

UNIVERZITA PARDUBICE
FAKULTA EKONOMICKO-SPRÁVNÍ
ÚSTAV SYSTÉMOVÉHO INŽENÝRSTVÍ A INFORMATIKY

DISERTAČNÍ PRÁCE

2024

Ing. Jakub JECH

Univerzita Pardubice
Fakulta ekonomicko-správní
Ústav systémového inženýrství a informatiky

**Návrh klasifikačního přístupu pro obrazová
data s velmi vysokým prostorovým rozlišením**

Disertační práce

Autor: Ing. Jakub JECH
Školitel: prof. Ing. Jitka KOMÁRKOVÁ, Ph.D.

Pardubice
2024

**University of Pardubice
Faculty of Economics and Administration
Institute of System Engineering and Informatics**

**Proposal of the classification approach for
image data with very high spatial resolution**

Dissertation thesis

Author: Ing. Jakub JECH
Supervisor: prof. Ing. Jitka KOMÁRKOVÁ, Ph.D.

Pardubice
2024

ABSTRAKT

Identifikace povrchu je jednou z metod zpracování geografických dat získaných dálkovým průzkumem. V dnešním světě se běžně setkáváme s obrazovými daty s velkým detailem, která mají vypovídající hodnotu o prozkoumávaném území, ale vypovídající hodnota lze zvýšit za pomoci různých metod zpracování nad těmito daty. A právě klasifikace dat je jednou z těchto metod. V dálkovém průzkumu existuje mnoho typů nosičů a snímačů obrazových dat, některé poskytují více komplexní data, ale také bývají dražší. Jiné zase poskytují pouze obrazová data ve viditelné části světelného záření. Právě tyto snímače nebo celé systémy dálkového průzkumu získávající RGB obrazová data s velmi vysokým prostorovým detailem jsou zajímavé. Pro tyto systémy zatím existuje malý počet aplikací nad takovými daty a tím i vznikají nové výzvy zpracování RGB obrazových dat. Cílem disertační práce je tedy navržení a ověření nového způsobu klasifikace RGB obrazových dat s velmi vysokým prostorovým rozlišením (méně než 10 cm na pixel).

V první části předložené disertační práci je uvedení do problematiky dálkového průzkumu a jsou vysvětleny základní pojmy z oblasti pořizování dat, zpracování dat a více do hloubky je vysvětlena klasifikace dat. Dále je v disertační práci uvedena hluboká analýza současného stavu v oblasti klasifikace obrazových dat s velmi vysokým prostorovým rozlišením. Ze současného stavu řešené problematiky vyplývají určité výzvy v této oblasti. Jde například o využívání konvenčních a moderních klasifikačních přístupů pro identifikaci typů pokryvu nad daty s vysokým nebo velmi vysokým prostorovým rozlišením. Po definování výzev je práce zaměřena na výběr vhodných metod a navržení klasifikačního přístupu pro dosažení cíle disertační práce. Těmito metodami jsou konvenční metody. Jde o především o tradiční řízené klasifikační metody: Maximum Likelihood, Random Trees a Support Vector Machine (SVM). Pomocí těchto metod je pak realizováno následné klasifikování pomocí navrženého klasifikačního přístupu CMCA. Vzájemné porovnání celkové přesnosti klasifikace je poté provedeno pomocí vybraných případových studií v části ověření a následně pomocí nově vytvořených případových studií v části aplikování navrženého klasifikačního přístupu CMCA.

KLÍČOVÁ SLOVA

Obrazová data; bezpilotní prostředky; klasifikace; klasifikace obrazových dat; řízená klasifikace; návrh klasifikačního přístupu; velmi vysoké prostorové rozlišení; CMCA

ABSTRACT

Surface identification is one of the methods of processing geographic data obtained by remote sensing. In today's world, it is common to encounter image data with great detail that have a telling value about the area being explored, but the telling value can be increased by using various processing methods on top of these data. Data classification is one of these methods. In remote sensing, there are many types of image data carriers and sensors, some provide more complex data but also tend to be more expensive, while others provide only image data in the visible part of the light. These sensors or entire remote sensing systems that acquire RGB image data with very high spatial detail that are interesting. For these systems, there is still a small number of applications over such data, and thus new challenges of processing RGB image data arise. Thus, the aim of this dissertation is to propose and validate a new method for classifying RGB image data with very high spatial resolution (less than 10 cm per pixel).

The first part of the dissertation introduces remote sensing and explains the basic concepts of data acquisition, data processing and more in-depth explanation of data classification. Furthermore, an in-depth analysis of the state-of-the-art in the classification of very high spatial resolution image data is presented in the dissertation. The current state of the state of art raises some challenges in this area. These include the use of conventional and modern classification approaches to identify coverage types over high or very high spatial resolution image data. After defining the challenges, the thesis focuses on selecting appropriate methods and designing a classification approach to achieve the dissertation objective. These methods are conventional methods. These are mainly traditional supervised classification methods: Maximum Likelihood, Random Trees and Support Vector Machine (SVM). These methods are then used to perform the subsequent classification using the proposed CMCA classification approach. The inter-comparison of the overall classification accuracy is then performed using the selected case studies in the validation part and then using the newly created case studies in the application part of the proposed CMCA classification approach.

KEY WORDS

Image data; unmanned vehicles; classification; image data classification; supervised classification; proposal of a classification approach; very high spatial resolution; CMCA

Prohlašuji:

Tuto práci jsem vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

Byl jsem seznámena 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 28. 6. 2024

Ing. Jakub JECH

PODĚKOVÁNÍ

Rád bych poděkoval paní prof. Ing. Jitce KOMÁRKOVÉ, Ph.D. za vedení a připomínky při vypracovávání disertační práce. Dále bych chtěl také poděkovat nejbližším kolegům a ostatním vědeckým pracovníkům Ústavu systémového inženýrství a informatiky Fakulty ekonomicko-správní Univerzity Pardubice. Chci také poděkovat své rodině za podporu po celou dobu studia.

OBSAH

ABSTRAKT	4
KLÍČOVÁ SLOVA	4
ABSTRACT	5
KEY WORDS	5
PODĚKOVÁNÍ	7
OBSAH	8
SEZNAM OBRÁZKŮ	10
SEZNAM TABULEK	12
SEZNAM ZKRATEK	13
ÚVOD	14
1 SOUČASNÝ STAV V OBLASTI TÉMATU DISERTAČNÍ PRÁCE	16
1.1 Dálkový průzkum	16
1.2 Obecný průběh celého procesu získávání dat	22
1.3 Sběr dat s velmi vysokým prostorovým rozlišením	22
1.3.1 Satelitní a letecké snímkování	22
1.3.2 Bezpilotní prostředky a bezpilotní systémy	24
1.3.3 Vhodný prostředek pro sběr dat s velmi vysokým prostorovým rozlišením	29
1.4 Režimy provozu bezpilotních prostředků/systémů	29
1.5 Plánovaný let	32
1.6 Předzpracování a zpracování obrazu	33
1.6.1 Zpracování obrazu	33
1.6.2 Mozaikování	35
1.6.3 Manuální identifikace	36
1.6.4 Klasifikace a postklasifikační úpravy	36
1.7 Klasifikace obrazových dat	36
1.7.1 Neřízené klasifikační metody	38
1.7.2 Řízené klasifikační metody včetně moderních přístupů	39
1.8 Omezení při klasifikaci RGB obrazových dat	41

1.9	Výzvy pro využití nového přístupu ke klasifikaci obrazových dat	41
2	CÍLE DISERTAČNÍ PRÁCE A POSTUP JEHO DOSAŽENÍ	43
2.1	Formulace cíle disertační práce	43
2.2	Dílčí cíle a formulace postupu dosažení cíle disertační práce	44
2.3	Přehled metod vhodných pro dosažení cíle disertační práce a použité vybavení	44
2.4	Omezení navrženého klasifikačního přístupu	45
2.5	Motivace	46
3	SOUČASNÝ STAV VE SMĚRU DISERTAČNÍ PRÁCE	47
4	NAVRŽENÝ KLASIFIKAČNÍ PŘÍSTUP CMCA.....	54
4.1	Použitá data, prostředky, metody a SW	54
4.2	Navržený model zpracování dat pomocí automatické klasifikace	55
4.1	Zdrojový kód CMCA přístupu – maticová ukázka	59
4.2	Identifikace typů povrchů na základě vlastních dat a výsledků jejich zpracování	62
4.3	Výpočetní náročnost	66
4.4	Ověření navrženého klasifikačního přístupu CMCA	69
4.4.1	Multimediální nástroje	69
4.4.2	Identifikace koní	76
5	APLIKACE CMCA NA PŘÍPADOVÉ STUDII	78
5.1	Případová studie: Identifikace vody	78
5.2	Případová studie: Monitoring koní	81
5.3	Případová studie: Typy pokryvu – přírodní rezervace Baroch	86
5.4	Případová studie: Identifikace malých vodních ploch – rybník Skříň.....	100
6	DISKUSE VÝSLEDKŮ	106
	ZÁVĚR.....	109
	POUŽITÁ LITERATURA	111
	VLASTNÍ PUBLIKACE DISERTANTA VZTAHUJÍCÍ SE K TÉMATU DISERTAČNÍ PRÁCE	124
	PŘÍLOHA – ZDROJOVÝ KÓD METODY CMCA	126

SEZNAM OBRÁZKŮ

Obrázek 1: Rozdělení elektromagnetického spektra	17
Obrázek 2: Ilustrace získávání dat	18
Obrázek 3: Obecný model systému pro získávání dat	19
Obrázek 4: Rozdíl mezi multispektrálními a hyperspektrálními daty	20
Obrázek 5: Princip snímání dat – v tomto případě pomocí LIDARu	21
Obrázek 6: Obecné workflow pro celý proces získávání dat.....	22
Obrázek 7: Výskyt nejpoužívanějších výrazů pro bezpilotní prostředek, 1945–2019	27
Obrázek 8: Porovnání velikostí bezpilotních prostředků.....	28
Obrázek 9: FPV vs. klasický bezpilotní prostředek (produkty DJI).....	30
Obrázek 10: Výňatek definice rozdílu typů letů podle ÚCL	31
Obrázek 11: Reakce antikolizních systémů na překážku, fly-bypass	32
Obrázek 12: Centrální projekce pořizování snímků	35
Obrázek 13: Vzorec pro výpočet Kappa koeficientu.....	38
Obrázek 14: Hierarchie systémů umělé inteligence	40
Obrázek 15: Pozice PR Baroch.....	55
Obrázek 16: Procesní diagram celého procesu zpracování dat včetně pomocí navrženého přístupu	56
Obrázek 17: Vývojový diagram navrženého klasifikačního přístupu CMCA (verze 1)	57
Obrázek 18: Navržený funkční model v nástroji ESRI ModelBuilder (verze 2).....	58
Obrázek 19: Navržený funkční CMCA přístup (verze2).....	58
Obrázek 20: Výstupní klasifikace na snímku s velmi vysokých prostorovým rozlišením	63
Obrázek 21: Použití Majority filtru (12×).....	64
Obrázek 22: Přehled všech klasifikací na dvou územích	65
Obrázek 23: Zkoumaná oblast – rybník Skříň	66
Obrázek 24: Proces klasifikace pomocí konvenčních metod	67
Obrázek 25: Proces klasifikace pomocí deep learning metod	68
Obrázek 26: Rybník Skříň, testovací část, ze studie na CISTI 2023	70
Obrázek 27: Referenční data CISTI 2023	71
Obrázek 28: Minimal distance CISTI 2023	72
Obrázek 29: Mahalanobis distance CISTI 2023	73
Obrázek 30: Maximum likelihood CISTI 2023	74
Obrázek 31: CMCA metoda CISTI 2023	75
Obrázek 32: Přehled vizuálních výsledků případové studie.....	77
Obrázek 33: Výsledná klasifikace pomocí DL, model U-Net	79
Obrázek 34 - Výsledná klasifikace pomocí DL, model PSPNet	79
Obrázek 35: Výsledná klasifikace pomocí DL, model DLv3.....	80
Obrázek 36: Výsledná klasifikace pomocí CMCA.....	80
Obrázek 37: Vstupní snímek.....	81
Obrázek 38: Referenční data.....	82
Obrázek 39: Výsledek klasifikace pomocí metody ML	82
Obrázek 40: Výsledek klasifikace pomocí metody RT	83
Obrázek 41: Výsledek klasifikace pomocí metody SVM.....	83
Obrázek 42: Výsledek klasifikace pomocí metody DL U-Net	84
Obrázek 43: Výsledek klasifikace pomocí metody DL DLv3.....	84
Obrázek 44: Výsledek klasifikace pomocí metody CMCA.....	85
Obrázek 45: Pozice přírodní rezervace Baroch	86

Obrázek 46: DJI Mavic 3T	87
Obrázek 47: Vybraná zkoumaná část PR Baroch	88
Obrázek 48: Výběr ze vstupních dat Barochu	89
Obrázek 49: Výsledek pomocí manuální identifikace	89
Obrázek 50: Výsledek klasifikace pomocí metody Maximum Likelihood	90
Obrázek 51: Výsledek klasifikace pomocí metody Random Trees	90
Obrázek 52: Výsledek klasifikace pomocí metody SVM.....	91
Obrázek 53: Výsledek klasifikace pomocí metody Deep Learning	91
Obrázek 54: Výsledek klasifikace pomocí metody CMCA.....	92
Obrázek 55: Graf s výsledky celkových přesností klasifikací (rozmezí 85–90 %)	92
Obrázek 56: RGB vstupní snímek z nasnímaného celého území Barochu.....	93
Obrázek 57: Referenční data celé zájmové oblasti Baroch	94
Obrázek 58: Klasifikace Maximum Likelihood nad celou zájmovou oblastí	95
Obrázek 59: Klasifikace Random Trees nad celou zájmovou oblastí	96
Obrázek 60: Klasifikace SVM nad celou zájmovou oblastí	97
Obrázek 61: Klasifikace Deep Learning (U-Net) nad celou zájmovou oblastí	98
Obrázek 62: Klasifikace CMCA nad celou zájmovou oblastí	99
Obrázek 63: Lokalizace rybníku Skříň	101
Obrázek 64: Výřez z nasnímaných dat rybníku Skříň	101
Obrázek 65: Manuální identifikace typů pokryvu povrchu (referenční data)	102
Obrázek 66: Klasifikace rybníku Skříň pomocí metody Maximum Likelihood	102
Obrázek 67: Klasifikace rybníku Skříň pomocí metody Random trees	103
Obrázek 68: Klasifikace rybníku Skříň pomocí metody SVM.....	103
Obrázek 69: Klasifikace rybníku Skříň pomocí metody Deep learning.....	104
Obrázek 70: Klasifikace rybníku Skříň pomocí metody CMCA.....	104

SEZNAM TABULEK

Tabulka 1: Rozcestník disertační práce	15
Tabulka 2: Satelitní systémy	23
Tabulka 3: Četnost hledaných výrazů k pojmu bezpilotní prostředek od roku 2000 (k 18. 6. 2024)	25
Tabulka 4: Četnost hledaných výrazů od roku 2000 (k 18. 6. 2024).....	33
Tabulka 5: Četnost výskytů neřízené klasifikace ve vědeckých databázích za celou dobu (k 11. 11. 2023)	39
Tabulka 6: Četnost výskytu řízené klasifikace ve vědeckých databázích za celou dobu (k 11. 11. 2023)	40
Tabulka 7: Přehled přesností klasifikací z článku [56].....	65
Tabulka 8: Porovnání dob výpočetní náročnosti	68
Tabulka 9: Porovnání výsledků klasifikací (případová studie Multimediální nástroje)	69
Tabulka 10: Porovnání výsledků klasifikací (koně)	76
Tabulka 11: Porovnání výsledků klasifikací (identifikace vody)	78
Tabulka 12: Porovnání výsledků klasifikací (Monitoring koní).....	85
Tabulka 13: Přesnosti jednotlivých klasifikátorů na celém území včetně doby zpracování	99
Tabulka 14: Porovnání výsledků klasifikací (případová studie 2) včetně bod zpracování	105

SEZNAM ZKRATEK

ASAP	As soon as possible – co nejdříve, jak je to možné
CMCA	Conventional Multi Classifier Approach
CNN	Convolutional Neural Networks
ČÚZK	Český úřad zeměměřický a katastrální
DJI	Dà-Jiāng Innovations – čínská technologická společnost
DL	Deep learning – hluboké učení
DN	Digital number
DPZ	Dálkový průzkum Země
EM	Elektromagnetické
FPV	First person view
GIS	Geografické informační systémy
GSD	Ground sample distance
IMU	Inertial measurement unit
IR	Infračervené záření (angl. Infrared radiation)
JPEG	Joint Photographic Experts Group
K-NN	K-Nearest neighbors
LIDAR	Light detection and ranging
ML	Maximum likelihood
NIR	Near infra red
PNG	Portable Network Graphics
RC	Remote controller – dálkový ovladač
RGB	Red Green Blue – viditelné spektrum světla pro lidské oko
RF	Random forest
RS	Remote Sensing – vzdálený průzkum
RT	Random trees
SVM	Algoritmus podpůrných vektorů (angl. Support Vector Machine)
TIF/TIFF	Tagged Image File Format
UA	Unmanned aircraft – bezpilotní letoun
UAS	Unmanned aerial system
UAV	Unmanned aerial vehicle
ÚCL	Úřad pro civilní letectví
UV	Unmanned vehicles – bezpilotní prostředky

ÚVOD

V dnešní době je obecným předpokladem, že je kladen velký důraz na dostupnost kvalitních a jednoznačných dat. Od počátku nového tisíciletí se začali velmi rychle vyvíjet a uplatňovat technologie bezpilotních prostředků, a to v akademické a komerční sféře. Bepilotní prostředky vybavené optickými snímači se jeví jako jeden z vhodných zdrojů dat při důrazu na kvalitu a opakovatelnost, jak při letech řízených pilotem, tak i plánovaných. Jedním ze způsobů, jak zajistit jednoznačnost dat je pomocí klasifikace, při které se data roztrídí do skupin daných uživatelem nebo do předem zadaného počtu [104].

Klasifikace obrazových dat je proces kategorizace a označování skupin pixelů ve snímku založených na spektrálních pravidlech [98]. Tento proces lze provádět pomocí dvou přístupů, a to řízenou a neřízenou klasifikací. Řízená klasifikace je proces klasifikování buněk (pixelů) na základě předem identifikovaných vzorků. Jedná se o buňky umístěné v trénovacích oblastech na snímku (tzv. trénovacích množinách), které jsou stejné informační hodnoty – homogenní. Následné ověření poté probíhá na buňkách v testovacích oblastech (tzv. testovací množině). Neřízenou klasifikaci lze definovat jako identifikaci přirozených skupin nebo struktur pomocí shlukování, kdy je každá buňka zařazena do shluku a je označena stejným symbolem či barvou. Jedná se o metodu, která je založena je proces založen na shlukové analýze – shlukové statistice [77].

Některé metody klasifikací jsou už nějakou dobu používány [7] a i zde přichází vývoj spolu s vývojem výpočetní technologií, resp. umělé inteligence a strojového učení. Nejnovějším typem klasifikátoru je řízená klasifikace pomocí hlubokého učení (deep learning). Metoda strojového učení deep learning [122] je založená na sítích umělé inteligence a umožňuje klasifikace obrazových dat pixelovým nebo objektovým přístupem.

S rychlým vývojem informatiky a miniaturizací hardwaru se od počátku tisíciletí staly bezpilotní prostředky oblíbenou formou poskytovatele obrazových dat, ve velké míře i pro dálkový průzkum Země. Bepilotní prostředky (unmanned vehicles – UV) nebo bezpilotní letouny (unmanned aircrafts – UA), také drony, poskytují obrazová data s velmi vysokým prostorovým rozlišením. Požadavky na získávání dat mohou být relativně neomezené, protože u bezpilotních prostředků lze hovořit o získávání dat na vyžádání. Na základě respektování legislativy lze pomocí bezpilotních prostředků získávat libovolná data. Získávání dat lze dělat manuálním letem, který nezaručuje optimální pokrytí snímané části. Manuální let je zcela závislý na zkušenostech a pozornosti pilota. Proto u manuálního letu hrozí nedostatek pokrytí snímaného objektu, anebo naopak nadbytečná redundance pořízených dat. Vhodnější způsob

získávat dat s kvalitním pokrytím snímané oblasti je pomocí plánovaných letů, kde je proces snímání zautomatizován a řídí se podle předem nastavených parametrů letu. Samotný bezpilotní prostředek může mít vestavěnou snímací kameru nebo může být použit jako nosič pro snímací kamery i speciálních typů. V posledních letech převažuje podoba bezpilotních prostředků s vestavěnými snímači. [40] Vestavěné snímače mohou snímat různé vlnové délky elektromagnetického záření, ale převládají snímače s klasickým snímačem viditelné části spektra elektromagnetického záření (tedy RGB snímačem) [96].

V disertační práci bude pozornost upřena na automatický proces zpracování RGB obrazových dat (klasifikaci) s velmi vysokým prostorovým rozlišením. Takový typ dat je zejména získáván pomocí bezpilotních prostředků. V práci bude navržen a ověřen nový postup/metoda a softwarový nástroj pro zpracování RGB obrazových dat pomocí řízených metod.

Tabulka 1 představuje rozcestník kapitol naplňujících dílčí cíle disertační práce.

Tabulka 1: Rozcestník disertační práce

Hlavní body	Poloha v textu	Dílčí cíl
Hlubková analýza stávajícího stavu ve směru práce	Kapitola 3	DC 1
Výběr vhodných metod	Kapitola 2.3 a 4.1	DC 2
Zhodnocení výpočetní náročnosti	Kapitola 4.3	DC 3
Ověření navrženého klasifikačního přístupu	Kapitola 4.4	DC 4
Aplikování navrženého klasifikačního přístupu na nových datech – případových studiích	Kapitola 5	DC 5

Zdroj: [vlastní zpracování]

1 SOUČASNÝ STAV V OBLASTI TÉMATU DISERTAČNÍ PRÁCE

V současné době je potřeba pracovat s daty, které mají, co nejvíce vypovídající hodnotu. Jinými slovy poskytují co největší detail informací. Obrazová data poskytují spoustu informací sami o sobě a čím více jsou kvalitní, tak dokáží poskytnout více informací. Pomocí dat s vysokým až velmi vysokým prostorovým rozlišením lze snadno identifikovat různé objekty. Častou aplikací je identifikace typů stromů nebo jiného typu vegetace [83] nebo plodin [17]. Od dob vysílání satelitů v minulém tisíciletí se k obrazovým analýzám využívala satelitní data, která byla snímána v pravých barvách, ale i v multispektrálních pásmech záření [119]. Satelitní data poskytují prostorové rozlišení spíše v metrech na pixel, ale s vývojem informačních technologií se moderní satelitní systémy dostávají na hodnoty desítek cm na pixel [90]. Studie [12][10][53] prokázaly, že na satelitních snímcích s vysokým rozlišením lze snadno a přesně identifikovat různé typy objektů.

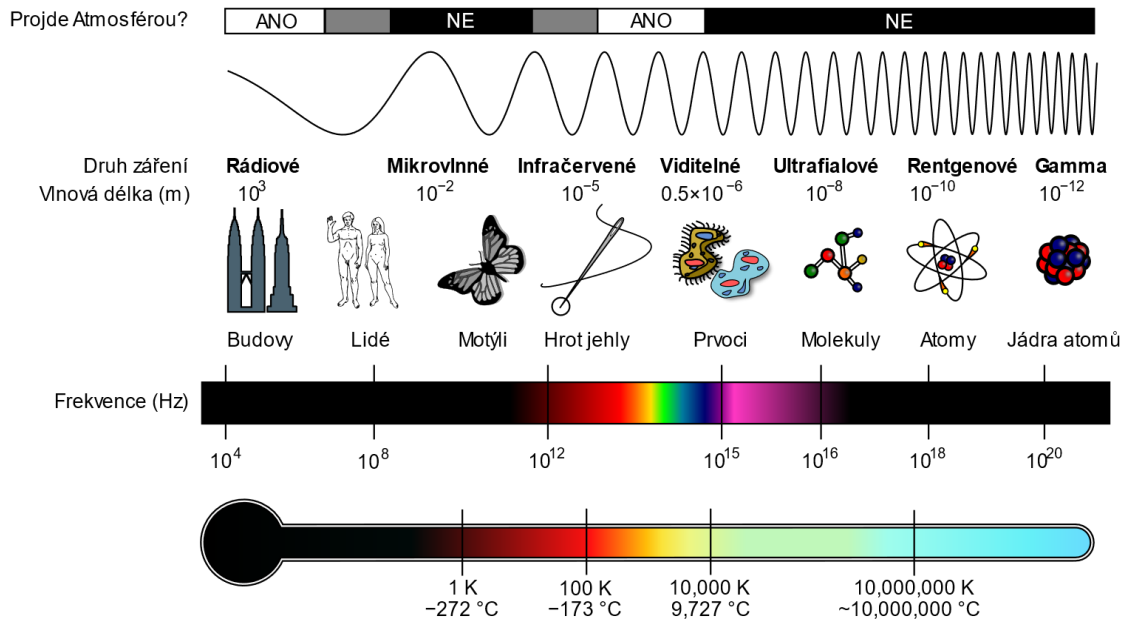
Články [35][102][23] jsou podle databáze WoS citovány 7 828krát, 6 452krát, 682krát k datu 13. 6. 2024, to dokazuje, že je tento směr zajímavý. Uvedené články byly zveřejněny od přelomu tisíciletí, ale za poslední dekádu zaznamenávají nárůst publikací a citací v tomto směru. To ukazuje, že je tento směr velmi atraktivní a za poslední dobu se stává i „hot topic“.

1.1 Dálkový průzkum

Obecně je dálkový průzkum (DP, popř. RS z anglického remote sensing nebo také DPZ z pojmu dálkový průzkum Země) vědecká oblast, která se zaměřuje na získávání užitečných informací o objektech či jevech prostřednictvím měření dat získaných nepřímým kontaktem s těmito zkoumanými objekty či jevy [72].

Lillesand a kolektiv [72] definují DPZ jako průnik vědy a umění, o získávání informací o objektech, oblastech a jevech prostřednictvím zařízení, které s nimi není v kontaktu. Tato zařízení mohou být nejrůznější sensory, které sbírají data. Autoři uvádí, že sesbíraná data pomocí DPZ mohou mít mnoho forem, vždy podle typu snímače. Jedna z forem může být akustické vlnění získané pomocí sonaru, které se zejména uplatní ve využití průzkumu vodních ploch. Dalším z forem záření je podle autorů záření elektromagnetické (EM). EM záření má několik částí, které jsou vidět jen pomocí speciálních snímačů, ale jedna část EM záření je vidět i lidským okem. Jedná se o viditelnou část EM spektra, což je úzká část (cca 400–750 nm), kterou lze rozdělit na dílčí intervaly. Svatoňová a Laurmann [105] rozdělují

viditelné světlo na intervaly modrého světla, zeleného světla a červeného světla podle vlnové délky. Ostatní vlnové délky jsou pro člověka bez speciálních pomůcek neviditelné. Celé EM spektrum se také nazývá Maxwellovou duhou [107] a je znázorněné na Obrázek 1.



Obrázek 1: Rozdělení elektromagnetického spektra

Zdroj: [26]

Uvedené vlnové délky jsou snímány pomocí speciálních snímačů (senzorů), které jsou součástí celého systému. Současné systémy pro automatický sběr dat lze rozdělit do dvou následujících skupin, a to podle typu nosiče a podle snímaných spektrálních pásem, kde typu nosičů jsou [72]:

- Družicové (satelitní) snímky.,
- Letecké snímky.,
- Snímky pořízené z bezpilotního prostředku.

A typy snímaných pásem elektromagnetické záření:

- Pásmo viditelného světla.,
- Pásmo tepelného záření – termální.,
- Multispektrální, popř. hyperspektrální pásma.


Tato pásma vycházejí ze snímačů využitých v libovolných typech zařízení pro sběr dat – bezpilotní prostředky, letadla, satelity [115].

V současné době existují pro všechny nosiče identické snímače, avšak jejich odlišnost je v pořízeném spektrálním rozlišení snímků. U nejmodernějších satelitů se lze dostat na rozlišení

snímků pořízených ve viditelné části spektra ve vyšších desítkách centimetrů až jednotkách metrů na pixel, nejmodernější satelity Pleiades NEO až na 30 cm/px [90]. Pro letecké snímky je typické rozlišení v nižších jednotkách desítek centimetrů na pixel, např. ČÚZK má pro poslední letecké snímání technologie pro nejlepší snímání v rozlišení 12,5 cm/px [84]. U bezpilotních prostředků se dostává nejlepšího prostorového rozlišení v řádech centimetrů na pixel, jedná se o velmi vysoké prostorové rozlišení (very high spectral resolution) [55][69]. Toto je jedním z důvodů, proč se i tato práce zaměřuje na bezpilotní prostředky.

Většinou bývají ty nejkvalitnější snímky zpoplatněné a ty volně dostupné jsou o několik řádů rozlišení horší nebo jsou zpřístupňovány až po delší době. Toto obecně platí pro satelitní snímky i letecké snímky. Výhodou bezpilotních prostředků je flexibilita pořizování dat, která je závislá, stejně jako u letadel, na počasí, ale samotný let nevyžaduje tolik prostředků a je podstatněji ekonomičtější [88].

Toto bylo obecné rozdělení nosičů, ale vždy závisí i na typu snímače, kterým je nosič vybaven. Obecné schéma získávání dat je na Obrázek 2 [16].

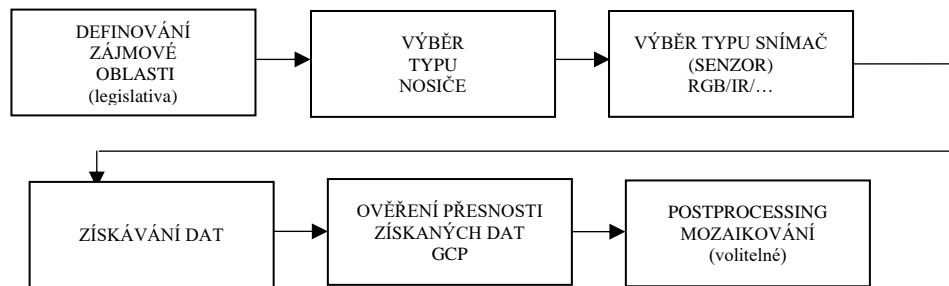


Obrázek 2: Ilustrace získávání dat

Zdroj: [16]

Systém pro získávání dat má několik modulů: definice sledovaného území; nosič – typ podle různých parametrů, dominantní parametr je velikost snímané plochy; snímač (senzor) – snímá charakteristiky snímaného povrchu (např. spektrální); získávání dat; ověření přesnosti získaných dat – využívání GCP; Postprocessing – různé úlohy ze získaných dat,

mezi které se řadí mozaikování, publikování dat, kešování dat a jiné. Modulový systém pro získávání dat je znázorněn v jeho obecném modelu na Obrázek 3.




Obrázek 3: Obecný model systému pro získávání dat

Zdroj: [vlastní zpracování]

Senzor je zařízení, které snímá určitou fyzikální veličinu a převádí ji na signál, který lze následně zpracovat. Jedním z typů senzorů využívaných pro RS jsou snímače elektromagnetického záření (nebo radiometrický snímač). Škálou elektromagnetického záření i vlnění je elektromagnetické spektrum. Elektromagnetické spektrum snímané senzory lze rozdělit na části podle vlnové délky EM záření (může být také podle frekvence). Senzory pro nejkratší vlnovou délku snímají rentgenové záření, následují senzory ultra fialového záření, senzory viditelného světlo, senzory infračerveného záření, senzory mikrovlnného záření a senzory pro nejdelší vlnovou délku snímají radiové vlny [82], viz kapitola o Předzpracování a zpracování obrazu.

