurosapiens/segmentation-and-classification-with-hsv-8f2406c62b39>
- [25] Simple Thresholding, 2023. In: *Medium* [Online]. [cit. 2024-03-28]. Dostupné z: <https://blog.devops.dev/mastering-thresholding-techniques-96706ce36d07>
- [26] The electromagnetic spectrum, 2024. In: *Khan Academy* [Online]. [cit. 2024-03-28]. Dostupné z: <https://www.khanacademy.org/science/physics/light-waves/introduction-to-light-waves/a/light-and-the-electromagnetic-spectrum>
- [27] ZHOU, Rui, Chao YANG, Enhua LI, Xiaobin CAI, Jiao YANG a Ying XIA, 2021. Object-Based Wetland Vegetation Classification Using Multi-Feature Selection of Unoccupied Aerial Vehicle RGB Imagery. *Remote Sensing* [online]. 13(23) [cit. 2024-01-21]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs13234910

## **SEZNAM PŘÍLOH**

Příloha A: Snímky z terénního průzkumu povrchu

Příloha B: Výřez 1 ve zvětšeném detailu

Příloha C: Výřez 2 ve zvětšeném detailu

Příloha D: Referenční výřez 1

Příloha E: Referenční výřez 2

Příloha F: Trénovací plochy pro výřez 2 v pravých barvách

Příloha G: Trénovací plochy pro výřez 2 v indexu TGI


Příloha H: Chybové matice vygenerované z kontrolních bodů

Příloha I: Použité skripty v jazyku Python


## PŘÍLOHA A: Snímky z terénního průzkumu povrchu




## PŘÍLOHA B: Výřez 1 ve zvětšeném detailu




## PŘÍLOHA C: Výřez 2 ve zvětšeném detailu



## PŘÍLOHA D: Referenční výřez 1




## PŘÍLOHA E: Referenční výřez 2





# PŘÍLOHA F: Trénovací plochy pro výřez 2 v pravých barvách

Pozice dlaždic ve výřezu




0 15 30 m

Vodní plocha 1




Vodní plocha 2



Půdní pokryv pevniny



Travní porost mokřadu 2




Půdní pokryv mokřadu



Travní porost pevniny




Travní porost mokřadu 1




0 1,5 3 m

# PŘÍLOHA G: Trénovací plochy pro výřez 2 v indexu TGI


Pozice dlaždic ve výřezu




Suchý travní porost



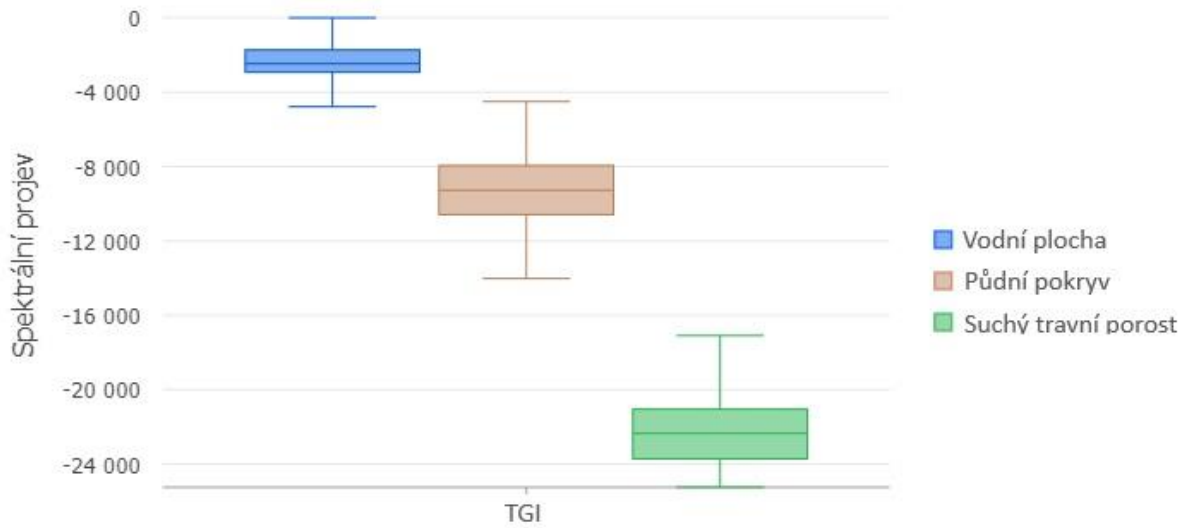
Vodní plocha



Půdní pokryv



Spektrální profil trénovacích ploch (výřez 2 / index TGI)



## PŘÍLOHA H: Chybové matice vygenerované z kontrolních bodů

Chybová matice 1: ISO CLUSTER - Výřez 1 v pravých barvách

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	379	0	1	380	99,74%
	T_2'	22	153	98	273	56,04%
	T_3'	256	0	91	347	26,22%
	Σ SLOUPEC	657	153	190	1 000	
PZ		57,69%	100,00%	47,89%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
62,30%	41,34%