Elektromagnetické spektrum rozdělné podle obvykle snímaných pásem pro satelity je zobrazeno na Obrázek 4, kdy se často snímají data v multispektrálních, popř. hyperspektrálních pásmech [82].




Obrázek 4: Rozdíl mezi multispektrálními a hyperspektrálními daty

Zdroj: [82]

Samotný snímač může disponovat prvky, které mu mohou pomoci vylepšovat pořizované snímky, např.: teleobjektiv, fullframe čipy, sdružování pixelů (binning) [8], a jiné.

Po pořízení snímků následuje jejich základní zpracování/zpracování, které opravuje některé z vlastností nebo chyb při jejich pořízení (korekce). Při pořizování surových dat je vždy základní krok převod do formátu, který je následně jednodušeji zpracovatelný. Tím může být bezztrátový (např. TIFF) nebo ztrátový (např. JPEG) formát. Takto zpracovaná data mohou být dále distribuována a dále zpracována [66].

Schéma principu pro získávání/snímání dat je znázorněno na Obrázek 5, kde je využit jako snímač LIDAR [49].



Obrázek 5: Princip snímání dat – v tomto případě pomocí LIDARu

Zdroj: [49]

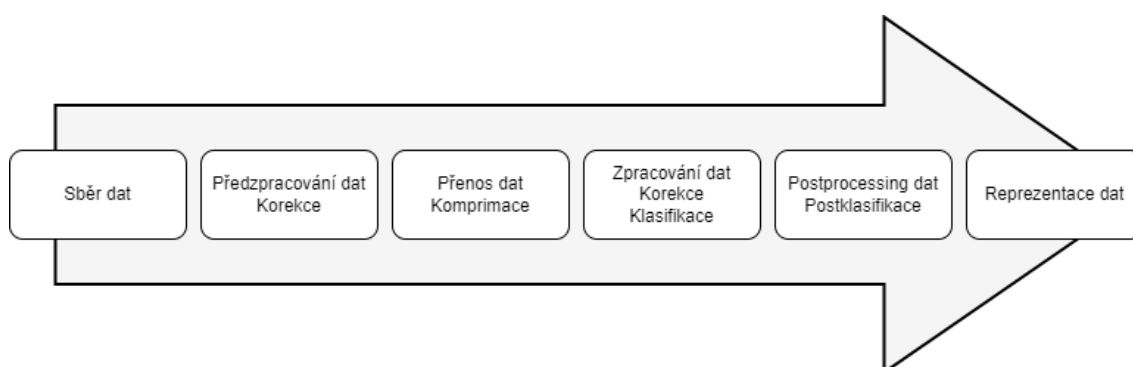
Pro sejmutí spektrální charakteristiky viditelné části spektra se v současné době nejčastěji využívají kamery s CCD čipem, což je světlocitlivý detektor obrazu, který využívají například digitální fotoaparáty, videokamery a webkamery. Senzorem snímající jiné charakteristiky může být laserový skener LIDAR [15][114]. V tomto případě se jedná o mračno bodů [74]. Senzor vysílá laserový paprsek, který následně odrazem od snímané oblasti zachytí nazpět a výstupem je mračno bodů, které vlastně tvoří 3D obraz snímané plochy, viz Obrázek 5. Dalším způsobem pro získávání 3D dat, je za pomoci stereoskopických kamer [87] nebo za pomoci plánované letu se specifickými plány letu. Speciální plánované lety jsou nejjednodušší a zároveň i nejlevnější možností pro získávání 3D dat [97][59].

Při získávání konzistentního vzorku dat pro sledovanou oblast hraje významnou roli i osvětlení, resp. nastavení senzoru na snímání ve stejném typu osvětlení [106]. Některé senzory nemusí být závislé na osvětlení, jedná se o multispektrální senzory snímající část elektromagnetického záření v délkách nezávislých na osvětlení (typicky infračervené pásmo pro sledování tepelného záření) [3]. Většina senzorů získává snímky sledovaného území při odrazivosti viditelného světla, zejména snímání v RGB spektru.

Všechny typy snímačů EM záření jsou v podskupině vzdáleného průzkumu neboli bez nutnosti fyzického kontaktu.

1.2 Obecný průběh celého procesu získávání dat

Celý průběh nebo proces získávání dat lze shrnout do několika základních kroků, které jsou identické pro většinu systémů vzdáleného průzkumu [25][72]. Po výběru zájmového území, čímž může být lokální území, region nebo celý stát, následuje sběr dat pomocí technologie, která poskytne nejlepší data na daný tvar zájmového území. Po získání dat je potřeba provést předzpracování dat. Technologie a techniky předzpracování dat mohou být přímo doplňujícím subsystémem k senzoru, tedy součástí sestavy. Po předzpracování dat následuje přenos dat ze snímacího systému ke zpracování. Proces zpracování obsahuje různé aplikace. Jsou uvedené v dalších kapitolách. Po zpracování dat následuje postprocesní fáze, pokud je potřeba provádět další úpravy již zpracovaných dat, nebo lze zpracovaná data rovnou interpretovat. Celý proces lze znázornit jako workflow na Obrázek 6.



Obrázek 6: Obecné workflow pro celý proces získávání dat

Zdroj: [vlastní zpracování]

1.3 Sběr dat s velmi vysokým prostorovým rozlišením

Tato kapitola popisuje, jaké jsou dostupné systémy pro pořizování dat s velmi vysokým prostorovým rozlišením, zejména vzhledem k tématu disertační práce. Obecně se tato informace váže k snímacímu senzoru, ale v praxi se uvažuje pro celou soustavu, tedy nosič, snímač a popř. doplňující zařízení.

1.3.1 Satelitní a letecké snímkování

Satelity poskytují relativně snadno snímky celé Země, avšak mají jisté nevýhody, mezi které patří např. potřeba atmosférických a geometrických korekcí, ale i jiné nevýhody. Některé z nich lze odstranit speciálními technikami předzpracování dat. Větší nevýhodou dat pořízených

pomocí satelitů je jejich prostorové rozlišení, které bylo historicky, ale i v současnosti je v řádech metrů na pixel, viz Tabulka 2.

Tabulka 2: Satelitní systémy

Satelitní systém	Prostorové rozlišení	Zdroj
WorldView-3 a WorldView-4 (DigitalGlobe)	31 cm/px panchromaticky 1,24 m/px multispektrálně	[34]
GeoEye-1 (DigitalGlobe)	41 cm/px panchromaticky 1,65 m/px multispektrálně	[37]
SkySat (Planet Labs)	50 cm/px panchromaticky	[45]
Kompsat-3 a Kompsat-3A (Korea Aerospace Research Institute)	41 cm/px panchromaticky 1,65 m/px multispektrálně	[68]
Sentinel-2 (Copernicus Programme, ESA)	10 m/px multispektrálně	[30]
SPOT 6 a SPOT 7 (Airbus Defence and Space)	1,5 m/px panchromaticky 6 m/px multispektrálně	[103]

Zdroj: [vlastní zpracování]

Moderní satelitní systémy poskytují prostorová data s vyšším detailem, tedy s velkým prostorovým rozlišením. Mezi nejmodernější satelitní systém se řadí Pleádes Neo. Pleádes Neo je satelitní systém určený k poskytování vysoce kvalitních a detailních snímků zemského povrchu. Skládá se ze čtyř satelitů, které společně poskytují globální pokrytí a umožňují rychlou reakci na aktuální potřeby uživatelů. Díky vysokému prostorovému rozlišení až 30 cm, vysoké geolokační přesnosti a schopnosti poskytovat jak multispektrální, tak panchromatické snímky, je Pleádes Neo ideální pro širokou škálu aplikací. [89]

Systém Pleádes Neo tedy představuje pokročilou technologii pro získávání a analýzu satelitních snímků, což přináší výhody v mnoha oblastech lidské činnosti. Avšak pokud je potřeba obrazových dat s vyšším prostorovým rozlišením, než poskytují satelity anebo jsou satelitní data drahá, tak lze využít leteckých snímků. Letecké snímkování obecně poskytuje obrazová data s vyšším prostorovým rozlišením než satelitní snímky, ale letecké snímky mají nižší plochu záběru než satelity, typicky jen konkrétní stát [86].

V České republice se letecké mapování provádí pravidelně a poskytuje detailní snímky zemského povrchu s vysokým prostorovým rozlišením. Hlavní organizací zajišťující tyto

služby je Český úřad zeměměřický a katastrální (ČÚZK), který spravuje ortofotomapy a další geodetické produkty. Mezi hlavní charakteristiky leteckého mapování v ČR patří [18]:

- Pořizování snímků s vysokým prostorovým rozlišením až 10 cm/px.
- Pravidelné aktualizace, půlka republiky každý rok (od roku 2012).
- Dostupnost dat pro veřejnost – Geoportál ČÚZK.
- Snímání pomocí různých senzorů, standardně RGB snímač, ale také LIDAR.

Letecké mapování v České republice je tedy důležitým nástrojem pro širokou škálu aplikací, poskytující velmi detailní a aktuální informace o povrchu země a je poskytováno ČÚZK [18].

1.3.2 Bezpilotní prostředky a bezpilotní systémy

V dnešní době je rostoucí požadavek na kvalitní a individuální obrazová data, která jsou dostupná ideálně hned – ASAP (As Soon As Possible). Jedním z prostředků, jak taková obrazová data získat jsou bezpilotní prostředky, resp. bezpilotní systémy. Bezpilotní systém lze podle Karase a Tichého [63] definovat jako soustavu dálkově řízené prostředku, řídicí stanice a dalších nezbytných součástí k provedení letu a komunikaci.

Bezpilotní prostředky (angl. unmanned vehicle někdy také unpiloted vehicle) nebo lidověji drony jsou stroje řízené na dálku operátorem/pilotem. Pojem dron se poprvé objevil ve 30. letech 20. století. Byl použit k označení bezpilotního letounu vytvořeného britským Královským námořnictvem známým jako DH.82B Queen Bee (včelí královna) [124]. Název Queen Bee pravděpodobně inspiroval používání termínu "drone" (česky trubec), který se později stal obecným označením pro bezpilotní letouny. Dron tedy představuje nejčastěji prostředek fungující ve vzduchu tedy bezpilotní vzdušný prostředek (angl. unmanned aerial vehicle – UAV, popř. unmanned aircraft – UA). Drony zažívají největší rozsah od přelomu posledního tisíciletí a souvisí s vývojem výpočetní techniky. [51]

Pro vyhledávání příspěvků spojených s využíváním bezpilotních prostředků je vhodné se zaměřit i na to, jaký výraz pro bezpilotní prostředek je potřeba vyhledávat [28]. Dalšími výrazy, které se používají mimo termín „dron“ nebo „UAV“ jsou: unmanned aerial system (UAS); remotely piloted aircraft (RPA); remotely piloted aircraft system (RPAS); micro air vehicle (MAV); small unmanned aerial system (sUAS); remotely piloted vehicle (RPV); remotely operated aircraft (ROA). [29]

Tabulka 3 zobrazuje četnosti jednotlivých výrazů pro označování bezpilotních prostředků v příspěvcích ve 2 největších databázích, a to WOS a SCOPUS. Z tabulky je vidět, že nejpoužívanější výrazy jsou unmanned aerial vehicle, unmanned aerial system, unmanned

aircraft, drone a jejich zkratky. Ostatní výrazy se vyskytují v desítkách až jednotkách stovek případů v databázi WOS a ty samé výrazy se vyskytují v jednotkách tisíc v databázi SCOPUS. Nadá se úplně tvrdit, že výrazy s nižším počtem záznamů v databázích se nemusí použít ve vyhledávání příspěvků, ale je jejich počet o dost méně významný, než jsou ty využívanější. Proto lze ty méně četné výrazy při vyhledávání publikací vynechat.

Tabulka 3: Četnost hledaných výrazů k pojmu bezpilotní prostředek od roku 2000 (k 18. 6. 2024)

Hledané klíčové fráze	WOS	SCOPUS
UAV OR Unmanned aerial vehicle	61 314	292 532
UAS OR Unmanned aerial system	12 499	56 257
sUAS OR small unmanned aircraft system	1 235	45 147
Drone	19 208	130 201
Quadcopter	2 355	13 653
Quadrocopter	225	3 969
Multicopter	466	3 499
RPA OR Remotely Piloted Aircraft	13 269	44 355
RPAS OR Remotely Piloted Aircraft System	1 038	155 106
RPV OR Remotely Piloted Vehicle	4 104	78 717
ROA OR Remotely Operated Aircraft	12 989	132 700
UA OR Unmanned Aircraft	174 031	390 251
MAV OR Micro Air Vehicle	6 766	32 612

Zdroj: [vlastní zpracování]

Bezpilotní prostředek sám o sobě je defacto nepoužitelný, protože nemá žádné ovládací prvky. Každý bezpilotní prostředek se ovládá pomocí dálkového ovladače (remote controller) nebo pomocí aplikace, kterou ovládá operátor anebo kombinací aplikace a dálkového ovladače. Kombinace dálkového ovladače a aplikace je nejběžnější způsob ovládání bezpilotního prostředku, neboť pilot vidí veškeré letové informace na zobrazovacím zařízení včetně obrazu z kamery, pokud je jí stroj vybaven. Bezpilotní prostředky ovládané pomocí aplikace se již tolik nevyskytují a jsou to zejména experimentální stroje nebo stroje staršího typu jako Tarot 690.

Ovládání Tarotu 690 bylo zmíněno v závěrečné práci [57], bezpilotní prostředek byl ovládán pomocí aplikace DJI Ground Station Desktop [24]. V tomto případě aplikace nahrazuje dálkový ovladač (ale je s ním spojená) a operátor ovládá bezpilotní prostředek skrze rozhraní aplikace.

DJI Spark je bezpilotní prostředek, který umožňuje ovládání pomocí dálkového ovladače včetně kombinace s aplikací, pomocí samotné aplikace napojené přímo na bezpilotní prostředek, a navíc je zde ovládání pomocí gest. DJI [24] zde vyzdvihuje technologii ovládání pomocí gest jako “seize the moment”. Od tohoto přístupu se s dalším vývojem bezpilotních prostředků odstoupilo a dnes se téměř vždycky využívá kombinace dálkového ovladače ve spojení s aplikací.


Operátor nebo také pilot bezpilotního systému je osoba, která ovládá dron a dohlíží na něj nebo může dronu naplánovat let a dohlížet na něj. Aplikace pro plánování letu tedy zastupuje pilota v ovládání a bezpilotní prostředek létá podle naplánovaného plánu letové mise z aplikace, defacto se dá říct, že se jedná o autopilota. Takovýto režim může být i autonomní, kde dron reaguje na podmínky z okolí. [62]

Jak bylo zmíněno v předchozí kapitole, tak bezpilotní prostředek je sám o sobě nepoužitelný. A proto je vhodnější mluvit o bezpilotním systému, který kombinuje samotný bezpilotní prostředek, dálkové řízení a pilota. Pro tuto sestavu se využívá označení bezpilotní systém nebo UAS [42][4]. UAS je opět na veřejnosti nahrazováno termínem dron, kde je pod termínem dron označována celá soustava řídicích prvků.

O tom, jak a jakým způsobem se létá s bezpilotními prostředky, hovoří vždy legislativa na národní úrovni. Úroveň legislativy může být i na širší členství států, jako např. Evropská legislativa o provozu UAS [64], která je platná pro všechny státy “EASA”. Národní legislativa je, ale vždy nad ostatními. V Čechách tuto legislativu spravuje a provádí úřad pro civilní letectví (ÚCL). Historicky se v Čechách létalo podle legislativy doplňku X předpisů L2 [27], platnou jak pro komerční a akademickou sféru, tak i pro hobby piloty, která platila do 1. 1. 2021, kdy vešlo v platnost Evropské nařízení o létání v kategoriích OPEN, SPECIFIC a CERTIFIED. Tato legislativa klasifikuje bezpilotní prostředky do kategorií podle tříd typů C0 až C4.

Bezpilotní prostředky lze klasifikovat dle velké škály kritérií/způsobů. Existují různé přístupy pro klasifikaci kategorií bezpilotních prostředků. Skrze všechny přístupy klasifikování je to nejzákladnější určení pro armádní využití a civilní využití. Jako většina technologií, tak i bezpilotní systémy přišly ke svému největšímu rozmachu a technologickému skoku díky vojenskému využití. Pomineme-li začátky bezpilotních prostředků typu “V-1” a “V-2” během 2. světové války, tak největšího využití a technického pokroku zažívá toto odvětví od 70. letech 20. století [108], díky válečným událostem na blízkém a dálném východu. Pro toto období

je nejikoničtější bezpilotním prostředkem americké armády typ “MQ-1 Predator” [1], nejdříve jako průzkumný a poté i jako útočný bezpilotní letoun i systém. V civilním sektoru se bezpilotní prostředky typu multikoptér začínají objevovat od roku 2006. Již před tímto datem se v modelářství využívaly bezpilotní prostředky typu letadlo nebo vrtulník, ale jednalo se zejména o modely nebo hračky. Klíčovým je rok 2013, kdy firma DJI přichází na trh s modelem Phantom a firma Amazon oznamuje doručování balíků pomocí bezpilotních prostředků. Toto je okamžik, od kterého se širší veřejnost začíná všimnout bezpilotních prostředků. Pokud vezmeme v potaz vývoj daných slov obecně v knihách ze zdroje Google NGRAM [41], tak lze vypořádat rostoucí trend přesně v okamžik přelomu 80. a 90. let, tedy vývoj výpočetní techniky, viz Obrázek 7. A poté je další skok, zejména pro termín “drone” od roku 2012, kdy se této technologii stává populární.



Obrázek 7: Výskyt nejpoužívanějších výrazů pro bezpilotní prostředek, 1945–2019

Zdroj: [41]

Jak již bylo zmíněno, tak existuje mnoho kritérií/způsobů, jak lze klasifikovat bezpilotní prostředky pro civilní využití. Historicky se bezpilotní prostředky klasifikovali podle způsobu použití a tomu také odpovídala jejich velikost. Například bezpilotní prostředky využívané v kinematografickém průmyslu byly typické pro svoji velikost a váhu, nejběžněji hexakoptéry spíše až oktakoptéry s možností nést filmařskou kameru, tedy hmotností v desítkách kilogramů. Oproti tomu bezpilotní prostředky pro sportovně rekreační využití (hobby) byly menší dragy, typicky quadrokoptéry s hmotností okolo jednoho kilogramu. Tento způsob lze aplikovat i dnešní době, ale trochu ztrácí smysl, a to kvůli vývoji výpočetní techniky a miniaturizaci komponent bezpilotních prostředků. Obrázek 8 reprezentuje porovnání velikostí dronů, které mají identické letecké vlastnosti. [24]



Obrázek 8: Porovnání velikostí bezpilotních prostředků

Zdroj: [vlastní zpracování]

Dříve se experimentovalo a využívalo bezpilotních prostředků s různými stavbami dragu od 3rotorových až po 8rotorové, a z tohoto směru se klasifikovalo na základě konstrukce. Dále se využívalo různých typů pohonů ať už od elektrických, hydraulických i spalovacích, tedy klasifikování na základě typu pohonu. Od tohoto se upustilo a jako ověřený a osvědčený se ukázal stroj typu quadrokoptéra se čtveřicí nebo osmicí rotorů na elektrický pohon [44]. Tento typ tvoří většinou nabídku dnešní produkce. Avšak výzkum a vývoj dále pokračuje, důkazem tohoto je rostoucí obliba bezpilotního prostředku typu pevné křídlo.

Legislativní klasifikace bezpilotních prostředků je jednoznačná. Krom kategorií provozu se dále klasifikuje na základě maximální vzletové hmotnosti (MTOW) [64], resp. výpočtu dopadové energie na zem. Tento přístup je celosvětový, a proto i firmy zabývající se produkcí bezpilotních prostředků, se drží těchto tříd a pokrývají své portfolio stroji v každé třídě. Nejnížší třída do pro stroje do hmotnosti 250 gramů (označována jako A1), následuje třída od 250 gramů do 900 gramů (A2) a nejvyšší kategorie od 900 gramů do 25 kilogramů (A3). Legislativa má v těchto kategoriích i podkategorie [109].

Výše zmíněné hmotnosti se týkají kompletního vybavení bezpilotního prostředku, které je tvořeno: dragem s řídicí jednotkou a senzory; baterií; vizuálním snímačem. Proto je v některých

kategoriích vykoupený některý z prvků na základě celkové hmotnosti. Proto je při volbě využívání bezpilotních prostředků kladen velký důraz zejména na dobu letu a kvalitu výstupního materiálu (snímku) [65].

1.3.3 Vhodný prostředek pro sběr dat s velmi vysokým prostorovým rozlišením

Z výše uvedených kapitol vyplývá, že bezpilotní prostředky jsou nejvhodnější prostředky pro získávání obrazových dat s velmi vysokým prostorovým rozlišením. Z tohoto důvodu bude dále v práci už jen zmiňován bezpilotní prostředek, resp. bezpilotní systém, jako poskytovatele obrazových dat.

Bezpilotní prostředky v moderní době dosahují velmi kvalitních RGB obrazových dat i při nízké ceně za stroj samotný. Takovéto bezpilotní prostředky lze řadit do kategorie nízko nákladových zdrojů dat, ale poskytujících kvalitní obrazový výstup s velmi vysokým prostorovým rozlišením. K aktuálnímu datu (13. 6. 2024) lze na trhu pořídit bezpilotní prostředky s kvalitním snímačem (kvalitní parametry snímače) od 10 do 60 tisíc korun českých. Tím se takovéto bezpilotní prostředky stávají zajímavý a dostupným zdrojem kvalitních dat.

1.4 Režimy provozu bezpilotních prostředků/systémů

Tato kapitola navazuje na závěr předchozí kapitoly, kde byl uveden bezpilotní prostředek jako ideální prostředek pro získávání dat s velmi vysokým prostorovým rozlišením. Proto se následující text vztahuje k bližšímu specifikování charakteristik bezpilotního prostředku.

Provozování bezpilotního prostředku ve smyslu samotné létání lze rozdělit do 3 kategorií: manuální režim; automatický režim (plánovaný let) a autonomní let. Získávání dat zejména pomocí plánovaného letu je velmi žádoucí, jelikož zaručuje minimální redundanci dat a maximální pokrytí naplánovaného letu za pomoci parametrizace plánu i letu samotného. Výstupní data (snímky) z plánovaného letu poskytují ideální vstupní data do ortofotomapy nebo také mozaiky. [50]

Manuální režim je režim řízení bezpilotního prostředku zcela ze strany pilota. Tento režim má minimální požadavky na prvky soustavy, kterými jsou bezpilotní prostředek, dálkově řízený ovladač a pilot. Většinou má pilot zapnuté pomocné systémy řízení pro asistenci stabilizace stroje v prostoru za pomoci globálního polohového systému a pro stabilizaci samotného stroje ve 3osách pomocí IMU jednotky. Pilotování stroje zcela bez asistenčních systémů je vhodné

pro tzv. FPV režim, kde se se strojem dají dělat akrobatické kousky. FPV stroje jsou typicky trochu odlišné konstrukce a z většiny se využívají v zábavním průmyslu [100]. Rozdíl mezi klasickým dronem a FPV lze vidět na Obrázek 9.



Obrázek 9: FPV vs. klasický bezpilotní prostředek (produkty DJI)

Zdroj: [24]

Automatický režim řízení bezpilotního prostředku znamená řízení za pomoci pilota a další aplikace, hovoří se také o plánovaném letu. Minimální požadavky na soustavu jsou bezpilotní prostředek (umožňující automatický režim), dálkově řízený ovladač, pilot a aplikace pro plánovaný let. V aplikaci pro plánovaný let se navrhne letový plán, který bude prostředek dodržovat se všemi jeho parametry. Aplikace často umožňují naplánovat let a pak i provádět samotný let, popřípadě naimportovat jinde naplánovaný let a ten poté řídit. Princip plánovaného letu je v definování letu (různé typy), poté nahrání letových parametrů do stroje a následně kontrole samotného letu. Letové plány jsou nahrány do stroje z důvodu výpadku signálu, kdy může stroj nejdříve dolétnout daný plán a až poté provést bezpečnostní funkce neboli fail safe funkce [52][46]. Plánovaný let může mít různé podoby od nejzákladnějších, let z bodu A do bodu B, přes skenování oblastí, až k vícevrstevným kruhovým letům pro 3D snímání. Většina plánovaných letů je pro skenování oblastí, kde je princip založen na průletových bodech tzv. waypoints, tedy bodech v prostoru, kterými se stroj řídí, resp. na těchto bodech získává sken oblasti neboli snímek. Waypoints jsou body na letové trajektorii, které jsou vypočteny na základě parametrů letu, parametrů kamery a jiných parametrech. Minimální vstupní parametry pro výpočet waypoints jsou překryvy snímků (podélné a příčné), letová hladina a ohnisko kamery. Samotný plánovaný let lze spustit v automatickém režimu zcela od začátku do konce, ale doporučuje se vzlétnout v manuálním režimu a poté „předat“ stroj plánovanému letu, pilot má vždy možnost zasáhnout do letu. Po dokončení plánu je také doporučeno přistát v manuálním režimu.

Autonomní režim řízení bezpilotního prostředku je takový provoz, viz Obrázek 10, kde je stroj schopen provést bezpečný let bez zásahu pilota [54].



Jaký je rozdíl mezi autonomním a automatickým dronem?

— Jaký je rozdíl mezi autonomním a automatickým dronem?

Autonomní dron je schopen provést bezpečný let bez zásahu pilota. Činí tak pomocí umělé inteligence, která mu umožňuje zvládat všechny druhy nepředvídaných a nepředvídatelných nouzových situací. Tím se liší od **automatického** provozu, kdy dron letí předem určené trať definované provozovatelem dronu před zahájením daného letu. U tohoto typu dronu je nezbytné, aby dálkově řídící pilot převzal kontrolu nad dronem a zasáhl při nepředvídaných událostech, pro které dron nebyl naprogramován. Zatímco **automatické** drony jsou povoleny ve všech kategoriích provozu, **autonomní drony nejsou povoleny v „otevřené“ kategorii provozu.**


Autonomní drony vyžadují úroveň ověření souladu s technickými požadavky, což není slučitelné se systémem zavedeným pro „otevřenou“ kategorii. Autonomní provoz je místo toho povolen ve „specifické“ kategorii, kde nařízení obsahuje dostatečně pružný nástroj pro ověřování požadavků s odpovídající úrovní robustnosti.

Autonomní provoz je povolen také v „certifikované“ kategorii provozu.

Obrázek 10: Výňatek definice rozdílu typů letů podle ÚCL

Zdroj: [54]

Autonomní režim provozu bezpilotního prostředku je řízen pomocí umělé inteligence, která umožňuje zvládnout všechny druhy nepředvídaných situací a chování stroje. Tímto se zcela odlišuje od plánovaného letu, kde se stroj zcela poddává letové trajektorii. Tento způsob se nejčastěji využije pro letu z bodu A do bodu B, kde jsou brány v potaz veškeré překážky na dráze letu. Nejčastější využití pro tento způsob řízení stroje je při využívání fail safe funkcí návratu stroje na místo vzletu. Autonomní řízení se využívá také jako podpůrný systém pro manuální let, kdy se za pomoci směrových kamer detekují objekty v dráze letu a stroj na ně reaguje. Tento způsob reakce je zejména uplatňován v případě automatického návratu na „home point“. Reakce spočívá v překonání překážky obletem jiným směrem, než je dráha letu např. oblet kolem překážky tzv. fly-bypass [47], viz Obrázek 11.



Obrázek 11: Reakce antikolizních systémů na překážku, fly-bypass

Zdroj: [47]

1.5 Plánovaný let

Plánování letu je proces přípravy všech aspektů plánovaného letu před vzletem. Zahrnuje komplexní posouzení různých faktorů k zajištění bezpečného a efektivního provedení letu [5]. Plánování letů je zásadní pro pilotované i bezpilotní letouny (jako jsou drony) a je standardní praxí v letectví. Hlavními faktory jsou výpočet paliva a soulad s řízením letového provozu. Existuje několik přístupů k plánování letů: jako traťový let, polygonový let a další [95]. Pro oblast skenování je nejrelevantnější polygonový plánovaný let, který poskytuje optimální pokrytí získanými obrazovými daty s minimální redundancí. Pro co nejlepší kvalitu získaných obrazových dat jsou vyžadovány vstupní parametry pro plánovaný let jako je překrytí obrazu 80 % a více a GSD [110]. GSD (ground sample distance) představuje velikost jednoho pixelu na zemi a souvisí s výškou letu a možnostmi kamerového senzoru.

Tabulka 4 znázorňuje četnosti publikací v databázích WOS a SCOPUS, ve kterých bylo využíváno plánovaného letu pro bezpilotní prostředky.

Tabulka 4: Četnost hledaných výrazů od roku 2000 (k 18. 6. 2024)

Hledaný výraz	WOS	SCOPUS
flight planning	679	3 211
planned flight	95	259
planned flight AND (drone OR uav)	23	68
flight planning AND (drone OR uav)	212	1 343

Zdroj: [vlastní zpracování]

1.6 Předzpracování a zpracování obrazu

Data v obrazové podobě, tedy obrazová data, mohou být v rámci dálkového průzkumu země pořízena bezkontaktními metodami formou fotografií. Jedná se o snímaná analogová data nebo snímky ze skenerů, radarů v digitální podobě, jedná se tedy o digitální data. Analogová data lze převést na digitální a digitální je možné převést na analogová. Digitální obraz je obrazová informace převedena do číslicové formy a je nutné počítat s určitým stupněm generalizace. Je tedy nutné pracovat s geometrickou rozlišovací schopností o určité velikosti, která už je dále nedělitelná. Digitální obraz se skládá z na sebe navazujících pixelů, které nabývají hodnot, tzv. DN – Digital Number. Za počátky praktického využívání digitálního zpracování obrazu se považuje první polovina 70. let dvacátého století [25]. V této době dochází k rozvoji výpočetní techniky (vstup osobních počítačů – PC na trh) a dostupnost digitálních dat poskytovaných družicemi [66].


Autoři [66] rozdělili digitální zpracování obrazu do čtyř hlavních operací. A to na předzpracování obrazu, zvýraznění obrazu, klasifikaci a postklasifikační úpravy. Tyto operace se odvíjí i od obecného schéma pro celý proces sběru a zpracování dat, viz Obrázek 6 z kapitoly o obecném průběhu procesu získávání dat.

1.6.1 Zpracování obrazu

Pořízený snímky pomocí dálkového průzkumu je potřeba v některých případech nejprve upravit, aby odpovídali realitě. Takovéto úpravy se nazývají korekce obrazu a patří mezi ně: atmosférická korekce, radiometrická korekce a geometrická korekce [76]. U bezpilotních prostředků je potřeba provádět geometrické korekce související s výškou letu, jelikož bezpilotní prostředky létají v nízké letové hladině do 120 metrů nad povrchem, tak vzniká výraznější

zkreslení perspektivy. Chyby vzniklé perspektivou kamery lze odstranit pomocí ortotransformace, georeferencováním nebo mozaikováním [22]. Na obrazových datech pořízených bezpilotními prostředky mohou vznikat atmosférické chyby, ale jen ve velmi omezené míře, mezi ně patří např.: prach. Pak je potřeba provést atmosférické korekce jen pomocí softwarového nástroje [99]. Radiometrické chyby mohou vznikat na snímcích získaných pomocí bezpilotního prostředku a nejčastěji se jedná o stíny, úhel zdroje světla (slunce), špatně kalibrovaný snímač. Většinu těchto chyb se lze vyhnout čistě pomocí zkušeností pilota, aby zvolil nejlepší podmínky pro let a získávání dat.

Pokud se jedná o data pořízená zejména pomocí bezpilotních prostředků, popř. letadel, tak je zpravidla potřeba snímky zpracovat do celistvého snímku tzv. mozaiky [73]. Skládání snímků do mozaiky souvisí s velikostí zájmového území, typicky satelitní snímky snímají plochu v řádech km^2 . U skládání jednotlivých snímků do celistvé mozaiky hrají hlavní roli plánovaný let a nastavení vyvážení barev snímače, zejména vyvážení bílé. Jak bylo zmíněno v dřívější kapitole, tak plánovaný let zajišťuje konzistenci snímaného území s nastavenými překryvy a zároveň minimalizuje redundanci dat. Skládání jednotlivých snímků do mozaiky je proces hledání klíčových prvků na dvou různých snímcích a jejich následné spojení [116]. Při spojování snímků dochází k jejich úpravám, a to k ohýbání snímků a přizpůsobování pro celistvou projekci. Je to z toho důvodu, že každý pořízený snímek z bezpilotního prostředku (i z letadla) má centrální projekci a okraje snímku jsou zkosené směrem od středu [38], viz Obrázek 12.



Obrázek 12: Centrální projekce pořizování snímků

Zdroj: [38]

1.6.2 Mozaikování

V rámci procesů po pořízení dat je jedním z těchto procesů i možnost vytvářet celistvý snímek snímaného území tzv. mozaiku. Proces mozaikování je vytvoření celistvého snímku, někdy také ortofoto mapy, na základě pořízených jednotlivých snímků [70]. Pro tvorbu mozaiky se pro pořízení obrazových dat zejména využívají plánované lety. Plánované lety provádí přesné lety s nastavenými letovými parametry a optimálně rozmístěnými body, ve kterých se pořizují snímky [33].

Proces mozaikování spojuje jednotlivé snímky na základě nalezených vlíčovacích bodů, opravuje zkreslení na pořízených snímcích centrální projekcí a vytváří jediný snímek [111], který je převážně ortogonální, viz Obrázek 12.

1.6.3 Manuální identifikace

Manuální identifikace je velmi důležitý prvek v rámci celého procesu automatického klasifikace obrazových dat pro ověření přesnosti klasifikace, ale i pro jiné případy. Manuální identifikace, někdy také manuální digitalizace, je proces vytváření jednotlivých bodů, linií nebo polygonů na získaných obrazových datech [112]. Je to zcela ruční proces prováděný GIS administrátorem nebo operátorem. Rozlišovací přesnost závisí na operátorovi, který tato data ručně zadává, resp. na jeho místní znalosti nasnímaného prostředí.

Tento proces je z hlediska času velmi náročný. Pokud je digitalizace provedena úspěšně/uspokojivě, tak se výstupní digitální snímek stává referenčními obrazovými daty [6].

1.6.4 Klasifikace a postklasifikační úpravy

Klasifikace obrazu je proces přiřazování jednotlivých pixelů v obraze (nebo skupinám pixelů) do předem definovaných kategorií nebo tříd na základě jejich spektrálních, texturálních a kontextuálních charakteristik [94].

Postklasifikační úpravy obrazových dat jsou kroky a techniky, které se aplikují na obrazová data po provedení klasifikace. Tyto úpravy jsou důležité pro zlepšení použitelnosti výsledků z klasifikací a zahrnují různé metody pro odstranění chyb. Mezi techniky zlepšení lze například zařadit filtrování, překlasifikování, mapovou algebru, hodnocení přesnosti a další [43].

Klasifikace je nejpodstatnější část této práce, a proto ji bude věnována odpovídající pozornost i detailní popis v disertační práci. V pojednání o disertační práci autora je v následujících kapitolách zmíněna zejména teoreticky a dále jsou uvedeny vlastní výsledky autora.

1.7 Klasifikace obrazových dat

Výstupní data pořízená pomocí bezpilotního prostředku mohou být užitečná sama o sobě, ale teprve s nějakou analýzou dostávají větší význam. Existuje více analýz nad obrazovými daty, může to být např. segmentace, detekce změn, klasifikace obrazových dat. Poslední

zmíněná je většinové zastoupení při pracování obrazových dat, a proto je i tímto směrem veden výzkum v disertační práci.

Podle [105] je klasifikace proces, kde jsou nahrazeny naměřené hodnoty hodnotami informačními. Informační hodnoty se odvíjí od podstaty problematiky, na které proces klasifikace probíhá. Proces klasifikace využívá klasifikátory, které zařazují jednotlivé dílčí části (objekty, pixely, hodnoty) v datech do určitých tříd. Liu a Mason [75] chápou klasifikaci jako počítačovou vědu, která se zabývá rozpoznáváním vzorů, a to podle statistických vlastností v případě shlukování nebo segmentace založené na prostorových a statistických vztazích mezi obrazovými body. Uvádí, že klasifikace se dělí na dva hlavní směry, a to na klasifikaci neřízenou a řízenou, anglicky *unsupervised* a *supervised*. V některých publikacích jsou tyto dva klasifikační směry označovány jako učení bez učitele a učení s učitelem. [9]

Moderní pojetí klasifikaci dat je za využívání umělé inteligence. Velké uplatnění klasifikace dat je při využívání strojového učení. Jednou z podskupin strojového učení jsou metody založené na neuronových sítích, které dosahují dobrých výsledků klasifikace dat [91][92][93]. Další podskupinou strojového učení jsou klasifikace pomocí hlubokého učení. Tento přístup klasifikace je přímo integrován v nejrozšířenějším komerčním GIS produktu ArcGIS PRO od firmy ESRI (přímo od verze 2.6) [20]. Tento nástroj je integrován jako jedna z možností zpracování obrazových dat, resp. přímo jedna z metod pro klasifikaci dat. Tato informace je důležitá pro autorovu část disertační práce.

Vyhodnocení správnosti klasifikace se provádí vůči referenčním datům. V tomto procesu se např. porovnávají jednotlivé náhodně zvolené body mezi klasifikovaným snímkem a referenčními daty. Pro zhodnocení správnosti klasifikace lze využít různé metriky. Jedny z nejpoužívanějších metrik jsou celková přesnost, která říká, jaký podíl ze všech kategorií byl klasifikován správně. Cohonen kappa koeficient, který vyjadřuje míru shody dvou proměnných (bodů). [117]

Výpočet celkové přesnosti v podstatě říká, jaký podíl ze všech referenčních vzorků byl klasifikován správně. Celková přesnost je obvykle vyjádřena v procentech, přičemž 100% přesnost je dokonalá klasifikace, kde byla všechna referenční místa klasifikována správně. Výpočet celkové přesnosti je založen na součtu správně klasifikovaných tříd, který je vydělený celkovým počtem vzorů. Celková přesnost je nejjednodušší na výpočet a pochopení, ale v konečném důsledku poskytuje uživateli pouze základní informace o přesnosti [2].

Diagonální prvky představují oblasti, které byly správně klasifikovány. Pro výpočet celkové přesnosti sečtete počet správně klasifikovaných lokalit a vydělíte jej celkovým počtem referenčních lokalit.

Výpočet Cohenova kappa vychází ze čtvercové kontingenční tabulky. Je založen na porovnání odhadu pravděpodobnosti relativní shody, viz Obrázek 13 (součet celkových procent diagonálních prvků) a očekávané pravděpodobnosti shody za předpokladu nezávislosti daných dvou hodnotitelů (tj. pravděpodobnosti náhodné shody) [14].

$$\kappa = \frac{\text{Pr}(a) - \text{Pr}(e)}{1 - \text{Pr}(e)},$$

Obrázek 13: Vzorec pro výpočet Kappa koeficientu

Zdroj: [14]

Kappa může nabývat hodnot z intervalu $\langle -1, 1 \rangle$, záporné hodnoty se však vyskytují spíše výjimečně [79]. Maximální možná hodnota 1 vyjadřuje perfektní shodu, 0 odpovídá pravděpodobnosti shody odhadnuté z tabulky. Záporných hodnot nabývá kappa v případě, že je pravděpodobnost shody odhadnutá z tabulky dokonce nižší než pravděpodobnost náhodné shody, což se stává zřídka.

1.7.1 Neřízené klasifikační metody

Neřízenou klasifikaci lze definovat [94] jako identifikaci přirozených skupin nebo struktur dat pomocí shlukování, které je založeno na shlukové statistice. Kdy je každá buňka zařazena do shluku a následně je označena stejným označením daného shluku (symbol, barva, hodnota). Autoři [11] uvádí jako přednosti neřízené klasifikace minimální možnost lidské chyby, protože lidský element pouze určuje množství klasifikačních tříd. Dále uvádí, že u této metody nejsou potřebné znalosti o zájmovém území, jelikož vychází ze vstupních dat přímo. Znalosti o zájmovém území jsou potřebné k interpretaci výsledků a popř. zhodnocení přesnosti. Ze samotného procesu seskupování a přiřazování shluků k informačním kategoriím vychází nevýhody této metody.

Mezi nejvíce využívané neřízené klasifikační metody na bázi shlukové analýzy řadíme metody Iso Cluster/Isodata a metody K-means. Z Tabulka 5 lze vidět, že se neřízená klasifikace obrazových dat využívá v menší míře i ve spojení s GIS a vzdáleného průzkumu.

Tabulka 5: Četnost výskytů neřízené klasifikace ve vědeckých databázích za celou dobu (k 11. 11. 2023)

Hledaná klíčová slova	Počet výskytů	
	WOS	SCOPUS
Unsupervised classification	3721	19008
Unsupervised classification & GIS	239	2068
Unsupervised classification & Remote sensing	1593	8393
Unsupervised classification & Image classification	377	4099
Unsupervised classification & Image classification & GIS	28	749
Unsupervised classification & Image classification & Remote sensing	248	3500
Unsupervised classification & Remote sensing & GIS	179	1858

Zdroj: [vlastní zpracování]

1.7.2 Řízené klasifikační metody včetně moderních přístupů

Řízená klasifikace je nejčastěji využívaná technika pro kvantitativní analyzování obrazových dat získaných DPZ [94]. Autoři [11] uvádí, že řízená klasifikace je proces, v rámci kterého se klasifikují buňky na základě předem identifikovaných vzorků. Jedná se o buňky umístěné v tzv. trénovacích množinách. Oblasti by měly být stejné informační hodnoty tedy homogenní v návaznosti na klasifikační třídu. V rámci procesu řízené klasifikace je při prozkoumávání trénovacích dat možné odhalit chyby. Výsledek z trénovacích dat může představuje hodnotu odhalující problémy v klasifikaci nebo ve výběru trénovacích vzorků. Správná klasifikace trénovacích dat nemusí vždy automaticky znamenat správnou klasifikaci následných dat v testovací množině. Dle autorů [75] je řízená klasifikace postavena na znalostech a zkušenostech tvůrce dat, který provádí řízenou klasifikaci, a také závisí na jeho místních znalostech, znalostech o zájmovém území. Zejména místní znalost může výsledek klasifikace zkreslit autorovým subjektivním pohledem. Opakem se stejným výsledkem může být úplná neznalost území, která může být zavádějící.

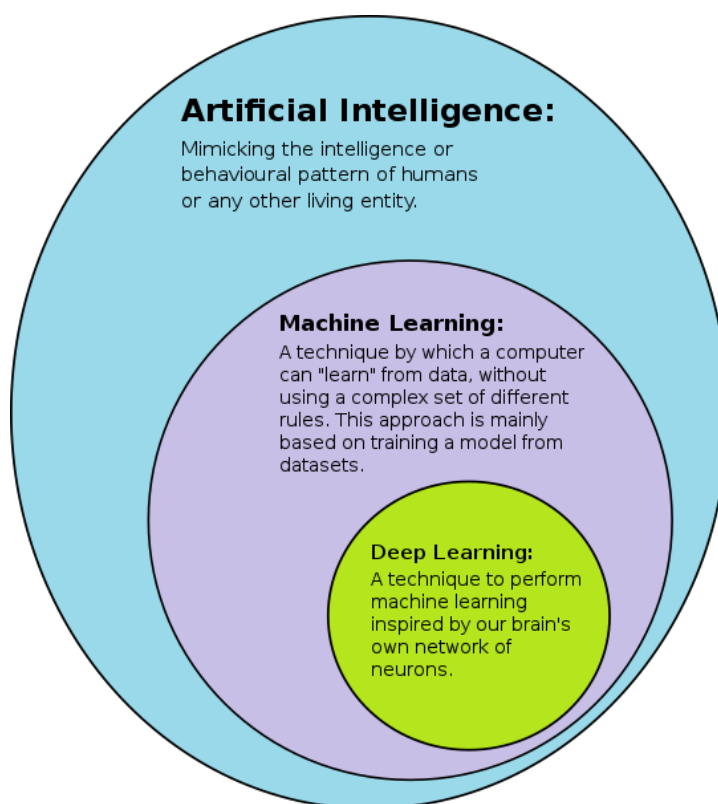
Mezi nejpoužívanější metody řízené klasifikace se řadí metoda Maximum Likelihood, jinak také Gaussian Maximum Likelihood Classifier [72]. Tato metoda je již dlouho známá [104] a uplatňuje se v široké škále odvětví. Mezi modernější metody využívané v hojné míře patří metody podpůrných vektorů neboli Support Vector Machine a metody náhodných stromů neboli Random Trees. V posledních letech s rozvojem strojového učení a umělé inteligence

se začala i tato oblast využívat v řízené klasifikaci, a to pomocí hlubokého učení neboli Deep Learning, které spadá to těchto oblastí umělé inteligence [48] [9], viz Obrázek 14. Tabulka 6 znázorňuje podobnou závislost využívání řízených klasifikačních metod v publikacích jako u metod neřízených, ale počet výskytů je celkově vyšší.

Tabulka 6: Četnost výskytu řízené klasifikace ve vědeckých databázích za celou dobu (k 11. 11. 2023)

Hledaná klíčová slova	Počet výskytů	
	WOS	SCOPUS
Supervised classification	9786	57394
Supervised classification & GIS	832	5624
Supervised classification & Remote sensing	3553	16457
Supervised classification & Image classification	899	12502
Supervised classification & Image classification & GIS	75	2194
Supervised classification & Image classification & Remote sensing	607	8030
Supervised classification & Remote sensing & GIS	672	4960

Zdroj: [vlastní zpracování]



Obrázek 14: Hierarchie systémů umělé inteligence

Zdroj: [48]

1.8 Omezení při klasifikaci RGB obrazových dat

Získaná RGB obrazová data jsou velmi dobrým zdrojem informací, zejména v rámci prostorového rozlišení, ale mají i své omezení. Ač je proces získávání těchto dat velmi jednoduchý, tak je i jejich schopnost rozlišovat odlišnosti na snímcích omezena. RGB obrazová data jsou tvořena reálným obrazem z viditelného spektra a jednotlivé hodnoty pixelů jsou jen barevné hodnoty DN v barevném modelu RGB. Tedy neposkytují jiné informace, než které vidí i uživatel svým zrakem [39].

Z tohoto důvodu je omezena klasifikace, a to zejména pixelová klasifikace obrazových dat. Tento přístup klasifikuje stejné barvy jednotlivých pixelů do stejných tříd, to může zapříčinit, že např. koně hnědé barvy budou klasifikovány jako holá hnědá půda a podobně. Tento jev lze lehce vypožorovat při identifikaci zvěře ve venkovním prostředí typu louka a pole, kde mají zvířata i holá zem stejné odrazivé hodnoty v RGB pásmu [55].

1.9 Výzvy pro využití nového přístupu ke klasifikaci obrazových dat

Aby byly obrazové klasifikace za bázi RGB obrazových dat v reálných aplikacích více účinné, je na základě autorovy znalosti stávajícího stavu dané problematiky a na základě jeho praktických zkušeností potřeba překonat následující problémy:

- **Kvalita vstupních dat** – Moderní snímací technika (senzor a optika) poskytuje velmi kvalitní obrazová data, která dosahují dobrých výsledků i při zhoršených světelných podmínkách. Problémem může být vyvážení bílé při snímání za využití kompresního formátu snímků (jpeg, png). Tato hodnota musí být vždy nastavená na stejnou hodnotu vyvážení bílé, během všech získávání dat, aby se dosáhlo stejného barevného odstínu u všech pořízených snímků. Software se snaží získat, co nejkvalitnější snímky a má ve výchozím nastavení nastaveno automatické vyvážení bílé a takto pořízené snímky jsou barevně odlišné – expozičně odlišné.,
- **Spektrální rozlišení dat** – U RGB obrazových dat jsou pouze 3 barevná spektra, a to je jejich největší omezení. Pomocí speciálních spektrálních indexů, založených na RGB pásmech, lze využít spektrální zvýraznění obrazu, ale jen omezeně.,
- **Klasifikátory** – Řízené i neřízené klasifikační metody poskytují odlišné přesnosti klasifikací. Dlouhodobě (z vlastní zkušenosti) poskytují metody SVM a Maximum Likelihood dobré výsledky, ale jsou u případy, kdy tyto metody selžou a dosáhnou špatných výsledků.

Vzhledem ke stávajícímu stavu klasifikace RGB obrazových dat, který byl popsán v předchozích kapitolách a vzhledem k výzvám a omezením v této oblasti, je navrhnout nový přístup pro klasifikaci RGB obrazových dat.

Důvod, proč byla vybrána RGB obrazová data, je především snadnost jejich pořízení a možnost využívat historická data. Snadnost pořízení vyplývá i z možnosti získávat tato data pomocí bezpilotních prostředků vybavených RGB snímači. S tím souvisí i další výhoda, a to je spektrální rozlišení pořízených RGB obrazových dat. V případě snímání dat pomocí bezpilotních prostředků se hovoří o velmi vysokém prostorovém rozlišení [72]. Velmi vysoké prostorové rozlišení může přinést spoustu výhod při identifikaci menších objektů na takto pořízených snímcích.

2 CÍLE DISERTAČNÍ PRÁCE A POSTUP JEHO DOSAŽENÍ

V kapitole s cílem disertační práce je uveden samotný cíl práce, dále jsou uvedeny postupy k dosažení cíle, vhodné metody pro naplnění navrženého cílového klasifikačního přístupu a vstupní omezení, která ovlivňují navržený klasifikační přístup.

2.1 Formulace cíle disertační práce

Cílem disertační práce je navržení a ověření nového způsobu procesu automatického zpracování dat s velmi vysokým prostorovým rozlišením, nejčastěji pořízených pomocí UAV. V práci bude navrhnout, otestován a zhodnocen model automatické klasifikace obrazových dat, který bude využívat kombinaci řízených klasifikačních metod a bude počítat vážený počet z hodnot klasifikačních tříd ve všech klasifikovaných snímcích v jednotlivých pixelech snímku.

Navržený klasifikační přístup je založen na nedostacích konvenčních klasifikačních metod, kde každá řízená klasifikační metoda dosahuje rozdílných výsledků na rozdílných vstupních datech. Navržený přístup kombinuje výsledky z více metod na vstupu a výstupem je nejlépe klasifikovaný snímek. V navrženém klasifikačním přístupu budou využívány nejvyužívanější řízené klasifikační metody pro obrazová data na vstupu, jako jsou: SVM, Maximum Likelihood, Random Trees a jiné. Navržený klasifikační přístup se bude zaměřovat zejména na využívání geoprocessingových nástrojů v GIS aplikačním prostředí. Potencionální možností je výstupní schéma modelu transformovat na jiný softwarový nástroj pro zpracování obrazových dat jako je např. open source GIS nástroj QGIS nebo interaktivní programové prostředí Matlab a využít tento klasifikační přístup.

Jelikož je navržený klasifikační přístup založen na tradičních neboli konvenčních klasifikačních metodách, tak je i tento termín uveden v označení navrženého klasifikačního přístupu, který se jmenuje: Conventional Multi Classifier Approach (CMCA).

2.2 Dílčí cíle a formulace postupu dosažení cíle disertační práce

Postup k dosažení cíle disertační práce se skládá z naplnění dílčích cílů disertační práce:

1. Shrnutí aktuálního stavu v oblasti automatické klasifikace obrazových dat.,
2. Nalezení vhodných metod využitelných pro automatickou klasifikaci obrazových dat pro potřeby navrženého klasifikačního přístupu CMCA.,
3. Porovnání výpočetní náročnosti navrženého klasifikačního přístupu proti moderním klasifikačním přístupům založených na hlubokém učení.,
4. Aplikování navrženého klasifikačního přístupu CMCA na snímcích z již publikovaných výsledků a ověření přesnosti klasifikace.,
5. Aplikování navrženého klasifikačního přístupu CMCA na nových případových studiích a ověření přesnosti klasifikace.

2.3 Přehled metod vhodných pro dosažení cíle disertační práce a použité vybavení

V rámci dalšího výzkumu bude realizováno vytvoření větší báze obrazových dat, kde budou aplikovány vybrané klasifikační metody, které budou vstupovat do nového přístupu pro klasifikaci CMCA. Báze dat bude tvořena snímky s velmi vysokým prostorovým pořízenými bezpilotními prostředky, a to konkrétně stroji DJI Mavic 3T. DJI M3T disponuje RGB snímačem s maximálním rozlišením až 48 Mpx. Snímání dat bude prováděno pomocí plánovaných letů, kde se sesbírají obrazová data celého území. Z plánovaného letu budou výstupem jednotlivé snímky, které se budou skládat do celistvé mozaiky v nástroji Pix4Dmapper. Plánované lety budou prováděny 25. den (podle povětrnostních podmínek) každý měsíc v identickou denní dobu. Nejvhodnější denní doba je poledne nebo polední blízká doba, kde jsou minimální stíny, kvůli pozici Slunce vůči Zemi, tzv. nadir. Nastavení snímače bude pro každý let identické bez ohledu na aktuální světelné podmínky. Vytvořené mozaiky budou tvořit surovou bázi dat, na které bude zvolena část území, která bude tvořit detailnější oblast zájmu.

Detailnější oblast zájmu je vybrána vzhledem k procesnímu času zpracování dat, resp. klasifikace dat. Po ověření funkčnosti navrženého modelu nového přístupu klasifikace lze tento přístup aplikovat na celé nasnímané území.

Vstupní data jsou tvořena výstupy z konvenčních klasifikačních metod, které dosahují nejlepších výsledků a jsou i nejčastěji využívané, viz kapitola 3.

Zvolené vybrané metody patří mezi nejčastěji využívané řízené klasifikační metody, jak dokládá i výstup ze stávajícího stavu v oblasti disertační práce. Jedná se o metody dostupné z různých nástrojích pro práci s prostorovými daty. Využitá metoda maximální věrohodnosti neboli Maximum Likelihood patří mezi tradiční klasifikační metody, která je známá již dlouhou dobu [104] a dosahuje dobrých výsledků přesností klasifikací. Metoda podpůrných vektorů neboli Support Vector Machine (SVM) je metoda strojového učení s učitelem, která patří mezi modernější tradiční metody a globálně dosahuje dobrých výsledků. Metoda Random Trees je metoda založená na rozhodovacích stromech, která má dobrou úspěšnost správné klasifikace.

Vzniklý model pro nový přístup klasifikace dat bude ohodnocen v hlediska přesnosti stejnou metrikou jako budou ohodnocovány jednotlivé klasifikační metody, a to pomocí celkové přesnosti z matice záměn a Kappa koeficientu.

2.4 Omezení navrženého klasifikačního přístupu

Vzniklý model bude pracovat na základě vstupních dat, která jsou omezena několika kritérii. Jedná se o kritéria omezení vstupního formátu dat, dále omezení spektrálních pásem vstupních snímků a omezení detailu dat formou spektrálního rozlišení.

Omezení vstupních dat je ve spektrálním omezení snímače, kdy se uvažuje klasický snímač snímající v pravých barvách, tedy elektromagnetická pásma R, G, B. Další omezení vstupních dat nebo už složených vstupních dat do mozaiky je ve spektrálním rozlišení, kde je podmínky vysokého až velmi vysokého prostorového rozlišení (méně než 10 cm na pixel).

Další omezení vstupních dat, už pro klasifikační model, je omezení na data rastrová, která jsou vytvářena jako výstupní snímek předešlých klasifikací. Tato data jsou nejčastěji obrazová data ve formátu TIFF, TIF, PNG nebo JPEG.

Vstupní data získávána bezpilotními prostředky klasické konstrukce splňují všechna omezující kritéria. Bezpilotní prostředek klasické konstrukce i z kategorie nízko nákladových dronů jsou vybaveny RGB snímačem, kde formát těchto obrazových dat je nejčastěji JPEG nebo TIFF. Velkým benefitem využívání bezpilotních prostředků je jejich lokální nasazení a tedy i vysoký detail poskytnutých snímků, tedy vysoké až velmi vysoké spektrální rozlišení.

2.5 Motivace

Motivací k navržení klasifikačního přístupu jsou dosavadní požadavky na softwarové vybavení, náročnost na výpočetní výkon i jistá omezení. Mezi další motivace lze zmínit i možnost navržení klasifikačního přístupu pro open source software.

Omezení pro navržený klasifikační přístup CMCA jsou:

- Data s velmi vysokým prostorovým rozlišením v řádech jednotek cm/pixel.,
- Data pouze v RGB pásmu elektromagnetického záření.,
- Využívání konvenčních metod pro klasifikaci dat.,
- Využívání nejběžnějších softwarových nástrojů pro práci s prostorovými daty.,
- Rychlost zpracování dat oproti moderním způsobům.

3 SOUČASNÝ STAV VE SMĚRU DISERTAČNÍ PRÁCE

V provedené hloubkové analýze stávajícího stavu ve směru disertační práce jsou brány potaz příspěvky uvedené ve vědecké databázi Web of Science, kde většina z příspěvků není starší než 8 let.

Zkoumané příspěvky se vždy zaměřují na práci s daty s velmi vysokým prostorovým rozlišením jednotkách cm/pixel. Většina příspěvků disponuje s daty pořízenými bezpilotním prostředkem, je to nejjednodušší způsob, jak získat data s takto vysokým prostorovým rozlišením. Ve vybraných příspěvcích se vždy zpracovávají RGB obrazová data, ale u některých příspěvků jsou s nimi zpracovávána i data v jiných spektrech světla, která jsou využita pro ověření. Vybrané příspěvky využívají tradiční (konvenční) klasifikační metody, a to buď přímo, anebo v porovnání s jinými přístupy klasifikace dat.

Autoři [70] se zaměřili na studie ke klasifikaci cibule a česneku s využitím řízené klasifikace z dat poskytnutými bezpilotním letounem s pevnými křídly (model Ebee). Letecké snímky byly pořízeny 11 až 12krát, ze studijních lokalit v Changryeng-gun a Hapcheon-gun v průběhu zemědělské sezóny v letech 2015 až 2016. Výsledek přesnosti klasifikace snímků cibule a česneku pomocí R-G-B a R-G-NIR snímků ukázaly nejvyšší koeficienty Kappa pro metodu Maximum Likelihood. Dále byly využity pro klasifikace obrazových dat: Mahalanobis Method a Minimum Distance Method. Výsledek pro přesnosti klasifikace cibule a česneku ukázaly vysoké koeficienty Kappa 0,75 až 0,97, zejména pro Maximum Likelihood metodu. Dle jejich závěru lze snímky z UAV použít k odhadu plochy pěstování cibule a česneku. Vstupní data v příspěvku dosahovala prostorového rozlišení 5 cm/px. Klasifikace pouze z RGB kamery dosahovaly výsledků celkové přesnosti v rozmezí 60 až 95 %. Výsledky klasifikace pouze za pomoci Maximum Likelihood dosahovaly celkové přesnosti v rozmezí 72 až 95 %, z dostupných výsledků.

Příspěvek „*Vineyard classification using machine learning techniques applied to RGB-UAV imagery*“ [85] se zaměřuje na RGB obrazová data pořízená pomocí UAV a klasifikace probíhala za pomoci metod strojového učení. Velmi vysoké rozlišení snímků pořízených pomocí UAV byly podrobeny fotogrammetrickému měření a byly zpracovány do ortofotomozaiky s prostorovým rozlišením 1,85 cm/px. Ve studii byly aplikovány i další metody analýzy dat, a to model povrchu plodin a pět vegetačních indexů. Ke klasifikaci byly využity tři techniky strojového učení: podpurný vektorový stroj (SVM), náhodný les (RF) a umělá neuronová síť (ANN). Ve studii probíhala klasifikaci dat do čtyř tříd: vinná réva, stín, půda a ostatní vegetace. Data byla rozdělena na 22 % (n=240, 60 na třídu) pro účely trénování

a 78 % (n = 850) pro účely testování. Výsledky ukázaly, že oba RF i ANN modely vykazovaly dobrou výkonnost 87,76 a 86,12 %, nicméně SVM zde dosáhl výkonnosti přesnosti klasifikace pouze 45,29 %. Měření výkonnosti bylo za využití matice záměn a metody F1-score.

Článek [31] se zaměřuje na klasifikaci druhů stromů založený na obrazových datech RGB s velmi vysokým prostorovým rozlišením získaných pomocí UAV, v oblasti středního Německa. Jejich důvod byl kvůli problémům se současnou automatizovanou detekcí dřevin na základě údajů z pasivního dálkového průzkumu země z leteckých průzkumů. Současná automatizovaná detekce však stále není dostatečně rozvinutá, aby bylo možné dosáhnout spolehlivých výsledků nezávislých na fenologickém stadiu, denní době, ročním období, vitalitě stromů a převládajících atmosférických podmínkách. Autoři představili nový přístup ke klasifikaci druhů stromů založený na obrazových datech RGB s vysokým rozlišením shromážděným během automatizovaných letů UAV, který tyto nedostatky překonává. Pro klasifikační úlohu byla navržena výpočetně lehká konvoluční neuronová síť (CNN). Ukazují, že se zvolenou architekturou modelu CNN lze dosáhnout průměrné přesnosti klasifikace 92 % nezávisle na podmínkách osvětlení a fenologických fázích čtyř různých druhů stromů. Pro jejich studii je potřeba mít minimální hustotu vzorkování země s prostorovým rozlišením 1,6 cm/px, která je potřebná pro klasifikační model, aby mohl využívat prostorově-strukturální informace v datech. K demonstrování použitelnost prezentovaného přístupu k odvození prostorově explicitních informací o dřevinách, byl generován mřížkový produkt, který poskytuje průměrnou přesnost klasifikace 88 %. Autoři využili modernější metody pro klasifikaci obrazových dat, ale pracují pouze s RGB částí spektra a s velmi vysokým prostorovým rozlišením.

Wan a kolektiv [113] uvedli příspěvek zaměřující se na problém odhadu počtu květů v řepce olejce založené na kombinaci vegetačních indexů a klasifikace obrázků získaných pomocí UAV. V této studii bylo použito bezpilotní letadlo (UAV) vybavené Red Green Blue (RGB) a multispektrálními kamerami k získání série snímků pole ve fázi květu. Snímky řepkového pole byly nejprve klasifikovány pomocí metody K-means. Jejich zjištění naznačují, že kombinace spektrálních indexů a klasifikace snímků z RGB a multispektrálních snímků získaných pomocí UAV má potenciál odhadnout počet květů v řepce olejce. Spektrální indexy byly založeny pouze na RGB pásmech, proto lze i tento článek brát jako součást literární rešerše. Metoda K-means autorům dosáhla přesnosti 89 %, která byla stanovena vůči korelaci s pokrytím květů v ploše (FCA). Prostorové rozlišení není v článku uvedeno, ale pomocí výpočtu hodnoty GSD a zmíněných parametrů bylo spočítán odhad hodnoty $GSD = <1$ cm/px.