Chybová matice 2: ISO CLUSTER - Výřez 1 ve zvýraznění indexem TGI

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	374	0	1	375	99,73%
	T_2'	23	153	99	275	55,64%
	T_3'	260	0	90	350	25,71%
	Σ SLOUPEC	657	153	190	1 000	
PZ		56,93%	100,00%	47,37%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
61,70%	40,62%

Chybová matice 3: ISO CLUSTER - Výřez 2 v pravých barvách

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	341	0	10	351	97,15%
	T_2'	21	138	136	295	46,78%
	T_3'	282	0	72	354	20,34%
	Σ SLOUPEC	644	138	218	1 000	
PZ		52,95%	100,00%	33,03%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
55,10%	31,56%

Chybová matice 4: ISO CLUSTER - Výřez 2 ve zvýraznění indexem TGI

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	329	0	9	338	97,34%
	T_2'	30	138	142	310	44,52%
	T_3'	285	0	67	352	19,03%
	Σ SLOUPEC	644	138	218	1 000	
PZ		51,09%	100,00%	30,73%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
53,40%	29,69%

Chybová matice 5: MAXIMUM LIKELIHOOD - Výřez 1 v pravých barvách

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	555	0	35	590	94,07%
	T_2'	0	144	5	149	96,64%
	T_3'	102	9	150	261	57,47%
	Σ SLOUPEC	657	153	190	1 000	
PZ		84,47%	94,12%	78,95%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
84,90%	72,04%

Chybová matice 6: MAXIMUM LIKELIHOOD - Výřez 1 ve zvýraznění indexem TGI

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	368	0	1	369	99,73%
	T_2'	0	153	32	185	82,70%
	T_3'	289	0	157	446	35,20%
	Σ SLOUPEC	657	153	190	1 000	
PZ		56,01%	100,00%	82,63%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
67,80%	50,04%

Chybová matice 7: MAXIMUM LIKELIHOOD - Výřez 2 v pravých barvách

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	549	1	40	590	93,05%
	T_2'	0	93	7	100	93,00%
	T_3'	95	44	171	310	55,16%
	Σ SLOUPEC	644	138	218	1 000	
PZ		85,25%	67,39%	78,44%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
81,30%	65,28%

Chybová matice 8: MAXIMUM LIKELIHOOD - Výřez 2 ve zvýraznění indexem TGI

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	369	0	11	380	97,11%
	T_2'	0	121	5	126	96,03%
	T_3'	275	17	202	494	40,89%
	Σ SLOUPEC	644	138	218	1 000	
PZ		57,30%	87,68%	92,66%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
69,20%	51,13%

Chybová matice 9: SUPPORT VECTOR MACHINE - Výřez 1 v pravých barvách

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	550	0	36	586	93,86%
	T_2'	0	142	5	147	96,60%
	T_3'	107	11	149	267	55,81%
	Σ SLOUPEC	657	153	190	1 000	
PZ		83,71%	92,81%	78,42%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
84,10%	70,65%

Chybová matice 10: SUPPORT VECTOR MACHINE - Výřez 1 ve zvýraznění indexem TGI

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	387	0	1	388	99,74%
	T_2'	0	151	24	175	86,29%
	T_3'	270	2	165	437	37,76%
	Σ SLOUPEC	657	153	190	1 000	
PZ		58,90%	98,69%	86,84%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
70,30%	53,25%

Chybová matice 11: SUPPORT VECTOR MACHINE - Výřez 2 v pravých barvách

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	546	0	46	592	92,23%
	T_2'	0	85	5	90	94,44%
	T_3'	98	53	167	318	52,52%
	Σ SLOUPEC	644	138	218	1 000	
PZ		84,78%	61,59%	76,61%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
79,80%	62,38%

Chybová matice 12: SUPPORT VECTOR MACHINE - Výřez 2 ve zvýraznění indexem TGI

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	362	0	11	373	97,05%
	T_2'	0	122	6	128	95,31%
	T_3'	282	16	201	499	40,28%
	Σ SLOUPEC	644	138	218	1 000	
PZ		56,21%	88,41%	92,20%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
68,50%	50,26%

Chybová matice 13: RANDOM TREES - Výřez 1 v pravých barvách

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	560	0	33	593	94,44%
	T_2'	0	142	5	147	96,60%
	T_3'	97	11	152	260	58,46%
	Σ SLOUPEC	657	153	190	1 000	
PZ		85,24%	92,81%	80,00%		