Článek [121] „Tree species classification using deep learning and RGB optical images obtained by an unmanned aerial vehicle“ se věnuje problematice klasifikace typů stromů za pomoci deep learning klasifikačních metod nad RGB daty získanými pomocí UAV. Podle autorů kombinace metod hlubokého učení a RGB snímků získaných UAV poskytuje nový směr výzkumu pro klasifikaci městských druhů stromů. Autoři navrhli datovou sadu optických snímků RGB s 10 městskými druhy stromů, nazvanou TCC10. Datový soubor TCC10 obsahuje dva typy dat: obrázky korun stromů s jednoduchým pozadím a obrázky se složitým pozadím. Cílem bylo prověřit možnost využití metod hlubokého učení (AlexNet, VGG-16 a ResNet-50) pro klasifikaci jednotlivých dřevin. Z dostupných parametrů byla vypočítána hodnota GSD v rozmezí mezi 0,87 a 1,31 cm/px, protože autory získaná data do datové sady TCC10 byly získávána ve 2 letových hladinách, a to 40 a 60 m. Výsledné snímky s velmi vysokým prostorovým rozlišením byly v RGB pásmech a pro klasifikaci bylo využito 3 modelů deep learning klasifikátorů. Výsledky pomocí deep learning metod dosahovaly celkové přesnosti (OA = overall accuracy) 84,6 % pomocí AlexNet, 87,1 % pomocí VGG-16 a 92,6 % pomocí ResNet-50 pro snímky s jednoduchým pozadím. Celková přesnost pro snímky se složitým pozadím byla 77,2 % pomocí AlexNet, 81,6 % pomocí VGG-16 a 85,4 % pomocí ResNet-50. V tomto článku byly využity moderní přístupy pro klasifikaci RGB obrazových dat, které dosahovali od 77 do 92 % přesnosti klasifikace v závislosti nad složitostí vstupních dat.

Autoři článku [123] se zaměřili na detekci rostlin rýže v rané sezóně. Vstupní obrazová data byla pořízena pomocí UAV, které neslo 3 typy snímačů. Snímače obsahovaly celkem tři senzory, které snímali v RGB, NIR-G-B a multispektrálním pásmu. Podle autorů je detekce plodin životně důležitá pro mapování oblasti výsadby plodin a získávání čistých informací o korunách plodin. V této studii byly získávány snímky vrchlíku rýže v raných růstových stádiích (okrajování, kultivace, fáze spojování a počátečního zavádění). Autoři navrhli nový rozhodovací strom kombinující texturní vlastnosti (střední hodnota a rozptyl) a spektrální vlastnosti pro detekci rostlin rýže v rámci UAV snímků nazvaný TS-DT. Výsledky ukázaly, že TS-DT vykazoval průměrně vysokou přesnost klasifikace s celkovou přesností (OA) a kappa koeficientem (KC) 91,25 %, 0,86 pro RGB obrazová data mezi ranými třemi růstovými fázemi. Autory navržená metoda TS-DT dosáhla ve srovnání s tradičními klasifikačními metodami lepší přesnosti klasifikace. Proto je tato metoda TS-DT spolehlivým přístupem pro detekci plodin pomocí UAV snímků. Autoři porovnávali jimi navrženou metodu s tradičními klasifikačními metodami (dostupnými pro softwarový nástroj ENVI), jmenovitě: Parallelepiped; Minimum Distance, Mahalanobis Distance; Maximum Likelihood; Neural Net; SVM. Vstupní RGB data dosahovala prostorového rozlišení 1,3 cm/px. Použité metody dosahovaly

následujících výsledků hodnot celkové přesnosti: Parallelepiped = 51,16 %; Minimum Distance = 80,81 %, Mahalanobis Distance = 86,19 %; Maximum Likelihood = 85,33 %; Neural Net = 87,43 %; SVM = 86,02 %; TS-DT = 89,05 %. Tento článek se nejvíce přibližuje chtěnému cíli této práce, protože je v něm navržen nový klasifikační přístup nad RGB obrazovými daty s velmi vysokým prostorovým rozlišením. Autory navržený klasifikační přístup je vytvořený ze stávajících metod, konkrétně rozhodovacího stromu.

Průspěvek [120] s názvem „Spatial and Spectral Hybrid Image Classification for Rice Lodging Assessment through UAV Imagery“ se zaměřuje na identifikaci poléhání rýže z důvodu vyšetřování odškodnění. Proto tato studie navrhuje komplexní a účinnou klasifikační techniku pro zemědělskou půdu, která zahrnuje použití snímků z UAV. Ze získaných a zpracovaných dat byly vypočteny hodnoty pravděpodobnosti jednoho znaku (SFP) pro vyhodnocení příspěvku spektrálních a prostorových hybridních obrazových informací k přesnosti klasifikace. Výsledky SFP odhalily, že informace o struktuře byly prospěšné pro klasifikaci rýže a vody. Klasifikace stromů v kombinaci s informací o struktuře a digitálním modelu povrchu byla užitečná při rozlišování mezi umělým povrchem a holou půdou. Kromě toho model klasifikace rozhodovacího stromu zahrnující hodnoty SFP poskytl optimální výsledky s přesností 96,17 % ve srovnání s modelem klasifikace s maximální pravděpodobností (90,76 %). Studie prokázala, že navrhovaná technologie prostorové a spektrální hybridní klasifikace obrazu je slibným nástrojem pro hodnocení poléhání rýže. Vstupní data pořízená bezpilotním prostředkem dosahoval 5,5 cm/px prostorového rozlišení a disponovala RGB pásmy. Autory navržený klasifikátor byl založen na metodě rozhodovacího stromu. Využitá klasická klasifikační metoda maximum likelihood dosahovala přesnosti klasifikace 90,76 %.

Garzon-lopez a Lasso [36] se věnovali identifikaci rostlin v oblasti Páramos. Páramos hostí více než 3500 druhů cévnatých rostlin a je zásadním dodavatelem vody pro miliony lidí v severních Andách. Sledování rozšíření druhů ve velkém měřítku je naléhavou prioritou ochrany vzhledem k probíhajícím klimatickým změnám a rostoucímu antropogennímu tlaku na tento ekosystém. Tato studie poprvé prozkoumávala potenciál obrazových dat v RGB vlnových délkách získaných pomocí UAV v tomto ekosystému. Dále byla získávány i hyperspektrální snímky pro ověření klasifikací druhů na ploše 10 ha v oblasti Páramo. S hyperspektrálními daty testovali schopnost detekovat pět reprezentativních druhů rostlin s různými růstovými formami pomocí klasifikátorů SVM a RF. Jejich závěr byl, že pomocí RGB snímků mohli klasifikovat 21 druhů rostlin s přesností větší než 97 %. Jejich výsledky ukazují, že druhy rostlin lze přesně mapovat pomocí RGB i hyperspektrálních snímků. Vstupní data pořízená bezpilotním prostředkem v RGB spektru dosahovala prostorového rozlišení

1 cm/px. Výsledná přesnost klasifikací pomocí SVM a RF byla minimálně 75 % pro všechny ze 40 druhů rostlin.

Wittstruck a kolektiv [118] se věnovali detekci Hokkaidó dýní a odhadu výnosu z dat pořízených pomocí UAV v RGB spektru. Podle autorů úspěšná komercializace vyžaduje podrobné předsklizňové informace o počtu a hmotnosti plodů. Autoři vyvinuli metodologii zpracování obrazu pro RGB data s vysokým rozlišením pořízených UAV. Metodologii použili na poli v severozápadním Německu, aby mohli získat nedestruktivní a nákladově efektivní odhad výnosu. Metodika byla implementována v programovacím jazyce Python a zahrnovala několik kroků, včetně předběžného zpracování obrazu, klasifikace obrazu na základě pixelů, následného zpracování klasifikace pro detekci jednoho ovoce a kvantifikace velikosti a hmotnosti ovoce. Výsledky odhalily uspokojivou detekci 95 % (chybovost 5 %) z terénního vzorku. Závěr autorů je, že navrhovaný přístup poskytuje producentovi Hokkaido užitečné informace pro cílenější marketingové strategie před sklizní, protože většina maloobchodníků s potravinami požaduje homogenní šarže v předepsaných velikostních nebo hmotnostních třídách. Vstupní data pořízená UAV v RGB spektru dosahovala prostorového rozlišení 1 cm/px. Autoři využili Random Forest klasifikátor (obsahující 500 rozhodovacích stromů) pro pixelovou klasifikaci. Klasifikátor dosáhl celkové přesnosti 94,7 % pro klasifikaci dýní vůči okolí.

„Mapování druhů stromů v mangrovových ekosystémech pomocí UAV-RGB snímků a objektově založené klasifikace snímků“ je v překladu název příspěvku [80], kde se autoři zaměřují na mapování stromů z RGB dat získaných pomocí komerčního UAV. Cílem této studie je identifikovat dva druhy mangrovů pomocí klasifikace založené na objektech. Objektově založená klasifikace (pomocí algoritmu Random Forest) snímků UAV s dominantními mangrovovými rysy dosáhla ve spojení s Canopy Height Model celkové přesnosti 98 %. Třídy vody a země byly identifikovány s přesností 100 %. Přesnost náhodného lesního algoritmu pro oba stromy byla více než 90 %. Výsledky prokázaly potenciál a užitečnost spektrálních dat, tj. ortomosaických odvozených z UAV–RGB, a strukturních dat pro identifikaci mangrovových stromů. Získaná data pomocí UAV dosahovala prostorového rozlišení 2,5 cm/px. Objektová klasifikace pomocí Random Forest pro RGB data dosáhla celkové přesnosti 94 % a pro identifikaci dvou typů stromů dosáhla přesnosti 91, resp. 95 %.

Studie [101] zaměřující se na představení techniky pro spolehlivý a rychlý odhad výnosu cukrové třtiny pro dvě oblíbené odrůdy (KK3 a UT12) v Thajsku, za použití RGB snímků získaných UAV spolu s pozemními informacemi. První výzvou studie bylo rozlišit pixely cukrové třtiny a pixely neobsahující cukrovou třtinu na snímcích. Za tímto účelem byly

zkoumány techniky analýzy obrazu založené na objektech (OBIA) a obrazové analýzy založené na pixelech. Výsledky autorů odhalily, že technika OBIA určila pixely cukrové třtiny s přesností 92 a 96 %, zatímco metoda ExG založená na pixelech měla přesnost 84 a 88 % pro obě odrůdy. Velmi vysoké prostorové rozlišení obrazu UAV a pokročilá klasifikace obrazu OBIA demonstrují významný potenciál pro zemědělce a související průmysly předpovídat výnosy před sklizní. Jak bylo uvedeno v předchozím textu, tak použité objektové a tradiční klasifikační přístupy dosáhli přesnosti minimálně 84 %, resp. pro objektovou klasifikaci minimálně 92 %. Vstupní RGB obrazová data získaná UAV dosahovala prostorového rozlišení 7,59 cm/px, které bylo spočítáno na základě uvedených parametrů letu a kamery.

Článek [81] popisuje použití RGB snímků pořízených z UAV k mapování invazivních rákosů v oblasti mokřadů Crow Island State Game Area v Michiganu. Přesné mapování pomocí snímků z dálkového průzkumu Země, které stále více využívá UAV jako zdroj dat, je klíčem k snahám o kontrolování růstu rostlin. Autoři mapovali rákos obecný (*Phragmites australis*) na zájmové oblasti pomocí RGB snímků z UAV v kombinaci s digitálním povrchovým modelem (DSM). Ke klasifikaci byl využity tradiční klasifikátor maximální věrohodnosti (ML) a dva klasifikační algoritmy strojového učení: podpůrný vektorový stroj (SVM) a neuronová síť (NN). Přesnost byla hodnocena více přístupy. Hodnocení celkové přesnosti dosáhlo následujících hodnot pro jeden snímek: SVM 72 %; MLC 70 %; NN 33 % OA, pro časovou řadu dosáhli následujících přesností: ML 64 %; SVM 71 %; NN 67 %. Tyto výsledky ukazují, že správci mokřadů mohou dosáhnout velmi přijatelné přesnosti mapování pomocí jednoduchých metod, které vyžadují jen málo zdrojů a odborných znalostí. Data pořízená UAV v RGB pásmu dosahovala prostorového rozlišení 5,04 cm/px.

Autoři příspěvku [21] zkoumali kombinaci fotogrammetrie, objektové klasifikace a konvolučních neuronových sítí pro automatizovanou detekci a charakterizaci lavinových nánosů. Podle autorů jsou lavinové aktivity na zasněžených horských svazích jsou velmi časté a stochasticky rozložené v čase a geografickém rozsahu. Běžné způsoby hlášení lavinového výskytu v těchto oblastech jsou neefektivní a neúplné z důvodu nehostinného počasí a nepřístupných topografických podmínek. Tento článek představuje nový způsob pro detekci a analýzu lavinových usazenin pomocí RGB snímků pořízených pomocí UAV. Autoři navrhli způsob detekování pomocí metody OBIA-CNN (Object Based Image Analysis-Convolution Neural Network), která využívala segmentaci obrazu. Klasifikátor založený na CNN byl vytvořen, trénován a ověřen. Lavinová ložiska detekovaná navrženou metodou byla shledána v dobré korelaci s ručně vytyčenými ložisky. Výsledky navržené metody detekce usazenin byly také porovnány s výsledky klasifikace Support Vector Machine (SVM), Random Forest (RF)

a UNET za účelem vyhodnocení výkonnosti metody. Dle autorů bude navržený způsob užitečný pro automatizovanou detekci lavinových ložisek a jejich charakterizaci pro regiony specifického zájmu. Studie naznačuje, že pravidelné monitorování lavinových aktivit pomocí UAV snímků poskytuje dobré řešení pro operativní monitorování důležitých koridorů zasněžených oblastí. Vstupní RGB obrazová data byla získána pomocí UAV a disponovala prostorovým rozlišením 4,88 cm/px. Výsledky klasifikací pomocí konvenčních metod, které byly využity pro ověření přesnosti s autory navrženým modelem, dosahovali následujících celkových přesností: RF 89 %; SVM 84 %. Dále byl autory navržený model ověřen vůči modernější přístupu klasifikování pomocí Deep learning, který s modelem U-NET dosáhl celkové přesnosti klasifikace 84 %.

Závěr na základě uvedené hlubší literární rešerše je dokázáno, že ve vědecké databázi Web of Science lze vyhledat (k datu 6. 6. 2024) pod termínem „image classification" and "RGB" and ("drone" or "UAV" or "uav" or "rpas")“ celkem 63 příspěvků. Uvedená klauzule o bezpilotních prostředcích zahrnuje automaticky, že se v příspěvcích pracuje s daty s vysokým až velmi vysokým prostorovým rozlišením. Většina z vyhledaných příspěvků využívá pro klasifikaci obrazu modernější metody založené na strojovém učení anebo umělé inteligenci. Jen malá část příspěvků se věnuje konvenčním klasifikačním metodám, v některých případech jsou s nimi porovnávány autory navržené klasifikátory.

Z tohoto důvodu lze najít jistou skulinu ve výzkumu nad RGB obrazovými daty s velmi vysokým prostorovým rozlišením. Typicky jsou data s velmi vysokým prostorovým rozlišením pořizována pomocí bezpilotního prostředku, které defacto zaručují pořízení dat s prostorovým rozlišením do 10 cm/pixel. Jelikož se většina příspěvků zaměřuje na modernější klasifikační přístupy, tak lze vidět i možný směr zkoumání ve využívání konvenčních klasifikačních přístupů. Z vlastního výzkumu, včetně autorových publikací, založeného na modernějších klasifikačních metodách založených na hlubokém učení vyplývá, že poskytují velmi dobré výsledky, ale jsou časově a hardwarově daleko náročnější, více v kapitole Výpočetní náročnost.

4 NAVRŽENÝ KLASIFIKAČNÍ PŘÍSTUP CMCA

Z vlastních výsledků výzkumu [57][56][60][67] a zkušeností bylo zjištěno, že pro různá data nedosahují vždy nejlepších výsledků stejné klasifikační metody. Proto vznikla myšlenka kombinace výsledků z různých klasifikačních metod, která by měla poskytnout nejlepší výsledek. V této části jsou shrnuty výsledky vlastních publikací a návrh modelu pro nový klasifikátor.

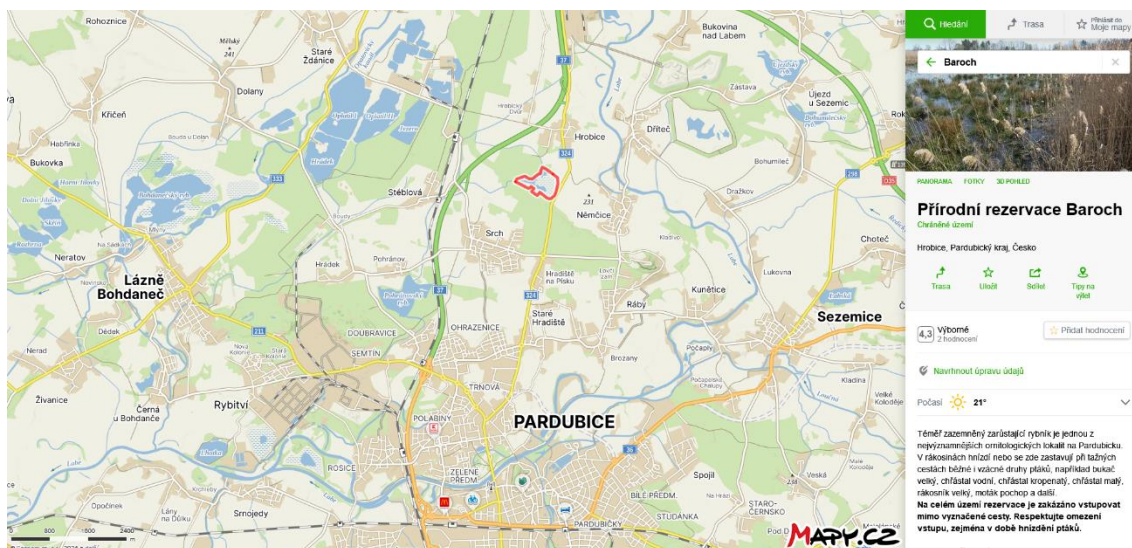
Vlastním směrem výzkumu byla vyzkoušena i klasifikace obrazových dat pomocí hlubokého učení. Tento přístup poskytl velmi dobré výsledky při klasifikaci do dvou tříd (led a ostatní), kde dosahoval přesnosti přes 92 %, změřené pomocí Kappa koeficientu [56]. Ačkoliv tento přístup dosahuje velmi dobrých výsledků, tak je zapotřebí výkonný hardware i správný software. A i při splnění požadavků na hardware je celý proces časově náročný, zejména s porovnáním při využití klasických metod. I z tohoto důvodu je nový klasifikační přístup zaměřen na využití stávající (starší) technologie, ale v novém pojetí.

4.1 Použitá data, prostředky, metody a SW

Vstupní data jsou tvořena vlastním sběrem obrazových dat získaných pomocí bezpilotního prostředku DJI Mavic 2 Enterprise DUAL a DJI Mavic 3T. Bepilotní prostředky snímají data na základě plánovaného letu vytvořeného pomocí aplikací Pix4Dcapture (v1.2.0) a DJI Pilot 2 (v2). Pomocí bezpilotních prostředků je snímáno území přírodní rezervace Baroch, viz Obrázek 15, které se nachází nedaleko Univerzity Pardubice. Lety se provádí každý měsíc, vždy kolem 25. dne (podle povětrnostních podmínek) a kolem poledne, kvůli minimalizaci stínů z vyšších objektů.

Zpracování dat probíhá za výkonném laptopu vybaveným 8 jádrovým procesorem (16 vláken) o základním taktu 3,2 GHz; 40 GB operační paměti, GPU RTX3060 8 GB; SSD disky. Zpracování dat do celistvého snímku probíhá za využití softwarového nástroje Pix4Dmapper (v4.8.4), který umožňuje výpočty i na grafické kartě. Následné analýzy, digitalizace a klasifikace probíhají v GIS nástrojích ArcGIS PRO (v3.1) a ArcMAP (v10.8.2).

Mezi použité metody se řadí metody pro klasifikaci obrazových dat, které jsou nejvyužívanější z kategorie řízených klasifikačních metod. Jedná se o nejčastěji využívané metody i z palety nástrojů v ArcGIS PRO a jedná se o metody: Maximum Likelihood; Support Vector Machine (SVM); Random Trees a Deep Learning.

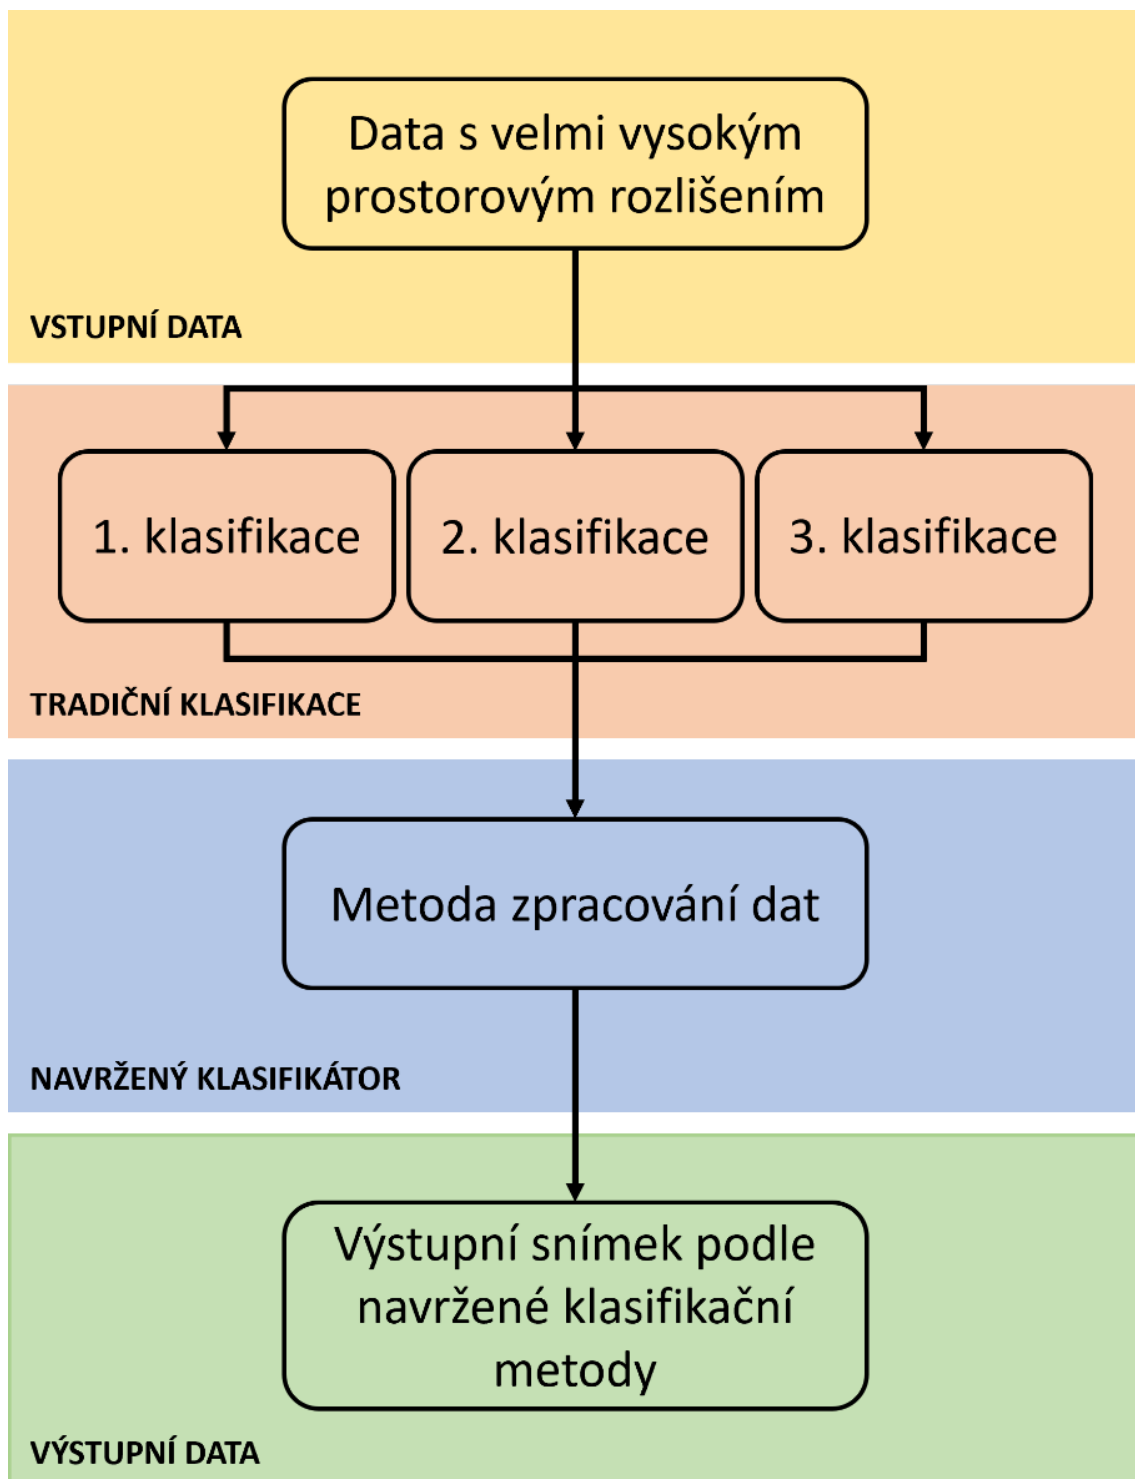


Obrázek 15: Pozice PR Baroch

Zdroj: [78]

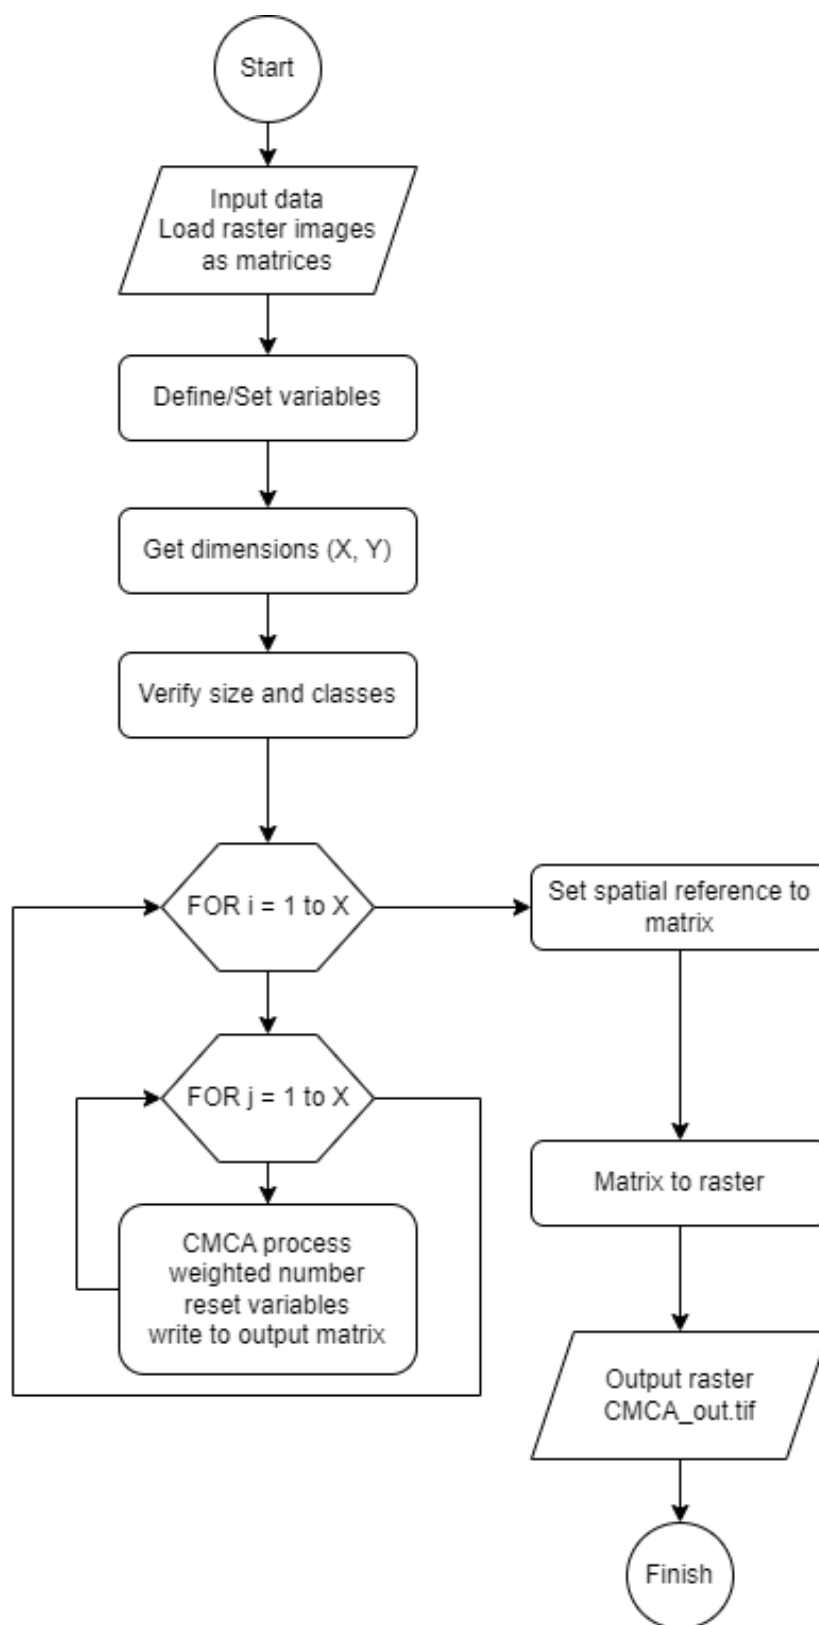
4.2 Navržený model zpracování dat pomocí automatické klasifikace

V navrženém modelu automatické klasifikace jsou po získání RGB obrazových dat, aplikovány (vybrané) konvenční metody pro klasifikaci obrazových dat. Poté následuje přečtení výsledků klasifikací z předchozího kroku, dále se nastavují parametry pro další zpracování. Tyto parametry jsou tvořeny: počet tříd; počet pixelů horizontálně; počet pixelů vertikálně; počet snímků na vstupu. V následující kroku se načte DN daného pixelu ve všech snímcích a vytváří se vážený počet, který je zároveň výstupní hodnotou nového klasifikátoru. Tento princip je blokově znázorněn pomocí Obrázek 16. Obrázek 17 znázorňuje schéma vývojové diagramu navrženého klasifikačního přístupu CMCA. Obrázek 18 a Obrázek 19 znázorňují funkční model pro CMCA klasifikaci přímo v prostředí ArcGIS PRO. Zdrojový kód scriptu navrženého klasifikačního přístupu je v příloze této práce.



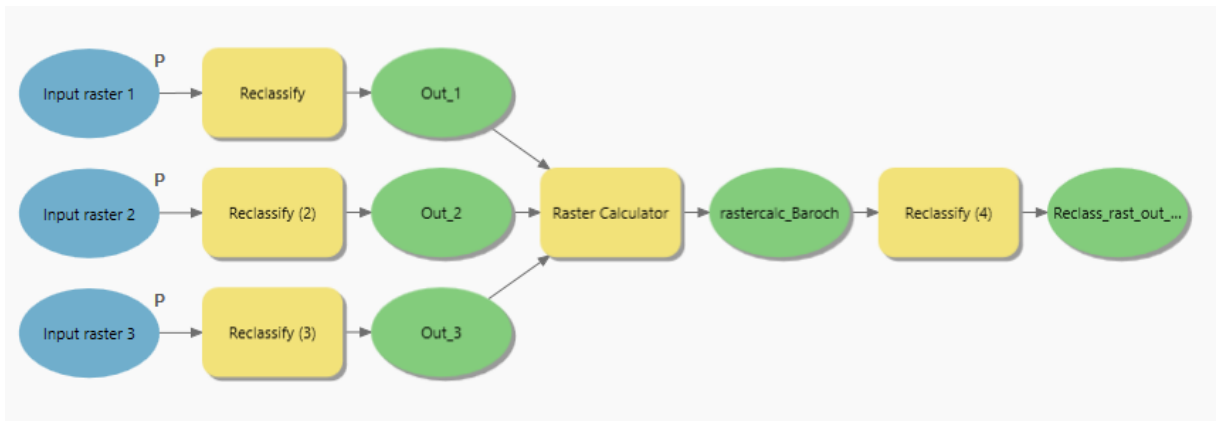
Obrázek 16: Procesní diagram celého procesu zpracování dat včetně pomocí navrženého přístupu

Zdroj: [vlastní zpracování]




Obrázek 17: Vývojový diagram navrženého klasifikačního přístupu CMCA (verze 1)

Zdroj: [vlastní zpracování]



Obrázek 18: Navržený funkční model v nástroji ESRI ModelBuilder (verze 2)

Zdroj: [vlastní zpracování]



Obrázek 19: Navržený funkční CMCA přístup (verze2)

Zdroj: [vlastní zpracování]

4.1 Zdrojový kód CMCA přístupu – maticová ukázka

Navržený zdrojový kód navrženého klasifikačního přístupu CMCA je v příloze této práce. V této kapitole je uveden zdrojový kód navrženého klasifikačního přístupu CMCA ve verzi se vstupními maticemi čísel (náhodně generovaných) pro potřeby ukázky nebo vyzkoušení bez potřeby vstupních rastrových snímků. Tato verze CMCA je univerzální skrze různé softwarové nástroje pro práci s prostorovými daty. Navržená verze převádí vstupní klasifikované rastrové snímky do matice čísel, následně provede výpočetní operace klasifikačního přístupu CMCA a v posledním kroku uloží výslednou matici do rastrového snímku.

```
import numpy as np
import rasterio
from rasterio.transform import from_origin

# Vstupní proměnné
pole = [0] * 3 #3 je omezení CMCA na 3 klasifikační třídy
print(pole)

# Generování předpokládané matice hodnot (pro ilustrační účely)
SIZE = 10
matrix1 = np.random.randint(0, 2, size=(SIZE, SIZE), dtype=np.uint8) #
Matice s náhodnými hodnotami 0-2
matrix2 = np.random.randint(0, 2, size=(SIZE, SIZE), dtype=np.uint8) #
Matice s náhodnými hodnotami 0-2
matrix3 = np.random.randint(0, 2, size=(SIZE, SIZE), dtype=np.uint8) #
Matice s náhodnými hodnotami 0-2
matrix = np.random.randint(0, 1, size=(SIZE, SIZE), dtype=np.uint8) #
Matice výstupní s vypočtenými hodnotami

#unikátní DN
unique_values1 = np.unique(matrix1)
print("Unikátní hodnoty v matici:")
print(unique_values1)

# Zjištění počtu řádků
pocet_radku = len(matrix)
# Zjištění počtu sloupců (předpokládáme, že matice není prázdná a všechny
řádky mají stejnou délku)
pocet_sloupcu = len(matrix[0]) if pocet_radku > 0 else 0
print(f"Velikost rastru je {pocet_radku} x {pocet_sloupcu} pixelů")
print()

#VYPOCETNI OPERACE
# Cyklus for od 1 do X
for x in range(0, pocet_radku + 1):
    # Cyklus for od 1 do Y
    for y in range(0, pocet_sloupcu + 1):
        hodnota1 = matrix1[x-1][y-1]
        hodnota2 = matrix2[x-1][y-1]
        hodnota3 = matrix3[x-1][y-1]
        #prvek = hodnota1 + hodnota2 + hodnota3

#CMCA přístup omezen na 3 třídy klasifikace
```

```

    if hodnota1 == 0:
        pole[0] += 1
    elif hodnota1 == 1:
        pole[1] += 1
    else:
        pole[2] += 1

    if hodnota2 == 0:
        pole[0] += 1
    elif hodnota2 == 1:
        pole[1] += 1
    else:
        pole[2] += 1

    if hodnota3 == 0:
        pole[0] += 1
    elif hodnota3 == 1:
        pole[1] += 1
    else:
        pole[2] += 1

    if pole[0] == pole [1] == pole[2]:
        # Získání náhodné hodnoty z pole
        prvek = random.choice(pole)
    else:
        # Získání maximální hodnoty v poli
        max_hodnota = max(pole)
        # Získání pozice (indexu) maximální hodnoty v poli
        prvek = pole.index(max_hodnota)

    #print(prvek, end=' ') #výpis matice
    matrix[x-1][y-1] = prvek
    pole = [0] * 3

print()
# Vypsání matice bez závorek a do řádků
for radek in matrix:
    print(*radek)

# Specifikace parametrů rastrového snímku
height, width = matrix.shape
count = 1 # Počet pásem (bands)
#dtype = matrix.dtype
dtype = np.uint8

# Definice transformace a metadat
transform = from_origin(0, width, 1, 1)
crs = 'EPSG:4326' # Příklad souřadnicového systému (WGS84)

# Uložení matice do rastrového snímku
with rasterio.open(
    'output_raster.tif',
    'w',
    driver='GTiff',
    height=height,
    width=width,
    count=count,
    dtype=dtype,
    crs=crs,
    transform=transform,
) as dst:

```

```

dst.write(matrix, 1) # Zapisujeme data z matice do prvního pásma (bandu)

print()
print("Rastrový snímek byl úspěšně uložen.") crs = 'EPSG:4326' # Příklad
souřadnicového systému (WGS84)

# Uložení matice do rastrového snímku
with rasterio.open(
    'CMCAoutput.tif',
    'w',
    driver='GTiff',
    height=pocet_radku,
    width=pocet_sloupcu,
    count=count,
    dtype=dtype,
    crs=crs,
    transform=transform,
) as dst:
    dst.write(matice_out, 1) # Zapisujeme data z matice do prvního pásma

print("Rastrový snímek byl úspěšně uložen.")

```

4.2 Identifikace typů povrchů na základě vlastních dat a výsledků jejich zpracování

Tato kapitola shrnuje výsledky získané v rámci prvních studií realizovaných autorem a poukazuje na zjištěné nedostatky při využívání tradičních metod pro zpracování dat.


Současný způsob klasifikace obrazových dat je pomocí řízených a neřízených klasifikačních metod. Neřízené klasifikační metody jsou metody učení bez učitele a obecně se dá říct, že dosahují horších výsledků než metody řízené klasifikace. Toto tvrzení nemusí platit vždy, v některých případech může neřízená klasifikace dosahovat lepších výsledků. Mezi nejpoužívanější neřízené metody patří Iso Cluster a K-means. Řízené klasifikační metody jsou založeny na učení s učitelem a je k nim potřeba uživatelská interakce. Jelikož je potřeba uživatelské interakce (učitel), která označuje výstupní data (polygony) do tzv. trénovací množiny, tak je díky tomuto kroku větší šance na správné zařazení rozhodovaného prvku (pixelu) do dané třídy. Mezi nejpoužívanější řízené klasifikační metody se řadí Maximum Likelihood, Support Vector Machine (SVM) a Random Trees, popř. hluboké učení (Deep Learning).

Podle současného způsobu klasifikace obrazových dat na základě vlastního zpracování a publikování vychází následující. V článku [55] *Utilization of UAV-Borne RGB Data for Monitoring Horses: Comparison of Classification Methods* (CISTI, 2023) bylo porovnáno několik přístupů pro monitorování koní v oblastech blízkosti vodních ploch. Monitorování neboli klasifikace snímku byla prováděna na RGB snímcích pořízených z dronu. Pro klasifikaci bylo využito několik přístupů: maximum likelihood, random trees, SVM, K-NN. Všechny klasifikační přístupy byly klasifikovány pomocí objektového i pixelového přístupu. Klasifikace byla prováděna na 2 snímcích, kde první byl zúžený na oblast v blízkosti koní a druhý byl na celistvé ploše. Byla vytvořena referenční šablona pomocí manuální identifikace, vůči které se za pomoci Kappa koeficientu určovaly přesnosti klasifikací. V prvním případě nejlepších výsledků dosahovala metody SVM s přesností klasifikace téměř 74 % a v druhém případě to byla metoda random trees, která dosahovala přesnosti téměř 35 %. Tyto hodnoty jsou nižší z důvodu omezení vstupních snímků na pásmo RGB, kde se berou jen DN pixelů v pravých barvách, a tedy hnědé koně se jeví stejně jako např. holá půda.

V příspěvku [60] *Land Cover Change Detection Near Small Water Bodies Based On RGB UAV Data: Case Study Of The Pond Baroch, Czech Republic* (ISPRS, 2022) byly porovnávány výsledky klasifikací různých řízeným klasifikačních metod (maximum likelihood, SVM) včetně metody Deep Learning. Analýzy byly prováděny na území v blízkosti vodní plochy

v 5 časových horizontech (srpen, září, říjen, listopad a prosinec) a bylo klasifikováno celkem do 5 tříd, pokrývající pokryv zemní plochy ve všech časových horizontech. Pro ověření správnosti klasifikace byla vytvořena referenční data pomocí manuální identifikace a přesnost byla ověřována pomocí Kappa koeficientu. Nejlepších výsledků byla pro každý měsíc dosahováno jinou metodou. Nejvyšší hodnota přesnosti klasifikace pro metodu maximum likelihood byla 55 %, pro metodu SVM 56 % a pro Deep Learning 74 %. Nižší hodnoty přesnosti klasifikace souvisely s heterogenitou povrchu a s velmi vysokým rozlišením vstupních snímků. Velmi vysoké rozlišení hraje roli při klasifikaci a vzniká velký počet frakcí klasifikovaných tříd v jiných třídách, viz

Obrázek 20. Pro vyhlazení lze využít filtrů, v tomto případě byla naznačeno využití Majority filtru, kde až po 12-ti násobném využití filtru byla data trochu očištěna, viz Obrázek 21. Zpracování dat a veškeré analýzy byly prováděny v softwarovém nástroji ArcGIS PRO (verze 2.9.2)



Obrázek 20: Výstupní klasifikace na snímku s velmi vysokých prostorovým rozlišením

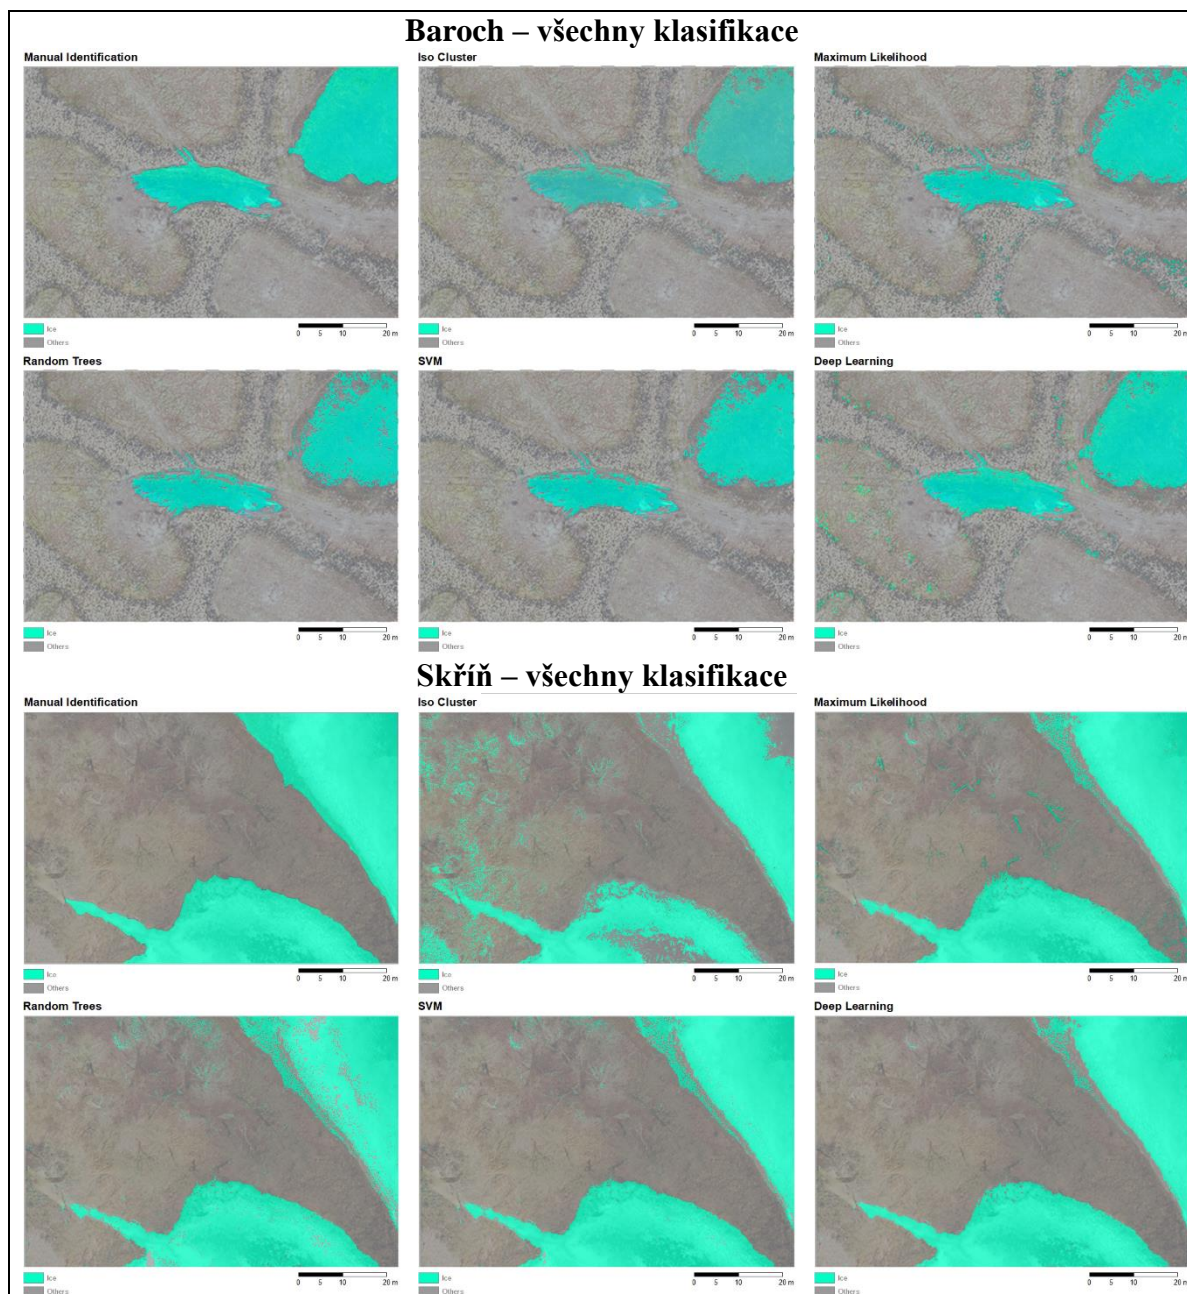
Zdroj: [60]



Obrázek 21: Použití Majority filtru (12×)

Zdroj: [60]

V publikaci *Comparison of automatic classification methods for identification of ice surfaces from UAV-borne RGB imagery* [56] byla použita klasifikace do dvou tříd (led a ostatní). Klasifikace obrazových dat probíhala na území v blízkosti vody, kde se vyskytoval led, holá půda a uschlá vegetace. Jednalo se dvě lokality (Baroch a Skříň), kde se porovnávaly přesnosti vybraných klasifikačních metod. Na Obrázek 22 jsou vidět výstupy klasifikace ledu vůči okolí a Tabulka 7 zobrazuje výsledky přesností klasifikací vypočítaných pomocí Kappa koeficientu. Na prvním území dosáhla nejlepšího výsledku metoda Deep Learning s hodnotou 92,12 % a na druhém území metoda Maximum Likelihood s hodnotou 93,12 %.



Obrázek 22: Přehled všech klasifikací na dvou územích

Zdroj: [56]

Tabulka 7: Přehled přesností klasifikací z článku [56]

METHOD	Pond Skříň	Pond Baroch
Manual identification – reference data	1	1
Iso Cluster	0,6946	0,8842
Maximum Likelihood	0,8464	0,9312
Random Trees	0,8175	0,9175
Support Vector Machine	0,8940	0,9225
Deep Learning	0,9212	0,8889

Zdroj: [56]

4.3 Výpočetní náročnost

Tato kapitola se zaměřuje na porovnání klasifikace dat pomocí konvenčních a moderních klasifikátorů z pohledu doby zpracování a náročnosti na výkon nebo hardware obecně.

Výpočetní náročnost pro konvenční a moderní přístupy klasifikace byla otestována na klasifikaci RGB obrazových dat s velmi vysokým prostorovým rozlišením. Zkoumaná oblast rybník Skříň, viz Obrázek 23, byla nasnímána pomocí bezpilotního prostředku a bylo potřeba klasifikovat vybranou zájmovou oblast do 3 kategorií, jmenovitě: voda, břeh a vegetace.



Obrázek 23: Zkoumaná oblast – rybník Skříň

Zdroj: [vlastní zpracování]

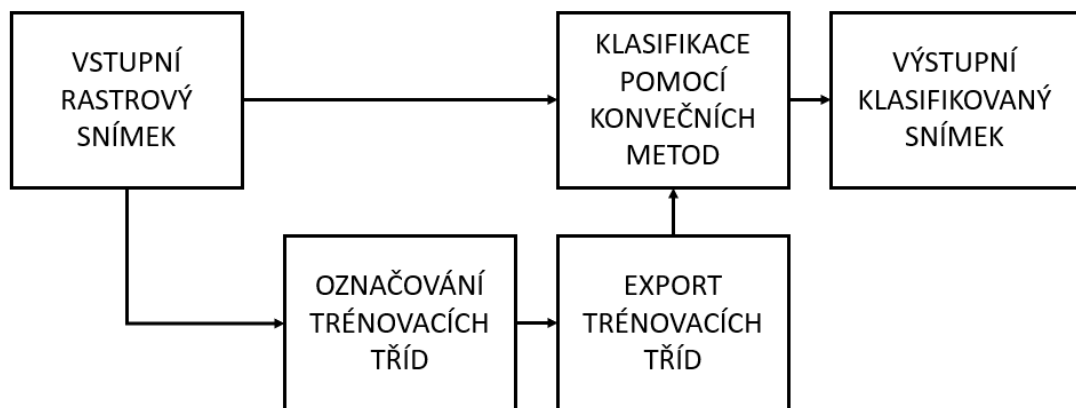
K zpracování dat, tedy i ke klasifikaci, byl využit GIS nástroj ArcGIS PRO (verze 3.2.2) ve verzi Advanced s rozšiřujícími balíčky. Jeden z rozšiřujících balíčků, Image Analyst, umožňuje klasifikace pomocí hluboké učení. Pro porovnání náročnosti na výpočetní výkon byly zvoleny řízené konvenční klasifikační metody, konkrétně: Maximum Likelihood; Support Vector Machine, Random Trees a metody hluboké učení (Deep Learning). Pro všechny klasifikační metody bylo potřeba označit na vstupních datech klasifikované třídy pomocí zakreslování polygonů do jednotlivých tříd. Takto zakreslené polygony reprezentují trénovací množiny/vzorky (Train Sample), které napřímo vstupují do konvenčních metod a pro deep learning vstupují do trénování modelu. U konvenčních klasifikačních metod se po zakreslení trénovacích polygonů přistoupí k samotné klasifikaci nad vstupním rastrovým snímkem. U metod hlubokého učení je nejdřív potřeba transformovat označené trénovací polygony

pomocí funkce Export Training Data For Deep Learning do formátu zpracovatelného hlubokým učením, které následně vstupují do trénování modelu. Pro trénování modelu se využívá funkce Train Deep Learning Model, u které lze parametrizovat požadavky na model. Mezi základní parametry patří typ model, který se využije (klasifikace, detekce, orientace na pixely nebo objekty), maximální počet epoch a další. Po natrénování modelu lze využít natrénovaný model ke klasifikace vstupního rastru.

Veškeré klasifikace byly prováděna na notebooku s následující hardwarovou konfigurací, u které je uvedena i grafická jednotka, protože ArcGIS PRO umožňuje využít výpočty na grafické jednotce zejména pro trénování modelu deep learning.

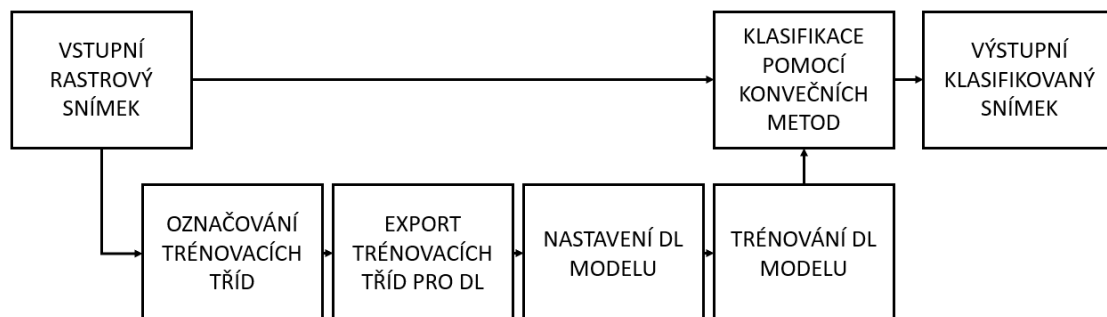
- Procesor AMD Ryzen 5800H, 8 jádrový, 16 vláknový, 3,2 GHz základní takt
- Operační paměť DDR4, 48 GB, Rychlost 3200 MHz
- Pevný disk NVMe SSD
- GPU Nvidia RTX 3070 Laptop, 8 GB

Celé procesy klasifikačních metod konvenčních i deep learning jsou znázorněny pomocí procesní schémat na Obrázek 24 a Obrázek 25.



Obrázek 24: Proces klasifikace pomocí konvenčních metod

Zdroj: [vlastní zpracování]



Obrázek 25: Proces klasifikace pomocí deep learning metod

Zdroj: [vlastní zpracování]

Porovnávané doby jednotlivých fází (samotného klasifikačního procesu) jsou uvedeny v Tabulka 8. Z tabulky je jednoznačně vidět, že proces hlubokého učení je několásobně časově náročnější. Pokud by se bralo v potaz i ekonomické zhodnocení, tak je určitě i z hlediska financí na výpočetní strojový čas (náklady na elektřinu) daleko nákladnější zpracovávat data pomocí hlubokého učení. Tento trend nárůstu spotřeby energie bude do budoucna potřeba řídit [2],

což by mohlo vést k jistému úpadku využívání těchto metod.

Tabulka 8: Porovnání dob výpočetní náročnosti

Klasifikační fáze	Konvenční metody	Deep Learning
Označování trénovacích polygonů	Doba zpracování daná rychlostí uživatele	Doba zpracování daná rychlostí uživatele
Exportování trénovacích dat	10 s	14 m 14 s
Trénování modelu	---	1 h 7 m 14 s (U-NET)
Klasifikace	ML 5 s RT 20 s SVM 13 s	U-NET 23 m 8 s

Zdroj: [vlastní zpracování]

Z výše uvedeného textu jasně vyplývá, že proces klasifikace pomocí hlubokého učení je časově i strojově a hardwarově daleko více náročný, než je proces využívající konvenčních klasifikačních metod.

4.4 Ověření navrženého klasifikačního přístupu CMCA

Tato kapitola shrnuje výsledky 2 studií, při kterých byl CMCA ověřen na reálných datech.

4.4.1 Multimediální nástroje

Případová studie [69] publikovaná na konferenci CISTI 2023 zkoumala vybrané multimediální nástroje jako nástroj pro porovnání změn v krajině. Studie byla založena na porovnání výsledků využívajících různých klasifikačních metod z různých nástrojů na zpracování prostorových dat. Vstupní data byla snímána bezpilotním prostředkem DJI Phantom 3 Professional a pomocí softwaru pro plánování a provádění automatického letu. Mozaika vytvořená ze vstupních dat disponuje velmi vysokým prostorovým rozlišením 2 cm/px. Vybrané klasifikační nástroje byly aplikovány na 4 časové záznamy od srpna do listopadu, kde na těchto snímcích byla identifikovaná voda, holá půda a vegetace. Pro zpracování dat byly využity 3 softwarové nástroje pro práci s geografickými daty, a to ENVI, ArcMAP a ArcGIS PRO.

Testovanou část nasnímaného území tvořila část rybníku s výběžkem, viz Obrázek 26. Obrázek 27 až Obrázek 30 znázorňují výstupy publikované v příspěvku a Obrázek 31 znázorňuje výstup pomocí metody CMCA z jednoho z vybraných časových záznamů.

Na této případové studii byl porovnán výstup z klasifikačního přístupu CMCA proti třem výstupním klasifikacím z nástroje ENVI, kdy i tyto výstupy z ENVI vstupovali do CMCA. Toto porovnání má za úkol ukázat možnosti různorodého vstupu do přístupu CMCA. Ačkoliv je CMCA primárně zaměřen jako nadstavba ArcGIS PRO, tak zvládne bez problému zpracovávat i data z jiných softwarových nástrojů. To poukazuje na univerzálnost mezi GIS nástroji.


Tabulka 9 zobrazuje dosažené výsledky pomocí vybraných klasifikačních přístupů.

Tabulka 9: Porovnání výsledků klasifikací (případová studie Multimediální nástroje)

Klasifikační metoda	Celková přesnost	Kappa
Minimal Distance	64,10 %	42,34 %
Mahalanobis Distance	83,16 %	71,22 %
Max Likelihood	87,15 %	78,53 %
CMCA	85,60 %	75,68 %

Zdroj: [vlastní zpracování]


RGB DATA



Obrázek 26: Rybník Skříň, testovací část, ze studie na CISTI 2023

Zdroj: [vlastní zpracování]


REFERENČNÍ DATA



Obrázek 27: Referenční data CISTI 2023

Zdroj: [vlastní zpracování]


MINIMAL DISTANCE



Obrázek 28: Minimal distance CISTI 2023

Zdroj: [vlastní zpracování]


MAHALANOBIS DISTANCE



Obrázek 29: Mahalanobis distance CISTI 2023

Zdroj: [vlastní zpracování]


MAXIMUM LIKELIHOOD



Obrázek 30: Maximum likelihood CISTI 2023

Zdroj: [vlastní zpracování]

CMCA



Obrázek 31: CMCA metoda CISTI 2023

Zdroj: [vlastní zpracování]

4.4.2 Identifikace koní

Článek [55] pojednává o identifikaci koní v přírodním prostředí na RGB obrazových datech získaných pomocí UAV. Článek popisuje využití dat RGB z dálkového snímání k podpoře monitorování koní v přirozeném prostředí na vyžádání. Data jsou snímána pomocí bezpilotního letounu. Snímání je omezeno pouze povětrnostními podmínkami a právními předpisy. Článek poskytuje srovnání několika pixelových a objektových klasifikačních metod, jmenovitě Maximum Likelihood, Random Trees, SVM a K-NN. Jako referenční metoda se využila ruční identifikace. Vstupní data získaná pomocí bezpilotního prostředku DJI Mavic 2 DUAL poskytovala ve výsledné mozaice prostorové rozlišení 2,18 cm/px.

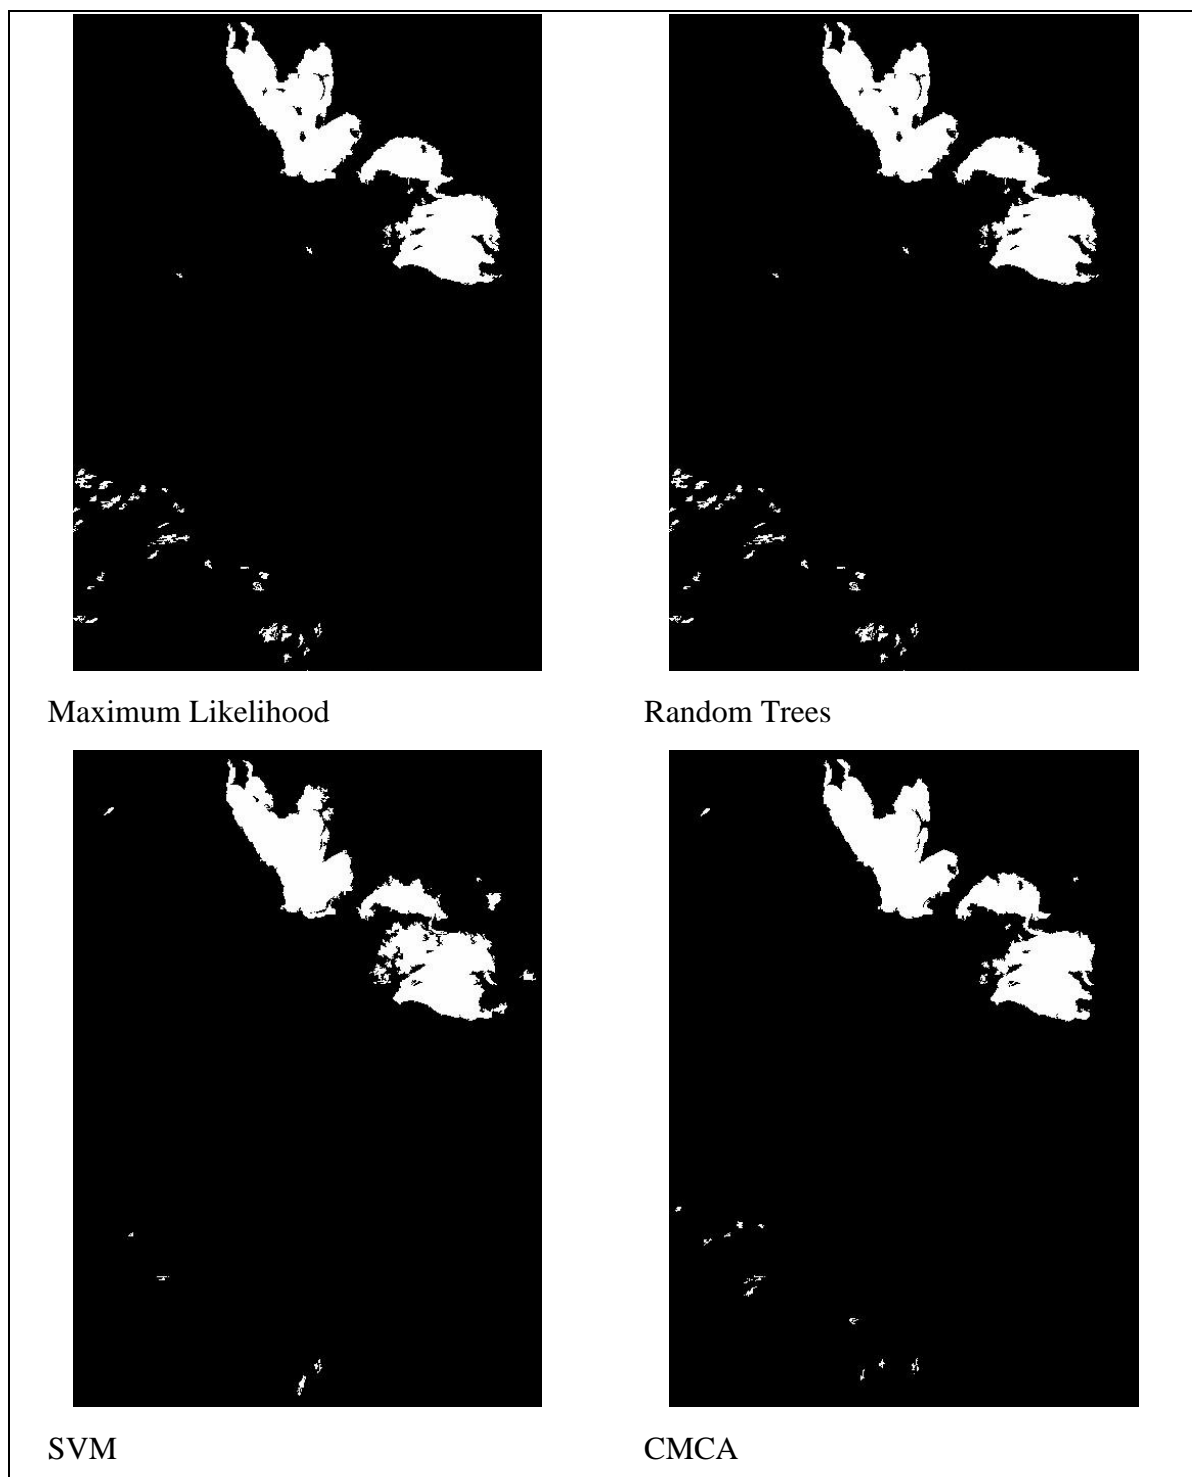
Na vstupních datech tohoto článku byl aplikován navržený klasifikační přístup (CMCA). Jelikož je CMCA metoda založena na 3 vstupních datových vrstvách, ve verzi 2, tak byly zvoleny pouze výsledky z klasifikací Random trees, Maximum Likelihood a SVM na vstupu. Dosažené výsledky klasifikací pomocí CMCA byly porovnány s dosaženými publikovanými výsledky, jak na trénovacím území (TRÚ), tak i celé vstupní mozaice neboli na testovacích datech (TEÚ). Jelikož se jednalo o data s velmi vysokým prostorovým rozlišením, tak bylo potřeba vygenerovat větší počet bodů (konkrétně 5000 a 8000) pro ověření přesností všech výsledků. Dosažené výsledky celkových přesností klasifikací a kappa koeficientů využitých metod na obou množinách jsou uvedeny v Tabulka 10.