Úspěšnost	Kappa
85,40%	72,89%

	T_1	Suchý travní porost
	T_2	Vodní plocha
	T_3	Půdní pokryv

Chybová matice 14: RANDOM TREES - Výřez 1 ve zvýraznění indexem TGI

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	396	0	1	397	99,75%
	T_2'	0	149	19	168	88,69%
	T_3'	261	4	170	435	39,08%
	Σ SLOUPEC	657	153	190	1 000	
PZ		60,27%	97,39%	89,47%		

Úspěšnost	Kappa
71,50%	54,82%

	T_1	Suchý travní porost
	T_2	Vodní plocha
	T_3	Půdní pokryv

Chybová matice 15: RANDOM TREES - Výřez 2 v pravých barvách

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	523	0	42	565	92,57%
	T_2'	0	89	3	92	96,74%
	T_3'	121	49	173	343	50,44%
	Σ SLOUPEC	644	138	218	1 000	
PZ		81,21%	64,49%	79,36%		

Úspěšnost	Kappa
78,50%	60,81%

	T_1	Suchý travní porost
	T_2	Vodní plocha
	T_3	Půdní pokryv

Chybová matice 16: RANDOM TREES - Výřez 2 ve zvýraznění indexem TGI

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	378	0	12	390	96,92%
	T_2'	0	114	4	118	96,61%
	T_3'	266	24	202	492	41,06%
	Σ SLOUPEC	644	138	218	1 000	
PZ		58,70%	82,61%	92,66%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
69,40%	51,06%

Chybová matice 17: K-NEAREST NEIGBOR - Výřez 1 v pravých barvách

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	533	0	39	572	93,18%
	T_2'	0	146	6	152	96,05%
	T_3'	124	7	145	276	52,54%
	Σ SLOUPEC	657	153	190	1 000	
PZ		81,13%	95,42%	76,32%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
82,40%	67,91%

Chybová matice 18: K-NEAREST NEIGBOR - Výřez 1 ve zvýraznění indexem TGI

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	394	0	1	395	99,75%
	T_2'	0	149	18	167	89,22%
	T_3'	263	4	171	438	39,04%
	Σ SLOUPEC	657	153	190	1 000	
PZ		59,97%	97,39%	90,00%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
71,40%	54,73%



Chybová matice 19: K-NEAREST NEIGBOR - Výřez 2 v pravých barvách

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	513	0	38	551	93,10%
	T_2'	0	81	5	86	94,19%
	T_3'	131	57	175	363	48,21%
	Σ SLOUPEC	644	138	218	1 000	
PZ		79,66%	58,70%	80,28%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
76,90%	58,31%

Chybová matice 20: K-NEAREST NEIGBOR - Výřez 2 ve zvýraznění indexem TGI

		REFERENČNÍ DATA			Σ ŘÁDEK	PU
		T_1	T_2	T_3		
KLASIFIKOVANÁ DATA	T_1'	378	0	12	390	96,92%
	T_2'	0	120	4	124	96,77%
	T_3'	266	18	202	486	41,56%
	Σ SLOUPEC	644	138	218	1 000	
PZ		58,70%	86,96%	92,66%		
	T_1	Suchý travní porost				
	T_2	Vodní plocha				
	T_3	Půdní pokryv				