Tabulka 10: Porovnání výsledků klasifikací (koně)

Klasifikační metoda	Celková přesnost	Kappa
ML TRÚ	97,96 %	63,41 %
RT TRÚ	98,00 %	61,18 %
SVM TRÚ	98,54 %	70,44 %
CMCA TRÚ	98,54 %	66,34 %
ML TEÚ	89,14 %	1,78 %
RT TEÚ	99,01 %	14,86 %
SVM TEÚ	98,44 %	7,19 %
CMCA TEÚ	98,15 %	8,42 %

Zdroj: [vlastní zpracování]

Z uvedených výsledků porovnání celkových přesností klasifikací a kappa koeficientu je vidět, že navržený klasifikační přístup CMCA dosahuje druhých nejlepších výsledků. Ale pokud se porovnájí výsledky vizuálně, viz Obrázek 32, tak lze vidět značný rozdíl u navržené klasifikačního přístupu při porovnání s klasifikátory, zejména při porovnání s výsledky klasifikací pomocí Maximum Likelihood a Random Trees.



Obrázek 32: Přehled vizuálních výsledků případové studie

Zdroj: [vlastní zpracování]

5 APLIKACE CMCA PŘÍSTUPU – PŘÍPADOVÉ STUDIE

5.1 Případová studie: Identifikace vody

Článek [konference ZINC 2024, čeká za zveřejnění sborníku] se zaměřuje na problematiku algoritmů hlubokého učení pro možnosti monitorování životního prostředí, např. vyhledávání a řízení vodních ploch z dat pořízených bezpilotními prostředky. Tato studie si klade za cíl využít tyto pokroky pro přesnou identifikaci typů povrchů se specifickým zaměřením na vodní útvary v obrazových datech RGB. Pomocí datového souboru složeného z leteckých snímků, pořízených bezpilotním prostředkem nad rybníkem Baroch v přírodní rezervaci, je tato studie srovnávací k vyhodnocení výkonnosti modelů hlubokého učení, včetně U-Net, Pyramid Scene Parsing Network (PSPNet) a DeepLabV3 v klasifikaci typů povrchů. Přesnost klasifikace je u většiny algoritmů hlubokého učení mírně přes 90 %. Tyto výsledky ukazují potenciál hlubokého učení v této oblasti. A to je klíčové pro řadu zainteresovaných stran, například státní správu, vodohospodáře, zemědělce či cestovní ruch.

Z publikovaných výsledků bylo provedeno nové porovnání celkové přesnosti včetně Kappa koeficientů, jelikož se jedná o data s velmi vysokým prostorovým rozlišením, tak bylo potřeba přesnost otestovat na více vygenerovaných bodem. Tabulka 11 zobrazuje dosažené výsledky použitých modelů hlubokého učení v porovnání s dosaženými výsledky pomocí navrženého klasifikátoru.


Tabulka 11: Porovnání výsledků klasifikací (identifikace vody)

Klasifikační metoda	Celková přesnost	Kappa
DL U-Net	93,35 %	85,26 %
DL PSPNet	94,13 %	87,08 %
DL DLv3	94,13 %	87,08 %
CMCA	94,60 %	88,13 %

Zdroj: [vlastní zpracování]


Na výsledcích z této případové studie bylo prokázáno, že ač je navržený model postaven zejména na konvenčních klasifikačních metodách, tak pokud má na vstupu data i z jiných klasifikačních metod, v tomto případě deep learning, tak dokáže spolehlivě pracovat i s jiným vstupem. Navíc v tomto případě dosáhl navržený klasifikační přístup CMCA lepších výsledků

než publikované metody. Na Obrázek 33 až Obrázek 36 je vidět výřez z části zájmového území v oblasti jednoho z ostrovů v přírodní rezervaci Baroch, kde je zřetelně vidět, že klasifikace pomocí navrženého přístupu CMCA eliminuje fragmenty ať už chybějící nebo přebývající na snímcích s velmi vysokým prostorovým rozlišením oproti snímkům klasifikovanými pomocí deep learning.




Obrázek 33: Výsledná klasifikace pomocí DL, model U-Net

Zdroj: [vlastní zpracování]



Obrázek 34 - Výsledná klasifikace pomocí DL, model PSPNet

Zdroj: [vlastní zpracování]



Obrázek 35: Výsledná klasifikace pomocí DL, model DLv3

Zdroj: [vlastní zpracování]



Obrázek 36: Výsledná klasifikace pomocí CMCA

Zdroj: [vlastní zpracování]


5.2 Případová studie: Monitoring koní

Případová studie (článek ve stavu odeslaný k 13. 6. 2024) pojednává o zpracování dat na území v blízkosti zaplavovacích ploch pro potřeby monitorování stavu území. Pro potřeby monitorování je nezbytné identifikovat objekty na obrazových datech, v tomto případě pasoucí se koně. Vstupní snímky, viz Obrázek 37, jsou pořízeny bezpilotním prostředkem DJI Mavic 3T, který poskytuje velmi detailní data a díky tomu disponuje výsledná mozaika celého snímaného území velmi vysokým prostorovým rozlišením, konkrétně 1,7 cm/px. V této studii byly porovnány a zhodnoceny výsledky poskytnuté pomocí konvenčních klasifikačních metod a modernějších metod na bázi hlubokého učení, viz Obrázek 38 až Obrázek 43. Tyto použité metody nahrávají k využití navrženého klasifikačního přístupu CMCA, viz Obrázek 44, který byl s dosaženými klasifikacemi porovnán pomocí celkové přesnosti a pomocí Kappa koeficientu. Tabulka 12 zobrazuje porovnání výsledků celkových přesností a Kappa koeficientů.




Obrázek 37: Vstupní snímek

Zdroj: [vlastní zpracování]




Obrázek 38: Referenční data

Zdroj: [vlastní zpracování]




Obrázek 39: Výsledek klasifikace pomocí metody ML

Zdroj: [vlastní zpracování]




Obrázek 40: Výsledek klasifikace pomocí metody RT

Zdroj: [vlastní zpracování]




Obrázek 41: Výsledek klasifikace pomocí metody SVM

Zdroj: [vlastní zpracování]




Obrázek 42: Výsledek klasifikace pomocí metody DL U-Net

Zdroj: [vlastní zpracování]



Obrázek 43: Výsledek klasifikace pomocí metody DL DLv3

Zdroj: [vlastní zpracování]



Obrázek 44: Výsledek klasifikace pomocí metody CMCA

Zdroj: [vlastní zpracování]

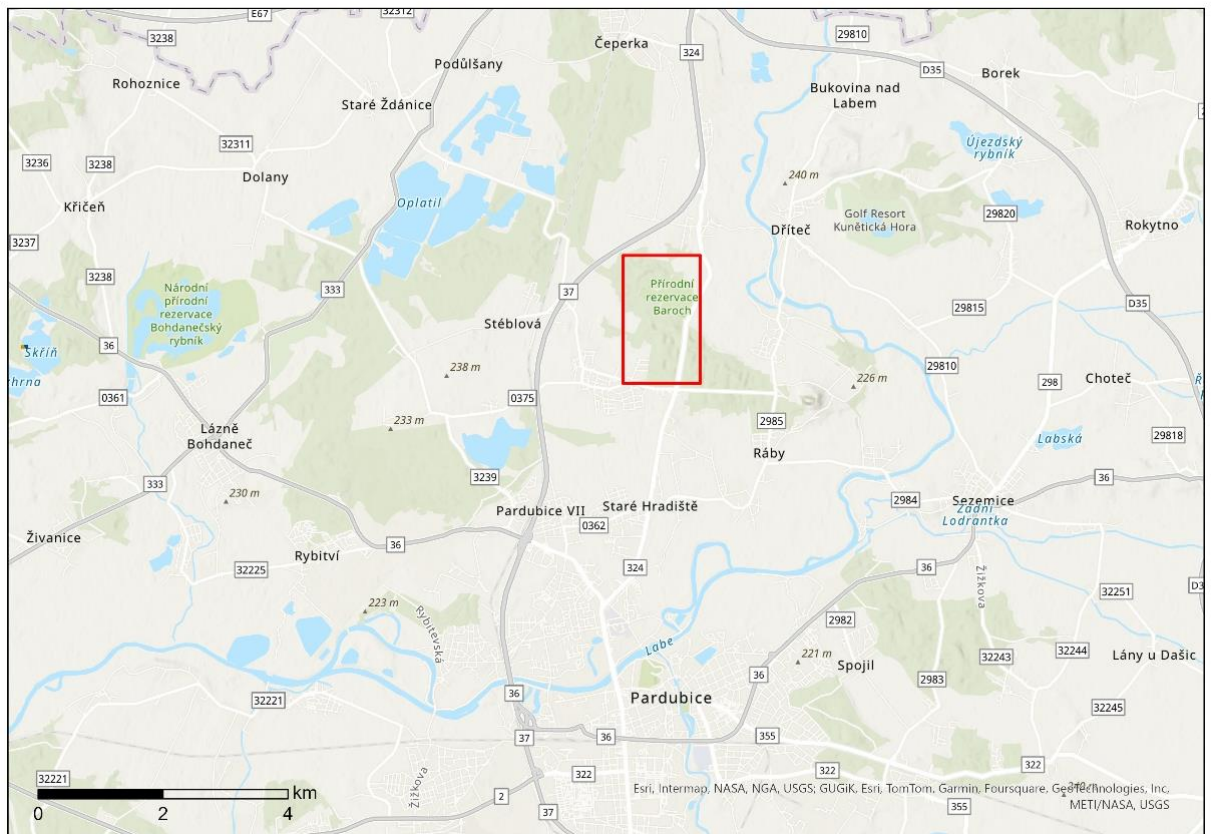
Tabulka 12: Porovnání výsledků klasifikací (Monitoring koní)

Klasifikační metoda	Celková přesnost	Kappa
DL DLv3	98,25 %	10,04 %
SVM	98,50 %	6,03 %
DL U-Net	99,10 %	18,00 %
RT	99,40 %	14,10 %
ML	99,45 %	15,21 %
CMCA	99,60 %	19,84 %

Zdroj: [vlastní zpracování]

5.3 Případová studie: Typy pokryvu – přírodní rezervace Baroch

Případová studie (podklad pro článek, který se bude publikovat na konci roku 2024) pojednává o zpracování dat na území v blízkosti zaplavovacích ploch pro potřeby monitorování stavu území. Zkoumaná oblast přírodní rezervace Baroch je zbytek velkého středověkého rybníku Baroch, která se nachází nedaleko Pardubic, viz Obrázek 45. Od roku 1998 je s přilehlými rákosinami a slatinnými loukami chráněn jako přírodní rezervace o výměře něco přes 30 ha. Území je chráněno především kvůli vzácnému ptactvu a i rostlinstvu, především slatinných luk. Na území rezervace se nacházejí volné vodní plochy s bohatým výskytem vodních makrofyt, rozsáhlé rákosiny, tvořené především rákosem (*Phragmites australis*), mokřadní vrby a bezkolencové a slatinné louky. Území je obklopeno převážně kulturním lesem [13]. Z těchto, ale i dalších důvodů je potřeba mít detailně analyzované území pro potřeby sledování krajiny a potřeby práce s vodním managementem.



Obrázek 45: Pozice přírodní rezervace Baroch

Zdroj: [vlastní zpracování]

Kvůli potřebě detailního zkoumání oblasti byly vstupní data nasnímána ve vybrané zájmové části pomocí bezpilotního prostředku, viz Obrázek 46. Následně byla vstupní data zpracována do výstupní mozaiky, viz Obrázek 47, který disponuje prostorovým rozlišením 2,1 cm/px.

Pro potřeby zkoumání oblasti byly využity GIS nástroje, konkrétně řízené klasifikace obrazových dat. Pomocí klasifikace obrazových dat bylo potřeba identifikovat typy pokrytí povrchu, a to konkrétně do 3 kategorií – voda, vegetace, holá půda.

Ze vstupních dat byl zvolen výřez z části mozaiky, který tvořil trénovací množinu a následné ověření bylo provedeno na celé mozaice neboli testovací množině. Na výřezu, Obrázek 48, byly vybrány vzorky reprezentující požadované klasifikované třídy, s převážně rovnoměrným zastoupením. Po výběru byly vzorky vyexportovány, kde následný export slouží jako vstup pro konvenční klasifikační metody, a i jako vstup pro trénování modelu deep learning klasifikátoru. Na zvoleném vzorku byla udělána manuální identifikace pro potřeby ověření přesnosti jednotlivých klasifikačních metod.

Ze skupiny konvenčních klasifikačních metod byly vybrány klasifikátory: Maximum Likelihood, Random Trees a SVM. Pro deep learning byl vytrénován model založený na modelovém typu U-net. V neposlední řadě byl aplikován autorem navržený CMCA (conventional multi classifier approach) klasifikační přístup ve verzi 2 (model v modelbuilderu), který měl na vstupu výstupní data z použitých konvenčních klasifikátorů.



Obrázek 46: DJI Mavic 3T


Zdroj: [vlastní zpracování]



Obrázek 47: Vybraná zkoumaná část PR Baroch


Zdroj: [vlastní zpracování]

Obrázek 48 znázorňuje výřez ze vstupních dat (mozaiky pořízené UAV) přírodní rezervace Baroch. Referenční data vytvořené pomocí manuální identifikace jsou vidět na Obrázek 49. Na Obrázek 50 až Obrázek 54 jsou vidět výsledky z jednotlivých klasifikátorů. Graf na Obrázek 55 znázorňuje výřez v rozsahu 85 až 90 % z výsledků celkových přesností použitých klasifikátorů.




Obrázek 48: Výběr ze vstupních dat Barochu

Zdroj: [vlastní zpracování]




Obrázek 49: Výsledek pomocí manuální identifikace

Zdroj: [vlastní zpracování]




Obrázek 50: Výsledek klasifikace pomocí metody Maximum Likelihood

Zdroj: [vlastní zpracování]




Obrázek 51: Výsledek klasifikace pomocí metody Random Trees

Zdroj: [vlastní zpracování]




Obrázek 52: Výsledek klasifikace pomocí metody SVM

Zdroj: [vlastní zpracování]




Obrázek 53: Výsledek klasifikace pomocí metody Deep Learning

Zdroj: [vlastní zpracování]



Obrázek 54: Výsledek klasifikace pomocí metody CMCA

Zdroj: [vlastní zpracování]




Obrázek 55: Graf s výsledky celkových přesností klasifikací (rozmezí 85–90 %)

Zdroj: [vlastní zpracování]

Po otestování na výběru (trénovací množina) z nasnímané celé lokality Baroch bylo provedeno klasifikování nad celým územím (testovací množina). Klasifikování bylo provedeno nad stejnými trénovacími množinami s tím, že u procesu hlubokého učení už nebylo potřeba učit model, ale rovnou se mohl aplikovat jako konvenční klasifikátory.

Pro potřeby ověření celkové přesnosti klasifikátorů byla provedena manuální identifikace nad celým územím. Výsledky jednotlivých klasifikačních metod jsou znázorněny na Obrázek 58 až Obrázek 62 a Tabulka 13 zobrazuje dosažené výsledky celkových přesností vypočtených vůči manuální identifikaci. Pro potřeby porovnání výpočetní náročnosti byly také do Tabulka 13 zapsány doby zpracování pomocí jednotlivých klasifikátorů. Doba zpracování se zaměřuje pouze na doby klasifikování, tedy není zohledněno trénování nebo výběr vzorků.



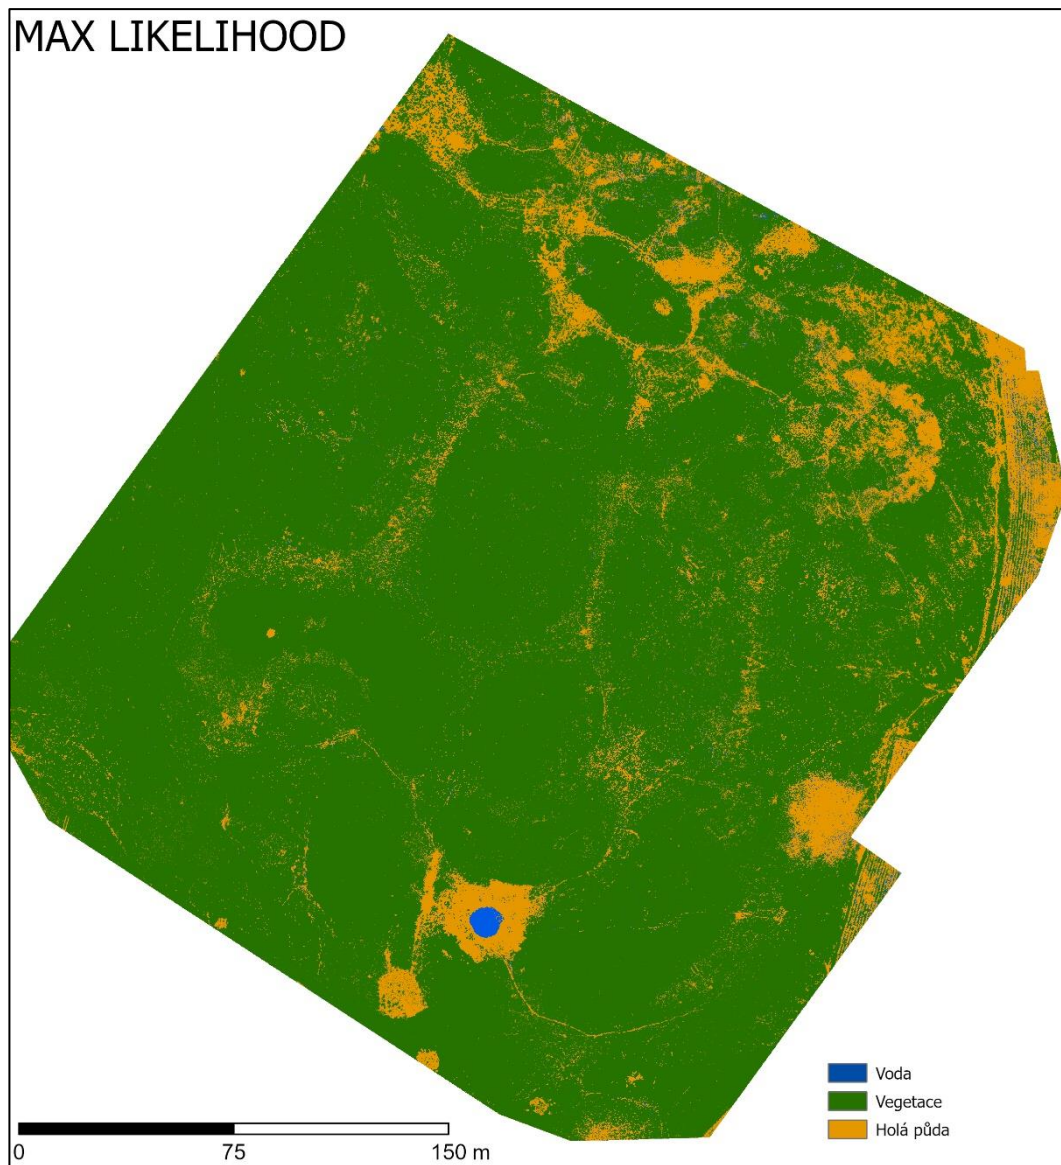
Obrázek 56: RGB vstupní snímek z nasnímaného celého území Barochu

Zdroj: [vlastní zpracování]




Obrázek 57: Referenční data celé zájmové oblasti Baroch

Zdroj: [vlastní zpracování]




Obrázek 58: Klasifikace Maximum Likelihood nad celou zájmovou oblastí

Zdroj: [vlastní zpracování]



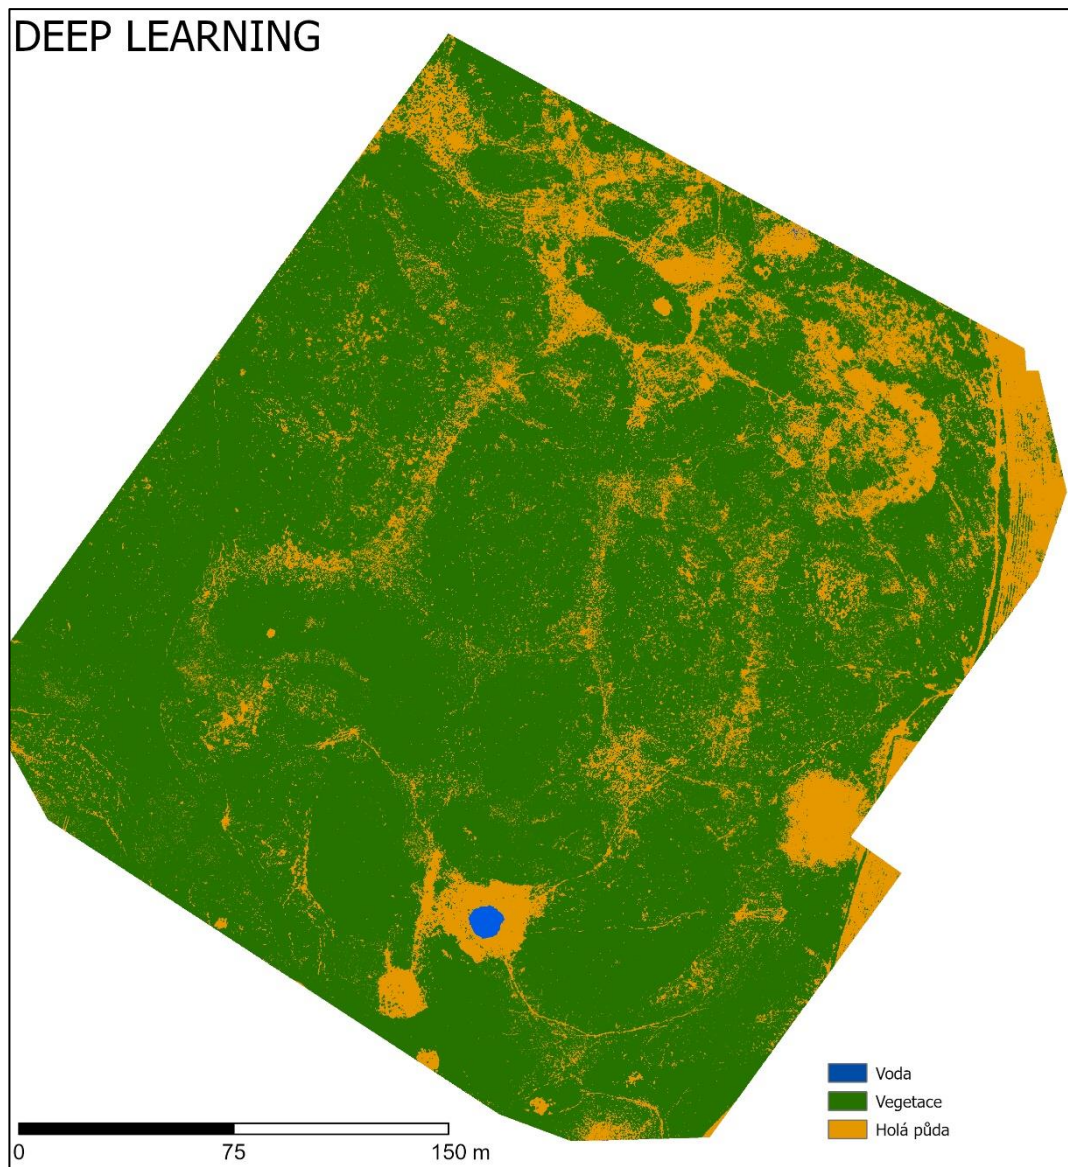
Obrázek 59: Klasifikace Random Trees nad celou zájmovou oblastí

Zdroj: [vlastní zpracování]



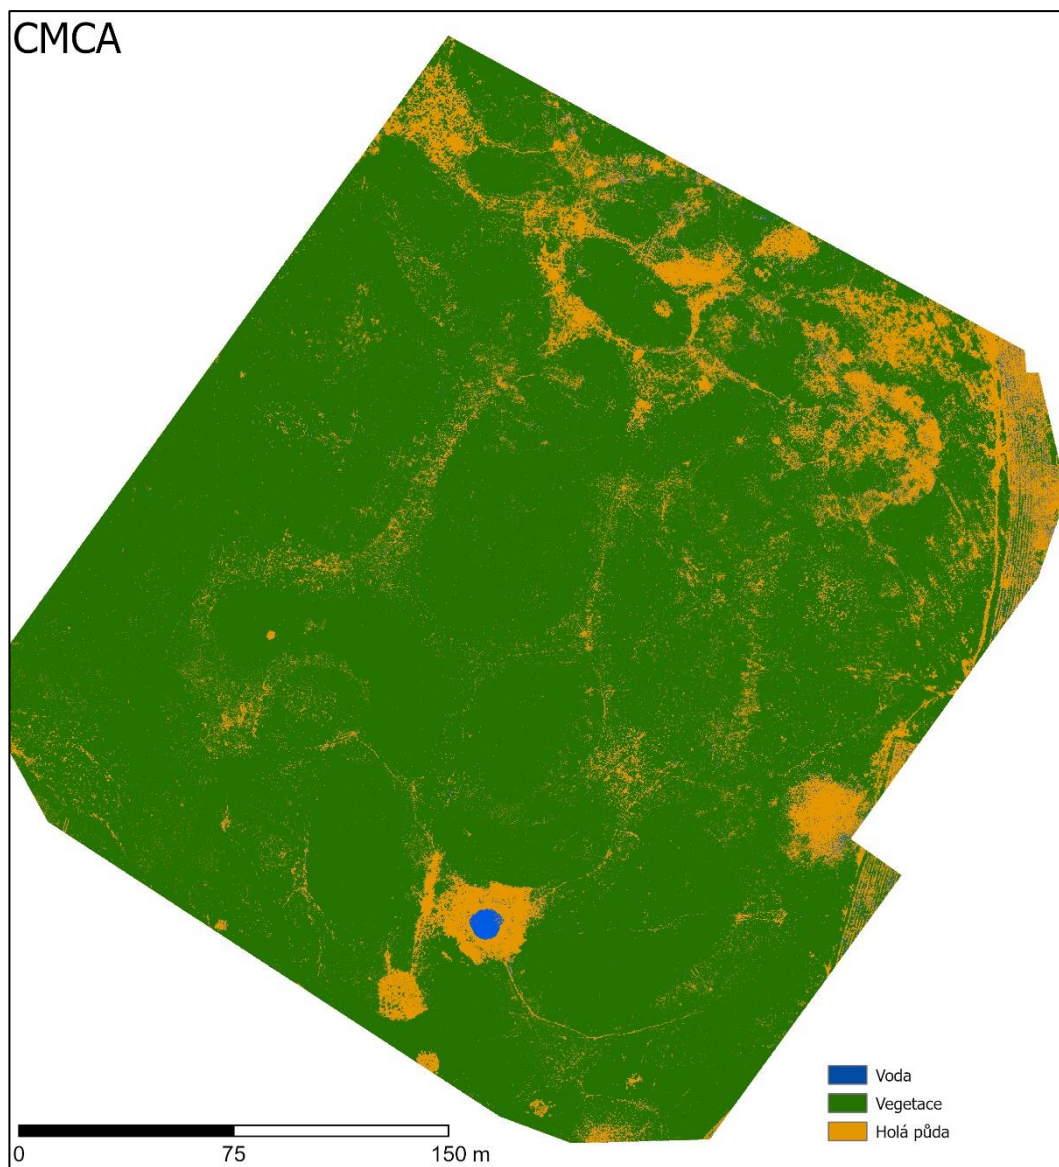
Obrázek 60: Klasifikace SVM nad celou zájmovou oblastí

Zdroj: [vlastní zpracování]



Obrázek 61: Klasifikace Deep Learning (U-Net) nad celou zájmovou oblastí

Zdroj: [vlastní zpracování]



Obrázek 62: Klasifikace CMCA nad celou zájmovou oblastí

Zdroj: [vlastní zpracování]

Tabulka 13: Přesnosti jednotlivých klasifikátorů na celém území včetně doby zpracování

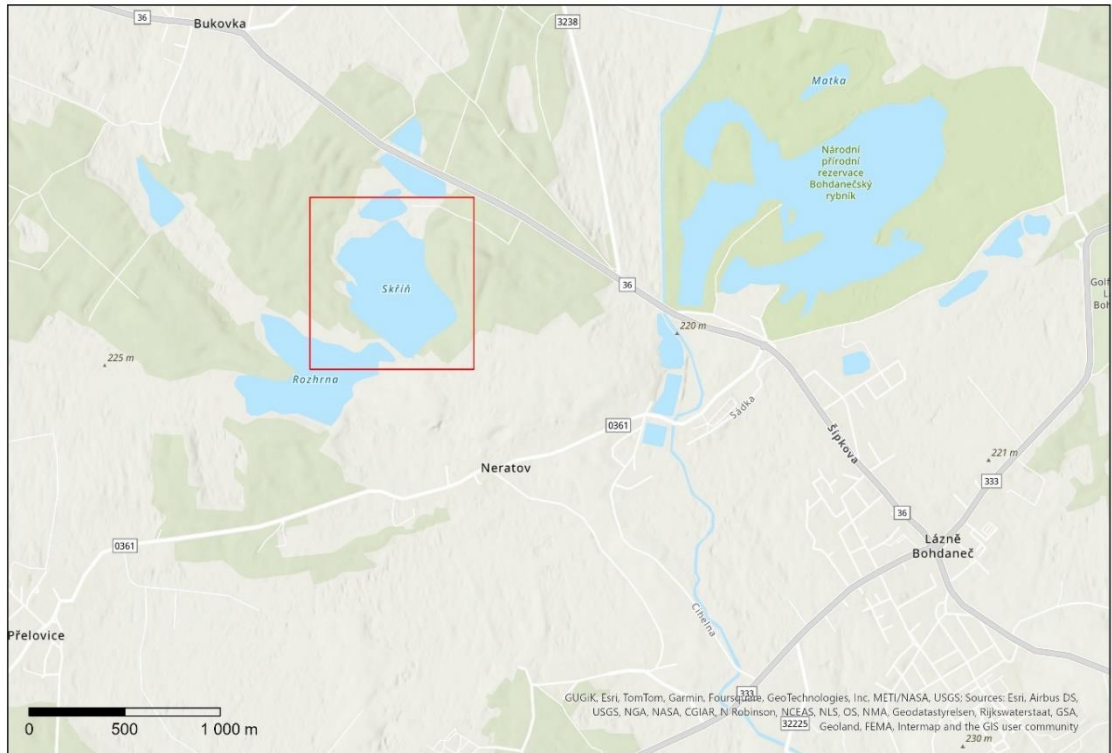
Klasifikační metoda	Celková přesnost	Kappa	Doba zpracování
RT	80,22 %	18,92 %	1 m 24 s
DL (U-Net)	84,36 %	24,88 %	10 h 52 m 45 s
SVM	88,98 %	30,41 %	1 m 6 s
CMCA	89,04 %	31,98 %	59,33 s
ML	89,95 %	33,48 %	26 s

Zdroj: [vlastní zpracování]

5.4 Případová studie: Identifikace malých vodních ploch – rybník Skříň


Kapitola pojednává o zpracování dat na území v blízkosti malých vodních ploch typu rybník v letním období. Zkoumaná oblast Skříň byla nasnímana bezpilotním prostředkem typu DJI Phantom 3, který poskytuje kvalitní data a zároveň spadá do kategorie nízko nákladových UAV. Sledování změn nebo monitorování obecně je velmi důležité pro jakoukoliv aplikaci, zejména ve sledování změny vegetace nebo vodního managementu je nutné rychle a precizně tyto změny sledovat. Bepilotní prostředky, zejména klasické bezpilotní prostředky spadající do kategorie nízko nákladových, se jeví jako zajímavý zdroj poskytovatele dat, jelikož je jejich nasazení okamžité, vzhledem k povětrnostním podmínkám a legislativě. Do této kategorie spadají jakékoliv bezpilotní prostředky největšího výrobce DJI do částky 50 tisíc korun. V této studii byl využit jako poskytovatel dat bezpilotní prostředek DJI Phantom 3 Professional disponující vestavěným RGB snímačem v rozlišení 12 Mpx [24]. Spojení tohoto typu bezpilotního prostředku se softwarem pro plánování letu poskytuje ideální volbu pro pravidelné snímání lokalit kolem malých vodních děl. Zájmová oblast rybníku Skříň byla vybrána pro výzkum sledování změny stavu vegetace po celý rok, kdy byla data pořizovány v podobné dny v každém měsíci a za podobných světelných podmínek.

Zájmové území rybníku Skříň se nachází nedaleko města Lázně Bohdaneč, viz Obrázek 63, a bylo za pomoci bezpilotního prostředku s plánovaným letem snímáno v jeho západní části. Bepilotní prostředek poskytuje dostatečně kvalitní data, a proto i výsledný celistvý snímek (mozaika) disponuje prostorovým rozlišením 2 cm/px. Na vybraném časovém záznamu, Obrázek 64, z nasbíraných dat byly aplikovány tradiční klasifikační přístupy, které byly následně porovnány s výsledky z navrženého klasifikačního přístupu CMCA. Výsledky jednotlivých využitých metody jsou znázorněny na Obrázek 65 až Obrázek 70. Shrnutí celkových přesností jednotlivých klasifikací a jejich potřebných časů na klasifikování je v Tabulka 14. Z dosažených výsledků lze konstatovat, že navržený klasifikační přístup CMCA dosahuje nejlepších výsledků na poli konvenčních klasifikačních metod a proti metodě hlubokého učení (model U-Net) zaostává jen o kousek, ale pokud se vezme v potaz doba zpracování, tak má navržený přístup CMCA velkou výhodu proti době zpracování pomocí deep learning.




Obrázek 63: Lokalizace rybníku Skříň

Zdroj: [vlastní zpracování]




Obrázek 64: Výřez z nasnímaných dat rybníku Skříň

Zdroj: [vlastní zpracování]




Obrázek 65: Manuální identifikace typů pokryvu povrchu (referenční data)

Zdroj: [vlastní zpracování]



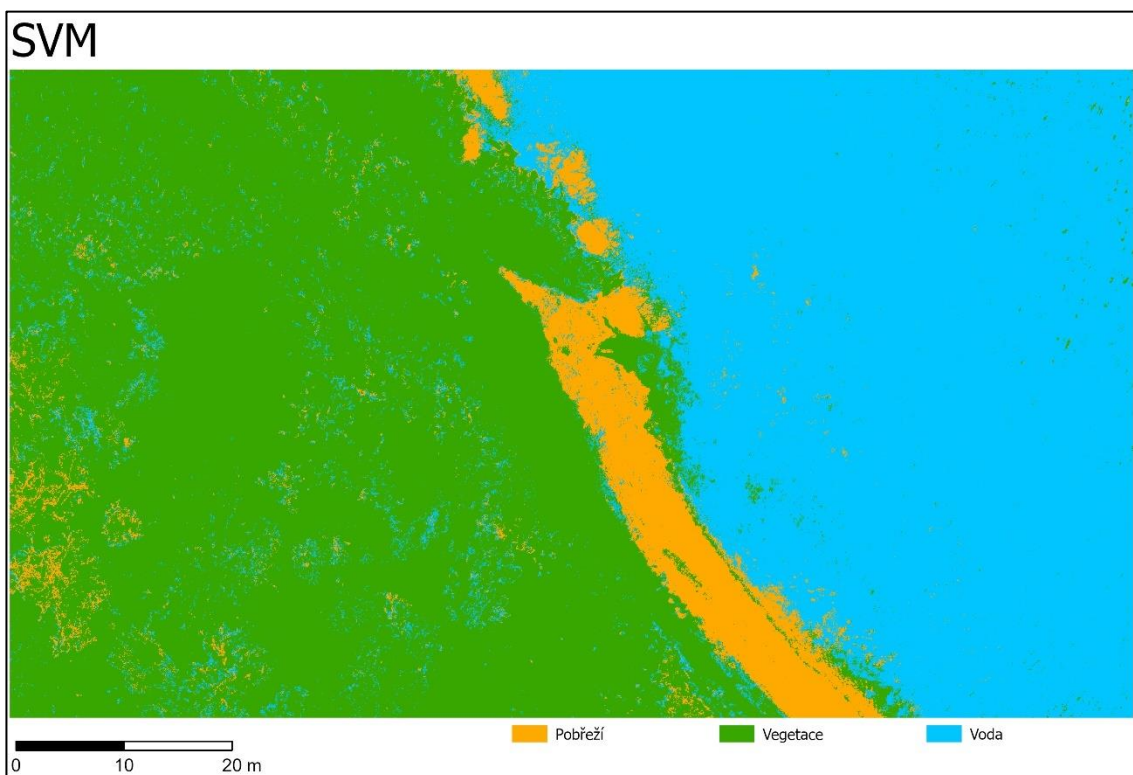
Obrázek 66: Klasifikace rybníku Skříň pomocí metody Maximum Likelihood

Zdroj: [vlastní zpracování]



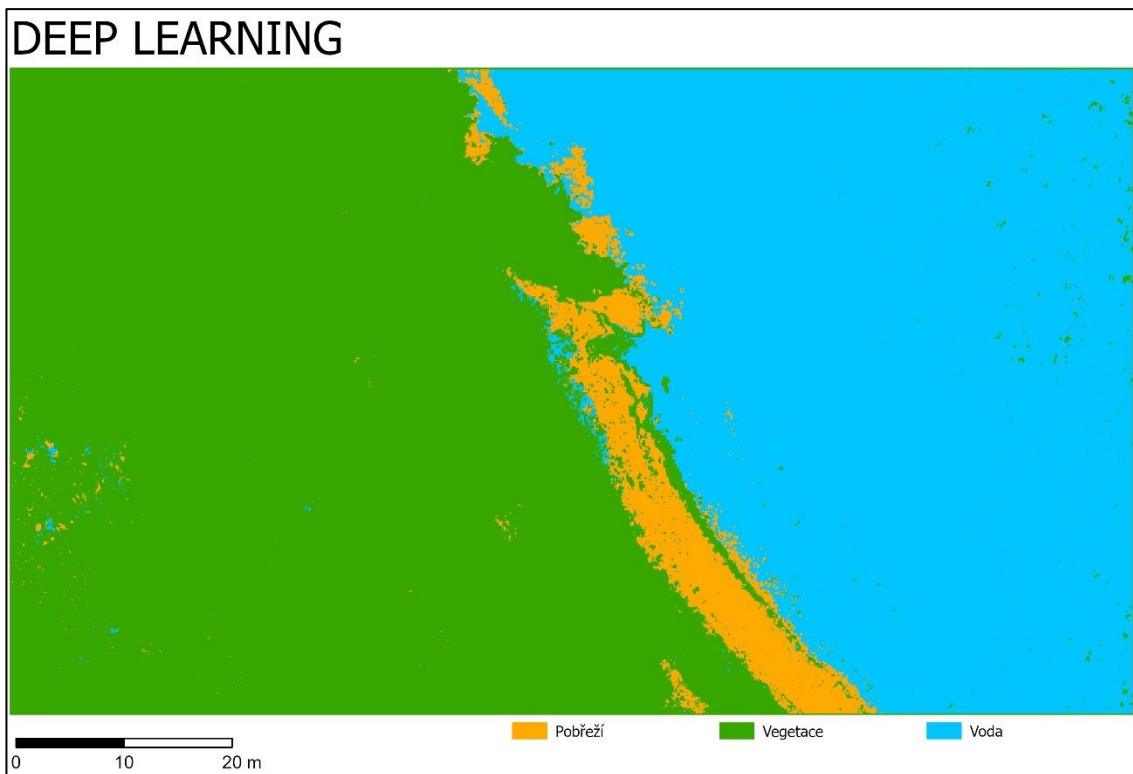
Obrázek 67: Klasifikace rybníku Skříň pomocí metody Random trees

Zdroj: [vlastní zpracování]



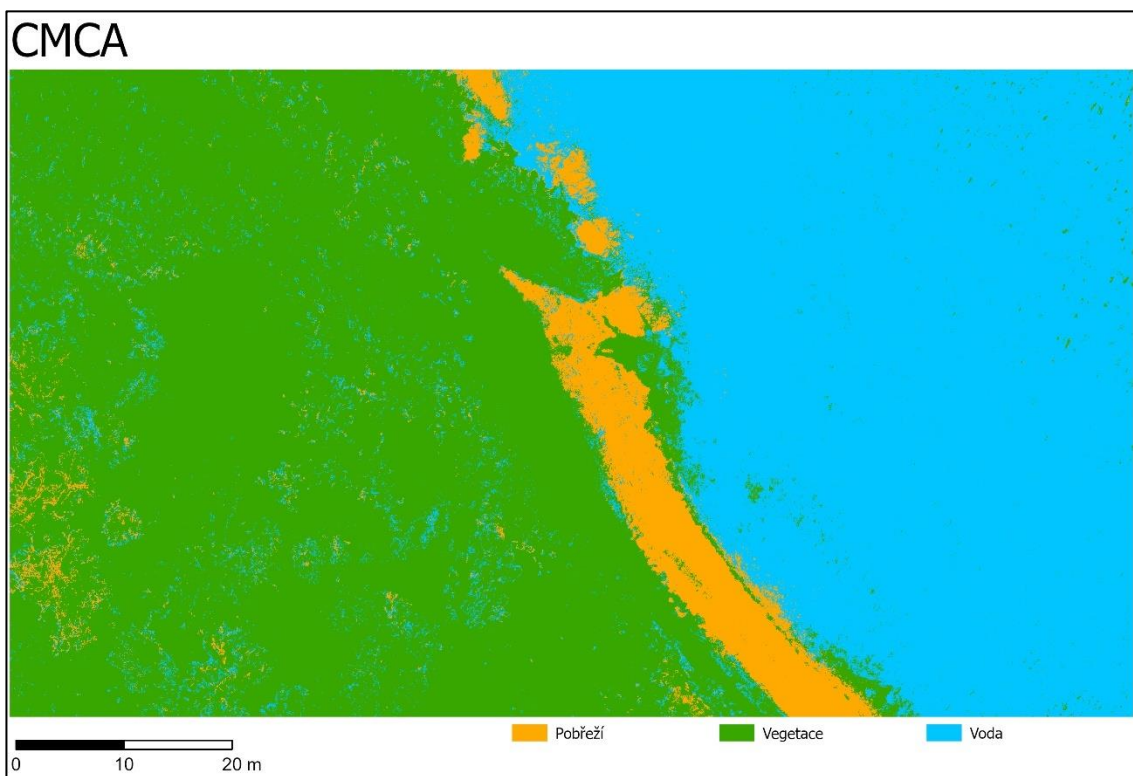
Obrázek 68: Klasifikace rybníku Skříň pomocí metody SVM

Zdroj: [vlastní zpracování]



Obrázek 69: Klasifikace rybníku Skříň pomocí metody Deep learning

Zdroj: [vlastní zpracování]



Obrázek 70: Klasifikace rybníku Skříň pomocí metody CMCA

Zdroj: [vlastní zpracování]

Tabulka 14: Porovnání výsledků klasifikací (případová studie 2) včetně bod zpracování

Klasifikační metoda	Celková přesnost	Kappa	Doba klasifikace
ML	92,30 %	85,89 %	8,16 s
RT	93,20 %	87,53 %	27,12 s
SVM	93,95 %	88,97 %	17,35 s
CMCA	94,20 %	89,35 %	11,40 s
DL U-Net	96,60 %	93,70 %	23 m 9 s

Zdroj: [vlastní zpracování]

6 DISKUSE VÝSLEDKŮ

Navržený klasifikační přístup CMCA dosáhl velmi dobrých výsledků přesnosti klasifikace, které byly ověřeny na již publikovaných příspěvcích [55][69]. Na již publikovaných příspěvcích bylo porovnáno dosažených výsledků a k nim byla vytvořena klasifikace pomocí CMCA a následně ověřena její přesnost a porovnána vůči publikovaným. Výsledky klasifikačního přístupu CMCA dosahují často druhých nejlepších výsledků [69] a někdy i nejlepších výsledků [5.1].

Při hodnocení více aspektů využívání CMCA klasifikátoru, než je jen celková přesnost, ale také výpočetní náročnost, tak ta hovoří jasně ve prospěch navrženého klasifikačního přístupu zejména při porovnání s metodami hlubokého učení [5.3, 5.4].

Navržený klasifikátor byl postaven na konvenčních klasifikačních metodách typu Maximum Likelihood, Support Vector Machine a Random Trees, jelikož poskytují dobré výsledky při klasifikování RGB obrazových dat s velmi vysokým prostorovým rozlišením, jak bylo zmíněno v kapitole 3. Zároveň tyto metody nemají velké nároky na výpočetní výkon v porovnání s modernějšími metodami založenými na hlubokém učení, viz Výpočetní náročnost.

Při klasifikování pomocí metody Maximum Likelihood, jako jeden ze vstupů pro klasifikační přístup CMCA, lze konstatovat, že pravidelně dosahuje vysokých výsledků, jak na autorem zpracovaných případových studiích [4.4.1, 4.4.2, 5.2, 5.3], tak i na publikacích s velmi podobnou charakteristikou [70][120]. Ale není tomu tak ve všech případech, někdy metoda Maximum Likelihood dosahuje nižších přesností než jiné použité klasifikátory [56][60][5.4], stejně jako v příspěvcích [123][21].

Vysokých přesností klasifikací dokazuje i klasifikační metoda Support Vector Machine (SVM), v některých případech dokonce nejlepších výsledků [36][81]. To potvrzuje, že je tento klasifikátor vhodný jako jeden ze vstupů do klasifikačního přístupu CMCA. V příspěvcích [4.4.2, 5.2] dosahuje celkové přesnosti přes 98 %.

Posledním z klasifikátorů zvolených jako vhodný pro vstup do klasifikačního přístupu CMCA je klasifikátor Random Trees, někdy také Random Forest, který obsahuje větší množství rozhodovacích stromů (500+). V autorem publikovaných příspěvcích [55][56] i v případových studiích [4.4.2, 5.2] dosahuje vysoké přesnosti klasifikace. Stejně je tomu v případech příspěvků z vědecké databáze uvedených v kapitole 3. V příspěvcích [36][118][80][21] metoda dosahuje dobrých výsledků přesností klasifikace s minimálně 90 % přesností.

Navržený klasifikační přístup CMCA eliminuje špatně klasifikované jednotlivé pixely na základě nedostatků konvenčních klasifikačních metod [4.4.1, 5.2] [55].

Bylo ověřeno, že navržený klasifikační přístup CMCA, je schopný zpracovat různá vstupní data (data z ENVI), která splňují omezující podmínky vstupních dat. Je postačující, aby vstupní data splňovala omezující podmínky prvně navrženého přístupu CMCA, tedy data s velmi vysokým prostorovým rozlišením a rastrové formáty. Tvrzení bylo ověřeno na studii Multimediální nástroje v kapitole 4.4.1. Toto potvrzení univerzálnosti vede k tvrzení, že lze aplikovat navržený klasifikační přístup i v jiných softwarových nástrojích.

Na základě diskutovaného textu, provedených ověření a aplikování na případových studiích lze shrnout výstupy disertační práce, omezující podmínky a přínosy v navrženého klasifikačního přístupu CMCA do následujících bodů:

- Zpracování dat s velmi vysokým prostorovým rozlišením sebou přináší problém s lokálními frakcemi různých klasifikačních tříd, které jsou obsaženy v jiných třídách.,
- Konvenční klasifikační metody mají potenciál ve zpracování RGB obrazových dat s velmi vysokým prostorovým rozlišením i za jisté úspornosti ve výpočetním výkonu.,
- Porovnáním výsledných celkových přesností klasifikačních metod s navrženou metodou CMCA ukazuje na vysokou hodnotu přesnosti.,
- Porovnání vizuálních výsledků poskytnutých klasifikační metodou CMCA znázorňuje značné vylepšení oproti tradičním metodám, ale i v některých případech oproti hlubokému učení.,
- Pro potřeby ověření přesností použitých metod je potřeba pro data s velmi vysokým prostorovým rozlišením vygenerovat vyšší počet náhodných hodnotících bodů pro porovnání s referenčními daty.,
- Navržený klasifikační přístup CMCA umožňuje zpracovat na vstupu i data z jiných GIS nástrojů, než je pro něj primárně určen.,
- CMCA dosahuje na ověřených datech z případových studií v mnoha případech dobrých výsledků, často 2. nejlepšího výsledku, ale někdy také nejlepších výsledků ze zvolených klasifikačních metod.,
- Navržený klasifikační přístup CMCA je velmi výkonově nenáročný, zejména s porovnáním s klasifikátory založené na hlubokém učení.

PŘÍNOS PRO VĚDNÍ OBOR A PRAXI

Navržený klasifikační přístup CMCA je přínosný pro vědní obor tím, že navržený skript pro jazyk Python je univerzální skrze software. Poskytuje dosažení lepších výsledků přesnosti klasifikace, než dosahují konvenční metody. Odstraňuje nedostatky využívání tradičních metod, tím, že provádí vážený počet z již klasifikovaných snímků a vybírá nejpravděpodobnější hodnotu daného pixelu snímku. Skript je navržen jako open source řešení, spustitelný na jakémkoliv zařízení podporující Python.

Aplikování navrženého klasifikačního přístupu v praxi poskytuje vylepšení výsledků identifikace typů povrchu pro potřeby sledování změn v krajině. Navržený klasifikační přístup CMCA je, ale také velmi univerzální, lze jej použít i na jiné aplikace, kde jsou vstupní data tvořeny RGB obrazovými daty s velmi vysokým prostorovým rozlišením. Výhodou je univerzálnost skrze GIS softwarové nástroje, jelikož je skript založen pouze na potřebě spuštění pomocí prostředí a jazyka Python (verze 3.0). Mezi další univerzálnost patří možnost spuštění klasifikačního přístupu CMCA i bez softwarových nadstaveb pro práci s prostorovými daty, ale pak není možnost si klasifikovaná data zobrazit.

ZÁVĚR

V moderním světě je velmi důležité mít spolehlivá data s velmi vysokou kvalitou informací. Prostředky pro dálkový průzkum Země poskytují neinvazivním způsobem získávání informací o povrchu, které se uplatní v jakémkoliv odvětví. S rozvojem výpočetní techniky a bezpilotních prostředků, včetně jejich dostupnosti, se možnost získávání vlastních kvalitních dat velmi rozšířila. Bepilotní prostředky jsou nejlevnější způsob, jak získat obrazová data s velmi vysokým prostorovým rozlišením (pod 10 cm/px) o snímaném povrchu. Obrazová data pořízena bezpilotními prostředky mohou sama o sobě posloužit, ale pro rozsáhlejší využití v praxi je potřeba vstupní data pořízená bezpilotními prostředky převést na kvalitnější informace. Jedním z těchto převodů je klasifikace dat. Klasifikace dat je již dlouho známý proces, ale má i své problémy zejména ve spojení s obrazovými daty pořízeny klasickým snímačem viditelné části EM spektra neboli viditelného světla. Mezi tyto problémy patří: omezení získaných dat na barvy viditelného světla, různé výsledky při využívání stejných klasifikačních metod na různá prostředí. Výhodou obrazových dat pořízených pomocí bezpilotních prostředků je jejich snadné získávání a poskytování velmi detailního rozlišení jednotlivě pořízených snímků.

Vzhledem k výše zmíněnému je cílem disertační práce navržení a ověření nového přístupu pro klasifikaci RGB obrazových dat s velmi vysokým prostorovým rozlišením. Obrazová data s velmi vysokým prostorovým rozlišením lze snadno získat pomocí bezpilotních prostředků. V práci je navrhnout, otestován a zhodnocen nový klasifikační přístup Conventional Multi Classifier Approach (CMCA), který na vstupu využívá výstupy z konvenčních klasifikačních metod, ze kterých vypočítá vážený počet v daném pixelu snímku, ze všech konvenčních klasifikačních výstupů. Tento přístup odstraňuje nevýhody konvenčních klasifikačních metod na různých RGB obrazových datech s velmi vysokým prostorovým rozlišením, zejména špatné klasifikace pixelů.

V této práci je představen navržený klasifikační přístup CMCA, který byl navržen a otestován na skutečných datech (snímcích zájmové oblasti sloužící pro water management ve viditelné části elektromagnetického spektra), viz kapitola 4.2. Klasifikační přístup CMCA zejména využívá pro výpočet výstupního snímku 3 vstupní klasifikované vrstvy podle řízených metod a to konkrétně: Maximum Likelihood, Random Trees a SVM. Klasifikační přístup CMCA je navrhnout ve dvou verzích. První verze je napsaný skript v jazyce Python a je určena pro jakýkoliv softwarový nástroj pro práci s obrazovými daty, resp. ani tento nástroj nepotřebuje, ale uživatel si bez něj nezobrazí výsledek klasifikace. První verze je založena

na přetypování rastrového snímku v číselné matice, na kterých se provádějí výpočty a následně je výsledná matice převedena na rastrový snímek umístěný v prostoru. Druhá verze klasifikačního přístupu CMCA je přímo určená pro nástroj ArcGIS PRO a jedná se o model navržený v ModelBuilderu.

Ověření funkčnosti navržené klasifikačního přístupu bylo provedeno na již publikovaných případových studiích [55][56][57][59][60][69], kde se dosažené výsledky porovnávaly s výsledky dosaženými klasifikačním přístupem CMCA. Lze konstatovat, že výsledky přesnosti klasifikace pomocí CMCA dosahují vysokých hodnot a v porovnání s jinými metodami se umísťuje na vysokých příčkách pořadí. V některých případech dokonce překonává již dosažené výsledky a klasifikuje s nejvyšší přesností.

Aplikováním klasifikačního přístupu na nové případové studie byla prokázána vysoká celková přesnost klasifikování RGB obrazových dat s velmi vysokým prostorovým rozlišením. Jelikož je navržený klasifikační přístup založen na práci s již klasifikovanými výsledky, tak není ovlivněn typy aplikací klasifikací, tedy je jedno, jestli se jedná o water management nebo o urbanismus a jiné aplikace. Dále bylo prokázáno, že klasifikační přístup umí pracovat s libovolnými výstupním rastrovými snímky, konkrétně bylo prokázáno zpracování výstupů z nástroje ENVI, viz 4.4.1.

V porovnání s moderními přístupy pro klasifikaci obrazových dat dosahuje navržený klasifikační přístup CMCA podobných výsledků, někdy i horších, než dosahují metody Deep Learning v nástroji ArcGIS PRO, ale CMCA je výpočetně výrazně úspornější než metody hlubokého učení, viz kapitola 4.3.

Přístup zpracování dat, který lze aplikovat i v souvislosti se získáváním obrazových dat s velmi vysokým prostorovým rozlišením, tedy za využití bezpilotních prostředků, lze definovat jako projekt a s ním spojen i přístup projektového managementu [58].

Navržený klasifikační přístup CMCA je navržen pro odstraňování nedostatků konvenčních klasifikačních metod při klasifikování RGB obrazových dat s velmi vysokým rozlišením. CMCA nástroj je univerzálním nástrojem, který lze využít pro různé nástroje pro práci s prostorovými daty, ale ve formě modelu lze přímo využívat jako součást ArcGIS PRO.

POUŽITÁ LITERATURA

- [1] A brief history of drones: from pilotless balloons to roaming killers. Interesting Engineering [online]. 2020 [cit. 2024-06-26]. Dostupné z: <https://interestingengineering.com/innovation/a-brief-history-of-drones-the-remote-controlled-unmanned-aerial-vehicles-uavs>
- [2] ALBERG, Anthony J., et al. The use of “overall accuracy” to evaluate the validity of screening or diagnostic tests. *Journal of general internal medicine*, 2004, 19.5p1: 460-465.
- [3] ARIFF, Mohd Farid Mohd, et al. Near-infrared camera for night surveillance applications. *Geoinformation Science Journal*, 2010, 10.1: 38-48.
- [4] BARNHART, R. Kurt; MARSHALL, Douglas M.; SHAPPEE, Eric (ed.). *Introduction to unmanned aircraft systems*. Crc Press, 2021.
- [5] BASHIOUM, DOUGLAS L.; CARR, EDWARD E.; SIMPSON, LEROY. Computer flight planning in the North Atlantic. *Journal of Aircraft*, 1965, 2.4: 337-346.
- [6] BAXES, Gregory A. *Digital image processing: principles and applications*. John Wiley & Sons, Inc., 1994.
- [7] BELWARD, A. S.; DE HOYOS, A. A comparison of supervised maximum likelihood and decision tree classification for crop cover estimation from multitemporal LANDSAT MSS data. *International Journal of Remote Sensing*, 1987, 8.2: 229-235.
- [8] Binning – hardwarové sdružování pixelů. OptiXs [online]. [cit. 2023-10-05]. Dostupné z: <https://www.optixs.cz/slovník-17/binning---hardwarove-sdruzovani-pixelu-55s>
- [9] BISHOP, Christopher M. *Pattern recognition and machine learning*. Springer google schola, 2006, 2: 1122-1128.
- [10] BRUZZONE, Lorenzo; CARLIN, Lorenzo. A multilevel context-based system for classification of very high spatial resolution images. *IEEE transactions on Geoscience and Remote Sensing*, 2006, 44.9: 2587-2600.

- [11] CAMPBELL, James B. a Randolph H. WYNNE, 2011. Introduction to Remote Sensing. 5th ed. Guilford Press, 667 s. ISBN 9781609181765.
- [12] CARLEER, A. P.; DEBEIR, Olivier; WOLFF, Eléonore. Assessment of very high spatial resolution satellite image segmentations. *Photogrammetric Engineering & Remote Sensing*, 2005, 71.11: 1285-1294.
- [13] CIBULKA, Radim, 2015. Pardubické Polabí, Baroch – přírodní rezervace. *BOTANY.cz* [online]. [cit. 2024-06-26]. Dostupné z: <https://botany.cz/cs/baroch/>
- [14] Cohenovo kappa jako míra shody dvou hodnotitelů. *Acrea* [online]. 2020 [cit. 2023-10-05]. Dostupné z: <https://acrea.cz/cohenovo-kappa-jako-mira-shody-dvou-hodnotitelu/>
- [15] COLLIS, R. T. H. Lidar. *Applied optics*, 1970, 9.8: 1782-1788.
- [16] Comparison of Aerial Surveying With a Manned Aircraft or UAS for Mapping and 3D Modelling? *GeoMatching* [online]. 2019 [cit. 2023-10-05]. Dostupné z: <https://www.eoportal.org/satellite-missions/pleiades-neo#overview>
- [17] COWARDIN, Lewis M.; MYERS, Victor I. Remote sensing for identification and classification of wetland vegetation. *The Journal of Wildlife Management*, 1974, 308-314.
- [18] ČÚZK: Geoportál, CMS [online]. [cit. 2024-06-26]. Dostupné z: [https://geoportal.cuzk.cz/\(S\(am5gjn4czvnskmt0312troeu\)\)/Default.aspx?mode=TextMeta&text=lms&side=lms](https://geoportal.cuzk.cz/(S(am5gjn4czvnskmt0312troeu))/Default.aspx?mode=TextMeta&text=lms&side=lms)
- [19] Data Classification, [online]. [cit. 2024-06-26]. Dostupné z: https://saylordotorg.github.io/text_essentials-of-geographic-information-systems/s10-03-data-classification.html
- [20] Deep learning in ArcGIS Pro. *ArcGIS PRO | Documentation* [online]. [cit. 2023-10-05]. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/deep-learning/deep-learning-in-arcgis-pro.htm>
- [21] DEWALI, Sanjay Kumar, et al. Combining OBIA, CNN, and UAV photogrammetry for automated avalanche deposit detection and characterization. *Advances in Space Research*, 2023, 72.8: 3109-3132.