Úspěšnost	Kappa
70,00%	52,06%

# PŘÍLOHA I: Použité skripty v jazyku Python

Plnění chybové matice a výpočet celkové přesnosti a Kappa koeficientu ze všech pixelů:

```
1 # Import potřebných knihoven
2 import cv2
3 import numpy
4 import sys
5
6 # Vstupní cesta ke snímkům
7 cesta_img_1 = "MANUAL_V1.tif"
8 cesta_img_2 = "ML_V1.tif"
9 # RGB hodnoty hledaných tříd
10 trida_1 = (191,255,255) # RGB reprezentace TRAVNÍ POROST
11 trida_2 = (102,168,222) # RGB reprezentace PŮDNÍ POKRYV
12 trida_3 = (242,217,191) # RGB reprezentace VODNÍ PLOCHA
13 # Načtení vstupních souborů
14 img_1 = cv2.imread(cesta_img_1)
15 img_2 = cv2.imread(cesta_img_2)
16 # Inicializace nulové chybové matice
17 chybova_matice = numpy.zeros((3,3)) # Musí odpovídat počtu
18 # Nastavení adresace
19 grnd_truth_hodnota = 0
20 classified_hodnota = 0
21 # Zjištění počtu řádků a sloupců prvního vstupního rastru
22 y_smer_img_1, x_smer_img_1, _ = img_1.shape
23 # Kontrola rozlišení rastrů
24 if (img_1.shape != img_2.shape):
25     print("Vstupní rastrové snímky mají rozdílný rozměr !")
26     sys.exit()
27     # Jestliže je rozdílný rozměr
28     # Výpis upozornění do konzole a ukončení skriptu
29
30 # Převod hodnoty pixelu na klasifikační třídu
31 # Důvod tohoto převodu je exportování výsledků s využitím RGB vykreslovače
32 # (Hodnoty pixelů odpovídají vizuálnímu znázornění klasifikační třídy)
33 # z důvodu lepšího vizuálního přehledu a orientace ze strany zpracovatele.
34 for y in range(y_smer_img_1):
35     for x in range(x_smer_img_1):
36         rgb_hodnota_1 = img_1[y][x]
37         rgb_hodnota_2 = img_2[y][x]
38         if all(rgb_hodnota_1 == trida_1):
39             grnd_truth_hodnota = 0
40         elif all(rgb_hodnota_1 == trida_2):
41             grnd_truth_hodnota = 1
42         elif all(rgb_hodnota_1 == trida_3):
43             grnd_truth_hodnota = 2
44         if all(rgb_hodnota_2 == trida_1):
45             classified_hodnota = 0
46         elif all(rgb_hodnota_2 == trida_2):
47             classified_hodnota = 1
48         elif all(rgb_hodnota_2 == trida_3):
49             classified_hodnota = 2
50         i = classified_hodnota
51         z = grnd_truth_hodnota
52         # Plnění matice na základě adresování skutečné a klasifikované hodnoty
53         chybova_matice[i][z] = chybova_matice[i][z] + 1
54
55 # Celkový součet pixelů
56 celkovy_soucet = numpy.sum(chybova_matice)
57 # Součet hlavní diagonály
58 soucet_diagonaly = numpy.trace(chybova_matice)
59 # Přesnost z pohledu
60 radek_1 = numpy.sum(chybova_matice[0,:])
61 radek_2 = numpy.sum(chybova_matice[1,:])
62 radek_3 = numpy.sum(chybova_matice[2,:])
63 # Přesnost z pohledu
64 sloupec_1 = numpy.sum(chybova_matice[:,0])
65 sloupec_2 = numpy.sum(chybova_matice[:,1])
66 sloupec_3 = numpy.sum(chybova_matice[:,2])
67 # Výpočet celkové přesnosti v procentuální hodnotě se zaokrouhlením na dvě desetinná místa
68 presnost = round((soucet_diagonaly / celkovy_soucet)*100,2)
69 # Výpočet Kappa koeficientu
70 promenna_k = (radek_1*sloupec_1)+(radek_2*sloupec_2)+(radek_3*sloupec_3)
71 kappa_citatel = (celkovy_soucet*soucet_diagonaly)-promenna_k
72 kappa_jmenovatel = (celkovy_soucet*celkovy_soucet)-promenna_k
73 # Vyjádření Kappa koeficientu v procentuální hodnotě se zaokrouhlením na dvě desetinná místa
74 kappa = round((kappa_citatel/kappa_jmenovatel)*100,2)
75
76 print("")
77 print(chybova_matice)
78 # Součet všech prvků matice musí být roven celkovému počtu pixelů (kontrola klasifikace každého pixelu)
79 print("")
80 print("Celková přesnost: ",presnost)
81 print("Kappa koeficient: ",kappa)
82 print("")
83
84
85
```

Import změn pixelů po postklasifikačních úpravách do CSV souboru:

```
1 # Import knihoven
2 import cv2
3 import csv
4
5 # Načtení obrázků
6 obr_1 = cv2.imread('Majority_V1_P1.tif')
7 obr_2 = cv2.imread('ML_V1.tif')
8 obr_3 = cv2.imread('MANUAL_V1.tif')
9 # Získání adresace pro FOR cyklus
10 y_smer, x_smer, _ = obr_1.shape
11 # Otevření CSV souboru pro zápis (obecný název - nutno měnit po každém běhu na patřičný název)
12 with open('pixely_data.csv', 'w', newline='') as csvfile:
13     # Inicializace souboru pro zápis
14     csvwriter = csv.writer(csvfile)
15     # Nastavení názvu atributů (první řádek)
16     csvwriter.writerow(['R', 'S', 'Pixel_1', 'Pixel_2', 'Pixel_3'])
17     # FOR cyklus pro kontrolu pixelů
18     for y in range(y_smer):
19         for x in range(x_smer):
20             # Získání hodnoty pixelů v obrázcích do proměnné
21             pixel1 = obr_1[y, x]
22             pixel2 = obr_2[y, x]
23             pixel3 = obr_3[y, x]
24             # Porovnání změny před a po majoritní filtraci
25             if not all(pixel1 == pixel2):
26                 # Pokud se hodnoty pixelů liší, zapíšeme je do CSV souboru
27                 csvwriter.writerow([y, x, pixel1, pixel2, pixel3]) # Zapiše se také hodnota pixelu ruční identifikace "pixel3"
28
29 print("PROVEDENO !!!")
30
```