- [22] DEWITT, Bon A.; WOLF, Paul R. Elements of Photogrammetry (with Applications in GIS). McGraw-Hill Higher Education, 2000.
- [23] DIAKOIANNIS, Foivos I., et al. ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 162: 94-114.
- [24] DJI - Official website [online]. [cit. 2023-10-05]. Dostupné z: <https://www.dji.com/cz>
- [25] DOBROVOLNÝ, Petr, 1998. Dálkový průzkum Země: digitální zpracování obrazu. Brno: Masarykova univerzita. ISBN 80-210-1812-7
- [26] Domestomas. Original version in English by Inductiveload – Translation from English version, CC BY-SA 3.0, [cit. 2024-06-26]. Dostupné z: <https://commons.wikimedia.org/w/index.php?curid=100189339>
- [27] Doplněk X - Bezpilotní systémy [online]. In: . Řízení letového provozu, s. 6 [cit. 2023-10-05]. Dostupné z: https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKEwiw9prCo9-BAXXDh_0HHUcIDPIQFnoECBMQAQ&url=https%3A%2F%2Faim.rlp.cz%2Fpredpisy%2Fpredpisy%2Fdokumenty%2FL%2FL-2%2Fdata%2Feffective%2FdoplX.pdf&usg=AOvVaw096Q83mQP8snKLbrlJsUI9&opi=89978449
- [28] Drone Glossary. Drones in Agriculture for STEM/STEAM Education [online]. 2016 [cit. 2023-10-05]. Dostupné z: <https://blogs.oregonstate.edu/agdrones4steam/drone-glossary/>
- [29] Drone, UAV, UAS, RPA or RPAS ... - Terminology. Altigator [online]. [cit. 2023-10-05]. Dostupné z: <https://altigator.com/en/drone-uav-uas-rpa-or-rpas/>
- [30] ECOSYSTEM, Copernicus Data Space, 2024. Sentinel-2. *Copernicus Data Space Ecosystem* [online]. [cit. 2024-06-26]. Dostupné z: <https://dataspace.copernicus.eu/explore-data/data-collections/sentinel-data/sentinel-2>

- [31] EGLI, Sebastian; HÖPKE, Martin. CNN-based tree species classification using high resolution RGB image data from automated UAV observations. *Remote Sensing*, 2020, 12.23: 3892.
- [32] Esri. "Topographic" [basemap]. Scale Not Given. "World Topographic Map" (2012). [online] [cit. 2024-06-26]. Dostupné z: <http://www.arcgis.com/home/item.html?id=30e5fe3149c34df1ba922e6f5bbf808f>.
- [33] FAHLSTROM, Paul G.; GLEASON, Thomas J.; SADRAEY, Mohammad H. *Introduction to UAV systems*. John Wiley & Sons, 2022.
- [34] FERSTER, Warren, 2023. U.S. Government Eases Restrictions on DigitalGlobe. *SpaceNews* [online]. [cit. 2024-06-26]. Dostupné z: <https://spacenews.com/40874us-government-eases-restrictions-on-digitalglobe/>
- [35] FICK, Stephen E.; HIJMANS, Robert J. WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. *International journal of climatology*, 2017, 37.12: 4302-4315.
- [36] GARZON-LOPEZ, Carol X.; LASSO, Eloisa. Species classification in a tropical alpine ecosystem using UAV-Borne RGB and hyperspectral imagery. *Drones*, 2020, 4.4: 69.
- [37] GDC4S News Release: General Dynamics to Build Satellite to Improve U.S. Government Access to High-Resolution Earth Imagery, [online]. [cit. 2024-06-26]. Dostupné z: <https://web.archive.org/web/20110928203829/http://www.gdc4s.com/news/detail.cfm?prid=14>
- [38] Geomorfologie - Práce s leteckými snímky. [online]. [cit. 2023-10-05]. Dostupné z: http://geologie.vsb.cz/geomorfologie/Cviceni/Zadani_2/Zadani_2_obr/Mapa_Lsnimek.jpg
- [39] GIANCOLI, Douglas C., 1994. *Physics for Scientists and Engineers with Modern Physics* [online]. [cit. 2024-06-26]. Dostupné z: <http://ci.nii.ac.jp/ncid/BA49170880>

- [40] GIONES, Ferran; BREM, Alexander. From toys to tools: The co-evolution of technological and entrepreneurial developments in the drone industry. *Business Horizons*, 2017, 60.6: 875-884.
- [41] Google Ngram Viewer. Google [online]. [cit. 2023-10-05]. Dostupné z: https://books.google.com/ngrams/graph?content=UAV%2Cdrone%2Cunmanned+aerial+vehicle%2Cunmanned+aerial+system&year_start=1940&year_end=2019&corpus=26&smoothing=3
- [42] GUPTA, Suraj G.; GHONGE, Dr Mangesh; JAWANDHIYA, Pradip M. Review of unmanned aircraft system (UAS). *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET) Volume*, 2013, 2.
- [43] HALOUNOVÁ, Lena a Jiří PAVELKA, 2008. *Dálkový průzkum Země. 3*. Praha: ČVUT, 182 s. ISBN 978-80-01-03124-7
- [44] HASSANALIAN, Mostafa; ABDELKEFI, Abdessattar. Classifications, applications, and design challenges of drones: A review. *Progress in Aerospace Sciences*, 2017, 91: 99-131.
- [45] High-Resolution Imagery with Planet Satellite Tasking | Planet, *Planet* [online]. [cit. 2024-06-26]. Dostupné z: <https://www.planet.com/products/hi-res-monitoring/>
- [46] How does a drone's fail-safe system work? TS2 [online]. 2023 [cit. 2023-10-05]. Dostupné z: <https://ts2.space/en/how-does-a-drones-fail-safe-system-work/>
- [47] How to use DJI's Return to Home (RTH) Safely. DJI Guides [online]. 2017 [cit. 2023-10-05]. Dostupné z: <https://store.dji.com/guides/how-to-use-the-djis-return-to-home/>
- [48] https://en.wikipedia.org/wiki/Deep_learning#/media/File:AI-ML-DL.svg
- [49] <https://www.semanticscholar.org/paper/Two-step-procedure-of-optimisation-for-flight-for-Dashora-Lohani/52a5bc4aace403cd220fa86cb0334cbf408fb455>
- [50] HUSSAIN, Ruba Yousif. Production of digital mosaics from aerial images. *Journal of Engineering and Sustainable Development*, 2013, 17.4: 72-88.

- [51] CHAN, K. W.; NIRMAL, U.; CHEAW, W. G. Progress on drone technology and their applications: A comprehensive review. In: AIP conference proceedings. AIP Publishing, 2018.
- [52] CHO, Doosan. A Study on a Flight Safe System in Unmanned Aerial Vehicles. *Int. J. Appl. Eng. Res.*, 2018, 13.9: 7128-7130.
- [53] IMMITZER, Markus; ATZBERGER, Clement; KOUKAL, Tatjana. Tree species classification with random forest using very high spatial resolution 8-band WorldView-2 satellite data. *Remote sensing*, 2012, 4.9: 2661-2693.
- [54] Jaký je rozdíl mezi autonomním a automatickým dronem? Úřad pro civilní letectví [online]. [cit. 2023-10-05]. Dostupné z: <https://www.caa.cz/uFAQs/jaky-je-rozdil-mezi-autonomnim-a-automatickym-dronem/>
- [55] JECH, Jakub, et al. Utilization of UAV-Borne RGB Data for Monitoring Horses: Comparison of Classification Methods. In: 2023 18th Iberian Conference on Information Systems and Technologies (CISTI). IEEE, 2023. p. 1-6.
- [56] JECH, Jakub, Jitka KOMÁRKOVÁ a Devanjan BHATTACHARYA. Comparison of Automatic Classification Methods for Identification of Ice Surfaces from Unmanned-Aerial-Vehicle-Borne RGB Imagery. In: *Applied Sciences*. MDPI, 2023. Dostupné z: doi: doi.org/10.3390/app132011400
- [57] JECH, Jakub. Zpracování dat z UAV pro monitoring změn v rámci vybraného zájmového území. 2019.
- [58] JECH, Jakub; JIRAVA, Pavel. Project Management Perspective on UAV Data Collection: Water Management Case Study Baroch. In: 2023 International Conference on Information and Digital Technologies (IDT). IEEE, 2023. p. 201-206.
- [59] JECH, Jakub; KOMÁRKOVÁ, Jitka. Comparison of Creating 3D Models from UAV: Case Study Windmill Černilov. In: 2023 International Conference on Information and Digital Technologies (IDT). IEEE, 2023. p. 213-218.
- [60] JECH, Jakub; KOMARKOVA, Jitka; SEDLAK, Pavel. Land Cover Change Detection Near Small Water Bodies Based on RGB Uav Data: Case Study of the Pond Baroch,

Czech Republic. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2022, 43: 617-623

- [61] JENSEN, John R. and LULLA, Kalmesh, 1987. Introductory digital image processing: A remote sensing perspective. Geocarto International. Vol. 2, no. 1, p. 65. DOI 10.1080/10106048709354084.
- [62] KAN, Masataka; OKAMOTO, Shingo; LEE, Jae Hoon. Development of drone capable of autonomous flight using GPS. In: Proceedings of the international multi conference of engineers and computer scientists. 2018.
- [63] KARAS, Jakub a Tomáš TICHÝ. Drony. Brno: Computer Press, 2016. ISBN 978-80-251-4680-4.
- [64] Kategorie provozu UAS. Úřad pro civilní letectví [online]. [cit. 2023-10-05]. Dostupné z: <https://www.caa.cz/provoz-stare/bezpilotni-letadla-stara/kategorie-provozu-uas/>
- [65] KHAN, Muhammad Sohaib, et al. Drone selection using multi-criteria decision-making methods. In: 2021 International Bhurban Conference on Applied Sciences and Technologies (IBCAST). IEEE, 2021. p. 256-270.
- [66] KOLÁŘ, Jan, Lena HALOUNOVÁ a Karel PAVELKA, 1997. Dálkový průzkum Země 10. Praha: České vysoké učení technické. ISBN 80-010-1567-X.
- [67] KOMÁRKOVÁ, J. - JECH, J. Processing UAV Based RGB Data to Identify Land Cover with Focus on Small Water Body: Comparison of Methods. In Iberian Conference on Information Systems and Technologies, CISTI , volume 2020-June. New York: IEEE (Institute of Electrical and Electronics Engineers), 2020. s. 9141170 s. ISBN 978-989-54-6590-3.
- [68] KOMPSAT-3A (Korea Multi-Purpose Satellite-3A) / Arirang-3A - eoPortal, 2022 [online]. [cit. 2024-06-26]. Dostupné z: <https://www.eoportal.org/satellite-missions/kompsat-3a#space-and-hardware-components>
- [69] KRATKY, Martin, et al. Selected Multimedia Tools as a Tool to Compare Changes in the Landscape. In: 2023 18th Iberian Conference on Information Systems and Technologies (CISTI). IEEE, 2023. p. 1-5.

- [70] LEE, KyungDo, et al. A comparative study of image classification method to classify onion and garlic using Unmanned Aerial Vehicle (UAV) imagery. *Korean Journal of Soil Science and Fertilizer*, 2016, 49.6: 743-750.
- [71] LI, Xinghua, et al. Remote sensing image mosaicking: Achievements and challenges. *IEEE Geoscience and Remote Sensing Magazine*, 2019, 7.4: 8-22.
- [72] LILLESAND, Thomas M., Ralph W. KIEFER a Jonathan W. CHIPMAN, 2008. Remote sensing and image interpretation. 6th ed. Hoboken, NJ: John Wiley. ISBN 978-0-470-05245-7
- [73] LINDER, Wilfried. Digital photogrammetry. Berlin/Heidelberg, Germany: Springer, 2009.
- [74] LINSEN, Lars. Point cloud representation. Technical Report, Faculty of Computer Science, University of Karlsruhe: Univ., Fak. für Informatik, Bibliothek, 2001.
- [75] LIU, Jian Guo a Philippa J. MASON, 2009. Essential Image Processing and GIS for Remote Sensing. NJ: John Wiley, 443 s. ISBN 9781118687963.
- [76] LONGLEY, Paul, Goodchild MICHAEL, Maguire DAVID a Rhind DAVID, 2011. Geographic Information Systems and Science. 3rd ed. Hoboken: Wiley, 560 s. ISBN 978-0-470-72144-5
- [77] LUKASOVÁ, Alena a ŠARMANOVÁ, Jana. Metody shlukové analýzy. Praha: SNTL, 1985. ISBN (Váz.).
- [78] Mapy.cz, Mapy.cz [online]. [cit. 2024-06-26]. Dostupné z: <https://mapy.cz/zakladni?x=15.6252330&y=49.8022514&z=8>
- [79] MCHUGH, Mary L. Interrater reliability: the kappa statistic. *Biochemia medica*, 2012, 22.3: 276-282.
- [80] MIRAKI, Mojdeh; SOHRABI, Hormoz; IMMITZER, Markus. Tree Species Mapping in Mangrove Ecosystems Using UAV-RGB Imagery and Object-Based Image Classification. *Journal of the Indian Society of Remote Sensing*, 2023, 51.10: 2095-2103.

- [81] MOHLER, Rhett L.; MORSE, Jarod M. Using UAV imagery to map invasive *Phragmites australis* on the Crow Island State Game Area, Michigan, USA. *Wetlands Ecology and Management*, 2022, 30.6: 1213-1229.
- [82] Multispectral and Hyperspectral drone imagery. AltiGator [online]. [cit. 2023-10-05]. Dostupné z: <https://altigator.com/en/multispectral-and-hyperspectral-drone-imagery/>
- [83] NEVALAINEN, Olli, et al. Individual tree detection and classification with UAV-based photogrammetric point clouds and hyperspectral imaging. *Remote sensing*, 2017, 9.3: 185.
- [84] Ortofoto České republiky. ČÚZK [online]. [cit. 2023-10-05]. Dostupné z: [https://geoportal.cuzk.cz/\(S\(grqb1nf3majaz3vh01qcbxww\)\)/Default.aspx?lng=CZ&mode=TextMeta&side=ortofoto&metadataID=CZ-CUZK-ORTOFOTO-R&mapid=83&menu=231](https://geoportal.cuzk.cz/(S(grqb1nf3majaz3vh01qcbxww))/Default.aspx?lng=CZ&mode=TextMeta&side=ortofoto&metadataID=CZ-CUZK-ORTOFOTO-R&mapid=83&menu=231)
- [85] PÁDUA, Luís, et al. Vineyard classification using machine learning techniques applied to RGB-UAV imagery. In: *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2020. p. 6309-6312.
- [86] PAINE, David P.; KISER, James D. *Aerial photography and image interpretation*. John Wiley & Sons, 2012.
- [87] PARK, Soon-Yong; SUBBARAO, Murali. A multiview 3D modeling system based on stereo vision techniques. *Machine Vision and Applications*, 2005, 16: 148-156.
- [88] PERRITT JR, Henry; SPRAGUE, Eliot. *Domesticating Drones: The technology, law, and economics of unmanned aircraft*. Routledge, 2016.
- [89] PerúSAT-1 - A 24-month story from A to Z, 2021Airbus [online] [cit. 2024-06-06]. Dostupné z: <https://www.airbus.com/en/space/earth-observation/earth-observation-portfolio/pleiades-neo>,
- [90] Pleiades Neo. EoPortal [online]. 2022 [cit. 2023-10-05]. Dostupné z: <https://www.eoportal.org/satellite-missions/pleiades-neo#overview>

- [91] PŘÍHODOVÁ, Kateřina; JECH, Jakub. Gender recognition using thermal images from UAV. In: 2021 International Conference on Information and Digital Technologies (IDT). IEEE, 2021. p. 83-88.
- [92] PŘÍHODOVÁ, Kateřina; JECH, Jakub. Low-cost system for gender recognition using convolutional neural network. In: Proceedings of 34th International Business Information Management Association Conference. Vision 2025: Education Excellence and Management of Innovations through Sustainable Economic Competitive Advantage, IBIMA 2019. International Business Information Management Association-IBIMA, 2019.
- [93] PŘÍHODOVÁ, Kateřina; JECH, Jakub. Prevention of the spread of viral disease using artificial intelligence from data obtained by UAVs. In: SHS Web of Conferences. Volume 92 (2021). EDP Sciences-Web of Conferences, 2021.
- [94] RICHARDS, John A., 2013. Remote Sensing Digital Image Analysis: An Introduction. 5th ed. Springer, Berlin, Heidelberg, 494 s. ISBN 978-3-642-30061-5.
- [95] RUSCIO, Davide Di, et al. Automatic generation of detailed flight plans from high-level mission descriptions. In: Proceedings of the ACM/IEEE 19th International Conference on Model Driven Engineering Languages and Systems. 2016. p. 45-55.
- [96] SANTOS, José Luís; FARAHI, Faramarz (ed.). Handbook of optical sensors. Crc Press, 2014.
- [97] SE, Stephen; JASIOBEDZKI, Piotr. Stereo-vision based 3D modeling and localization for unmanned vehicles. International Journal of Intelligent Control and Systems, 2008, 13.1: 47-58.
- [98] SHINOZUKA, M.; MANSOURI, B. Synthetic aperture radar and remote sensing technologies for structural health monitoring of civil infrastructure systems. In: Structural health monitoring of civil infrastructure systems. Woodhead Publishing, 2009. p. 113-151.
- [99] SCHLÄPFER, Daniel; POPP, Christoph; RICHTER, Rudolf. Drone data atmospheric correction concept for multi-and hyperspectral imagery–the DROACOR model. The

International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2020, 43: 473-478.

- [100] SMITH, Colin. The photographer's guide to drones. Rocky Nook, Inc., 2022.
- [101] SOM-ARD, Jaturong, et al. Pre-harvest sugarcane yield estimation using UAV-based RGB images and ground observation. Sugar Tech, 2018, 20.6: 645-657.
- [102] SPAROVEK, Gerd, et al. Köppen's climate classification map for Brazil. 2013.
- [103] SPOT-6 and SPOT-7 (Azersky) - eoPortal, 2022 [online]. [cit. 2024-06-26]. Dostupné z: <https://www.eoportal.org/satellite-missions/spot-6-7#performance-specifications>
- [104] STIGLER, Stephen M. The epic story of maximum likelihood. Statistical Science, 2007, 598-620.
- [105] SVATOŇOVÁ, Hana a Lubomír LAUERMAN, 2010. Dálkový průzkum Země – aktuální zdroj geografických informací. Brno: Masarykova univerzita. ISBN 978-80-210-5162-1
- [106] Světlo ve fotografii: Přírozenému světlu musíte přizpůsobit expozici i scénu. Milujeme fotografii [online]. [cit. 2023-10-05]. Dostupné z: <https://www.milujemefotografii.cz/svetlo-ve-fotografii-prirozenemu-svetlu-musite-prizpusobit-expozici-i-scenu>
- [107] SYDER, Diana. Maxwell's Rainbow. Smith/Doorstop Books, 2002.
- [108] The Evolution of Drones: From Military to Hobby & Commercial. Percepto [online]. 2019 [cit. 2023-10-05]. Dostupné z: <https://percepto.co/the-evolution-of-drones-from-military-to-hobby-commercial/>
- [109] Topics | EASA, EASA [online]. [cit. 2024-06-26]. Dostupné z: <https://www.easa.europa.eu/cs/light/topics/drones>
- [110] TU, Yu-Hsuan, et al. Optimising drone flight planning for measuring horticultural tree crop structure. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 160: 83-96.

- [111] Understanding the mosaicking rules for a mosaic dataset. ArcMap | Documentation [online]. [cit. 2023-10-05]. Dostupné z: <https://desktop.arcgis.com/en/arcmap/latest/manage-data/raster-and-images/understanding-the-mosaicking-rules-for-a-mosaic-dataset.htm>
- [112] Vstup dat do GIS. Masarykova univerzita [online]. [cit. 2023-10-05]. Dostupné z: <https://www.fi.muni.cz/usr/richter/lekceGIS/u08i.htm>
- [113] WAN, Liang, et al. Combining UAV-based vegetation indices and image classification to estimate flower number in oilseed rape. *Remote Sensing*, 2018, 10.9: 1484.
- [114] WANDINGER, Ulla. Introduction to lidar. In: *Lidar: range-resolved optical remote sensing of the atmosphere*. New York, NY: Springer New York, 2005. p. 1-18.
- [115] What are the band designations for the Landsat satellites? USGS [online]. [cit. 2023-10-05]. [cit. 2024-06-26]. Dostupné z: <https://www.usgs.gov/faqs/what-are-band-designations-landsat-satellites>
- [116] What is mosaick? ArcMap | Documentation [online]. [cit. 2023-10-05]. Dostupné z: <https://desktop.arcgis.com/en/arcmap/latest/manage-data/raster-and-images/what-is-a-mosaic.htm>
- [117] WIRTZ, M.; KUTSCHMANN, M. Analyzing interrater agreement for categorical data using Cohen's kappa and alternative coefficients. *Die Rehabilitation*, 2007, 46.6: 370-377.
- [118] WITTSTRUCK, Lucas, et al. UAV-based RGB imagery for Hokkaido pumpkin (*Cucurbita max.*) detection and yield estimation. *Sensors*, 2020, 21.1: 118.
- [119] XUE, Yong, et al. Small satellite remote sensing and applications—history, current and future. *International Journal of Remote Sensing*, 2008, 29.15: 4339-4372.
- [120] YANG, Ming-Der, et al. Spatial and spectral hybrid image classification for rice lodging assessment through UAV imagery. *Remote Sensing*, 2017, 9.6: 583.
- [121] ZHANG, Chen, et al. Tree species classification using deep learning and RGB optical images obtained by an unmanned aerial vehicle. *Journal of Forestry Research*, 2021, 32.5: 1879-1888.

- [122] ZHAO, Wenzhi; DU, Shihong. Learning multiscale and deep representations for classifying remotely sensed imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 113: 155-165.
- [123] ZHENG, Hengbiao, et al. Early season detection of rice plants using RGB, NIR-GB and multispectral images from unmanned aerial vehicle (UAV). *Computers and Electronics in Agriculture*, 2020, 169: 105223.
- [124] UDDIN, Myin. *Drone 101: a must-have guide for any drone enthusiast*. Amazon Kindle: Washington, DC, USA, 2020.

VLASTNÍ PUBLIKACE DISERTANTA VZTAHUJÍCÍ SE K TÉMATU DISERTAČNÍ PRÁCE

PŘÍHODOVÁ, Kateřina; JECH, Jakub. Thermal-Based Gender Recognition using Drones: Advancing Biometric Recognition in Challenging Outdoor Environments. *Drone Systems and Applications*, 2024, just-in.

JECH, Jakub; KOMÁRKOVÁ, Jitka; BHATTACHARYA, Devanjan. Comparison of Automatic Classification Methods for Identification of Ice Surfaces from Unmanned-Aerial-Vehicle-Borne RGB Imagery. *Applied Sciences*, 2023, 13.20: 11400.

JECH, Jakub, et al. Utilization of UAV-Borne RGB Data for Monitoring Horses: Comparison of Classification Methods. In: 2023 18th Iberian Conference on Information Systems and Technologies (CISTI). IEEE, 2023. p. 1-6.

JECH, Jakub; KOMÁRKOVÁ, Jitka. Comparison of Creating 3D Models from UAV: Case Study Windmill Černilov. In: 2023 International Conference on Information and Digital Technologies (IDT). IEEE, 2023. p. 213-218.

KRATKY, Martin, et al. Selected Multimedia Tools as a Tool to Compare Changes in the Landscape. In: 2023 18th Iberian Conference on Information Systems and Technologies (CISTI). IEEE, 2023. p. 1-5.

JECH, Jakub; KOMARKOVA, Jitka; SEDLAK, Pavel. Land Cover Change Detection Near Small Water Bodies Based on RGB Uav Data: Case Study of the Pond Baroch, Czech Republic. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2022, 43: 617-623.

PŘÍHODOVÁ, Kateřina; JECH, Jakub. Gender recognition using thermal images from UAV. In: 2021 International Conference on Information and Digital Technologies (IDT). IEEE, 2021. p. 83-88.

PŘÍHODOVÁ, Kateřina; JECH, Jakub. Prevention of the spread of viral disease using artificial intelligence from data obtained by UAVs. In: *SHS Web of Conferences*. Volume 92 (2021). EDP Sciences-Web of Conferences, 2021.

KOMÁRKOVÁ, J. - JECH, J. Processing UAV Based RGB Data to Identify Land Cover with Focus on Small Water Body: Comparison of Methods. In Iberian Conference on Information Systems and Technologies, CISTI , volume 2020-June. New York: IEEE (Institute of Electrical and Electronics Engineers), 2020. s. 9141170 s. ISBN 978-989-54-6590-3.

PŘÍHODOVÁ, Kateřina a Jakub JECH. Low-cost gender recognition using convolutional neural network. In: *34th International Business Information Management Association Conference*. 2019, 6316-6322 ISBN: 978-0-9998551-3-3.

SEDLÁK, P. - KOMÁRKOVÁ, J. - JECH, J. - MAŠÍN, O. Low-cost UAV as a Source of Image Data for Detection of Land Cover Changes *Journal of Information Systems Engineering & Management*, 2019, vol. 4, no. 3, s. 1-9. ISSN: 2468-4376.

K datu 19. 6. 2024 příspěvky v stavu Odesláno nebo Přijato

JECH, KOMÁRKOVÁ, SEDLÁK, BRUNCLÍK, KRÁTKÝ. Comparison of Image Classification Methods in Two Time Horizons: Horses, Baroch Reserve, the Pardubický Region, Czech Republic – odesláno, čeká se na recenze

JECH, KOMÁRKOVÁ, KRÁTKÝ. Availability of spectral indices based on RGB image data obtained by low-cost UAV: case study – přijato, čeká na zařazení sborníku do databází

JECH, PŘÍHODOVÁ. Comparative Analysis of Modern Methods for Surface Type Identification in RGB Image Data – přijato, nyní ve fázi just-in, čeká na zveřejnění

PŘÍLOHA – ZDROJOVÝ KÓD METODY CMCA

```
# This works in ArcPy 3.0
import sys
import numpy as np
import rasterio
from rasterio.plot import show
from rasterio.transform import from_origin

#=====
=====
#
# This is version 3
# Requirements for input rasters: same size, same number of band.
# This script works for 3 input rasters and 3 classes
#
# Required install numpy and rasterio library (pip install rasterio numpy)
#
#=====
=====

print("Probíhá nahrávání dat...")

### Specifické cesty k rastrovým souborům
raster1 = r"X:\CMCA\CMCA\Raster\class_ml.tif"
raster2 = r"X:\CMCA\CMCA\Raster\class_rt.tif"
raster3 = r"X:\CMCA\CMCA\Raster\class_svm.tif"

# Nastavení proměnných
pole = [0] * 3 #3 je omezení CMCA na 3 klasifikační třídy

print("-----")

# Otevření rastrového snímku jako objektu datasetu
with rasterio.open(raster1) as src:
    # Přečtení rastrových dat jako numpy pole
    raster_matrix1 = src.read(1) # Přečtení prvního pásma (band)

with rasterio.open(raster2) as src:
    # Přečtení rastrových dat jako numpy pole
    raster_matrix2 = src.read(1) # Přečtení prvního pásma (band)

with rasterio.open(raster3) as src:
    # Přečtení rastrových dat jako numpy pole
    raster_matrix3 = src.read(1) # Přečtení prvního pásma (band)

# Zjištění unikátních hodnot v matici
unique_values = np.unique(raster_matrix1)
unique_values2 = np.unique(raster_matrix2)
unique_values3 = np.unique(raster_matrix3)
```

```

if set(unique_values) == set(unique_values2) == set(unique_values3):
    print(f"Unikátní hodnoty v matici: {unique_values}")
else:
    print("Matice nemají identické třídy!")

# Zjištění počtu řádků
pocet_radku = len(raster_matrix1)

# Zjištění počtu sloupců (předpokládáme, že matice není prázdná a všechny řádky mají
stejnou délku)
pocet_sloupcu = len(raster_matrix1[0]) if pocet_radku > 0 else 0

# Otestování stejné velikosti
try:
    raster_height1 = len(raster_matrix1)
    raster_width1 = len(raster_matrix1[0]) if raster_height1 > 0 else 0

    raster_height2 = len(raster_matrix2)
    raster_width2 = len(raster_matrix2[0]) if raster_height2 > 0 else 0

    raster_height3 = len(raster_matrix3)
    raster_width3 = len(raster_matrix3[0]) if raster_height3 > 0 else 0

    if raster_height1 == raster_height2 == raster_height3:
        if raster_width1 == raster_width2 == raster_width3:
            print(f"Dimenze rastrů je {raster_height1} px na výšku a {raster_width1} px na šířku.")
            print("Všechny rastry jsou stejně velké!")
        else:
            print("Není stejná velikost!")
    else:
        print("Není stejná velikost!")

except arcpy.ExecuteError:
    print(arcpy.GetMessages())
except Exception as e:
    print(e)

# Vytvoření prázdné matice {pocet_radku X pocet_sloupcu}
matice_out = np.random.randint(0, 1, size=(pocet_radku, pocet_sloupcu), dtype=np.uint8)
# Matice výstupní s vypočtenými hodnotami

# Přejmenování proměnných
raster_height = raster_height1
raster_width = raster_width1

# Cykly for pro procházení matic
print()
print("Klasifikování pomocí přístupu CMCA...")
for x in range(1, raster_height+1):
    for y in range(1, raster_width+1):
        extracted_value1 = raster_matrix1[x-1][y-1]

```

```

extracted_value2 = raster_matrix2[x-1][y-1]
extracted_value3 = raster_matrix3[x-1][y-1]

#CMCA přístup omezen na 3 třídy klasifikace
if extracted_value1 == unique_values[0]:
    pole[0] += 1
elif extracted_value1 == unique_values[1]:
    pole[1] += 1
else:
    pole[2] += 1

if extracted_value2 == unique_values[0]:
    pole[0] += 1
elif extracted_value2 == unique_values[1]:
    pole[1] += 1
else:
    pole[2] += 1

if extracted_value3 == unique_values[0]:
    pole[0] += 1
elif extracted_value3 == unique_values[1]:
    pole[1] += 1
else:
    pole[2] += 1

if pole[0] == pole [1] == pole[2]:
    # Získání náhodné hodnoty z pole
    prvek = random.choice(pole)
else:
    # Získání maximální hodnoty v poli
    max_hodnota = max(pole)
    # Získání pozice (indexu) maximální hodnoty v poli
    prvek = pole.index(max_hodnota)

#Zápis do matice
matice_out[x-1][y-1] = prvek

#reset pole
pole = [0] * 3

##for radek in matice_out:
## print(*radek)

matrix = matice_out

# Specifikace parametrů rastrového snímku
height = pocet_radku
width = pocet_sloupcu
count = 1 # Počet pásem (bands)
dtype = np.uint8

# Definice transformace a metadat

```



```

transform = from_origin(0, width, 1, 1) # Levý horní roh (0, 100) a rozlišení 1x1
crs = 'EPSG:32633' # Příklad souřadnicového systému (WGS84)

# Pomocí rasterio načteme další informace o rastru
with rasterio.open(raster1) as src:
    # Získání projekce
    crs = src.crs
    #print(f"Projekce: {crs}")

    # Získání transformační matice (geotransformace)
    transform = src.transform
    #print(f"Transformační matice (geotransformace): {transform}")
print()

# Uložení matice do rastrového snímku
with rasterio.open(
    'CMCA_out.tif',
    'w',
    driver='GTiff',
    height=height,
    width=width,
    count=count,
    dtype=dtype,
    crs=crs,
    transform=transform,
) as dst:
    #print(dst)
    dst.write(matrix, 1) # Zapisujeme data z matice do prvního pásma (bandu)

print("Rastrový snímek byl úspěšně uložen.")
print()

# Konec, čekání na zmáčknutí klávesy pro ukončení skriptu
input("HOTOVO! Pro ukončení stiskněte klávesu Enter...")
sys.exit()

```