

Univerzita Palackého v Olomouci

Přírodovědecká fakulta

Katedra geoinformatiky

**VYUŽITÍ METOD STROJOVÉHO UČENÍ PRO
KLASIFIKACI OBRAZOVÝCH A LIDAROVÝCH
DAT**

Diplomová práce

Bc. Vojtěch JABŮREK

Vedoucí práce: RNDr. Jakub MIŘIJOVSKÝ, Ph.D.

Olomouc 2024

Geoinformatika a kartografie

ANOTACE

Tématem diplomové práce je aplikace moderních metod strojového učení pro klasifikaci obrazových a lidarových dat. Práce se zaměřuje na tři případové studie, které se dotýkají fyzicko-geografických i socio-ekonomických témat.

Cílem práce je využití metod strojového učení k dosažení co nejefektivnějšího a nejpřesnějšího řešení při klasifikaci dat do vybraných tříd.

První případová studie se zabývá podrobnou klasifikací horské vegetace na Vysoké holi, druhé nejvyšší hoře Hrubého Jeseníku. Druhá případová studie se věnuje detekci stromů mimo vegetační období v oblasti sadu v obci Veselíčko. Poslední případová studie využívá automatizovaných nástrojů a modelů hlubokého učení v programech ArcGIS Pro a OpenCities Map PowerView pro klasifikaci leteckých dat LIDAR ve vybraných částech Olomouce a obcích Březové a Střeň.

KLÍČOVÁ SLOVA

Klasifikace, Strojové učení, Hluboké učení, LIDAR, Letecké snímky

ANOTATION

The topic of the thesis is the application of modern machine learning methods for image and lidar data classification. The thesis focuses on three case studies that deal with physical-geographical and socio-economic topics.

The aim of the work is to use machine learning methods to achieve the most efficient and accurate solution in classifying data into selected classes.

The first case study deals with the detailed classification of mountain vegetation on Vysoká hole, the second highest mountain of the Hrubý Jeseník.

The second case study deals with the detection of trees outside the growing season in an orchard area in the village of Veselíčko.

The last case study uses automated tools and deep learning models in ArcGIS Pro and OpenCities Map PowerView to classify aerial LIDAR data in selected parts of Olomouc and the municipalities of Březová and Střeň.

KEYWORDS

Classification, Machine learning, Deep learning, LIDAR, Aerial images

Prohlašuji, že

- bakalářskou/diplomovou práci včetně příloh, jsem vypracoval(a) samostatně a uvedl(a) jsem všechny použité podklady a literaturu.

- jsem si vědom(a), že na moji bakalářskou/diplomovou práci se plně vztahuje zákon č.121/2000 Sb. - autorský zákon, zejména § 35 – využití díla v rámci občanských a náboženských obřadů, v rámci školních představení a využití díla školního a § 60 – školní dílo,

- beru na vědomí, že Univerzita Palackého v Olomouci (dále UP Olomouc) má právo nevydělečně, ke své vnitřní potřebě, bakalářskou/diplomovou práci užívat (§ 35 odst. 3),


- souhlasím, že údaje o mé bakalářské/diplomové práci budou zveřejněny ve Studijním informačním systému UP,

- v případě zájmu UP Olomouc uzavřu licenční smlouvu s oprávněním užít výsledky a výstupy mé bakalářské/diplomové práce v rozsahu § 12 odst. 4 autorského zákona,

- použít výsledky a výstupy mé bakalářské/diplomové práce nebo poskytnout licenci k jejímu využití mohu jen se souhlasem UP Olomouc, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly UP Olomouc na vytvoření díla vynaloženy (až do jejich skutečné výše).

V Olomouci dne 5. května 2024

plné jméno autora: Vojtěch Jabůrek

podpis autora: 

Děkuji vedoucímu práce RNDr. Jakubovi Mířijovskému, Ph.D. za podněty a připomínky při vypracování práce.

Za poskytnutá data děkuji firmě Renofarmy a.s. a katedře Geoinformatiky.

Za poskytnuté rady a software děkuji firmě MDP GEO, s.r.o.

UNIVERZITA PALACKÉHO V OLMOUCI

Přírodovědecká fakulta
Akademický rok: 2022/2023

ZADÁNÍ DIPLOMOVÉ PRÁCE (projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: Bc. Vojtěch JABŮREK
Osobní číslo: R220009
Studijní program: N0532A330009 Geoinformatika a kartografie
Téma práce: Využití metod strojového učení pro klasifikaci obrazových a lidarových dat
Zadávající katedra: Katedra geoinformatiky

Zásady pro vypracování

Cílem práce je stanovit optimální postup pro klasifikaci obrazových dat DPZ a dat z laserového skenování. Student na základě provedené rešerše zvolí vhodné klasifikační metody založené na strojovém učení a Deep Learning. Autor stanoví kritéria použitelnosti jednotlivých metod a vytvořený postup aplikuje na minimálně tři případové studie. Jedna ze studií bude zaměřena na obrazová data z fyzickogeografické oblasti.

Text práce student zpracuje v souladu se závaznou šablonou pro kvalifikační práce KGI. O diplomové práci student vytvoří webovou stránku a poster. Celou práci (text, přílohy, výstupy, zdrojová a vytvořená data, poster a web) odevzdá student v digitální podobě na datové úložiště katedry. Do evidence STAG student odevzdá úplný text práce s přílohami, které určí vedoucí práce. Fyzicky student odevzdá výtisk posteru ve formátu A2 a přílohy určené vedoucím práce.

Rozsah pracovní zprávy: max. 50 stran
Rozsah grafických prací: dle potřeby
Forma zpracování diplomové práce: elektronická

Seznam doporučené literatury:

1. LILLESAND, T., KIEFER, R., CHIPMAN, J. Remote Sensing and Image Interpretation. John Wiley & Sons, Inc., New York, 756 s., 2008.
2. CAMPBELL, J., B., WYNNE, R. H. Introduction to Remote Sensing. 5th ed. Guilford Press, New York, 667 s., 2011.
3. LARY, David J., et al. Strojové učení v geovědách a dálkovém průzkumu Země. Geoscience Frontiers, 2016, 7.1: 3-10.
4. Voženílek, V. (2002): Diplomové práce z geoinformatiky. Vydavatelství Univerzity Palackého, Olomouc, UP, 31 s.

Vedoucí diplomové práce: RNDr. Jakub Miřijovský, Ph.D.
Katedra geoinformatiky

Datum zadání diplomové práce: 5. prosince 2022

Termín odevzdání diplomové práce: 9. května 2024

L.S.

doc. RNDr. Martin Kubala, Ph.D.
děkan



prof. RNDr. Vilém Pechanec, Ph.D.
vedoucí katedry

OBSAH

SEZNAM POUŽITÝCH ZKRATEK	10
ÚVOD	11
1 CÍLE PRÁCE	12
2 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY	13
2.1 Umělá inteligence.....	13
2.1.1 Strojové učení (Machine learning)	14
2.1.2 Hluboké učení (Deep learning)	20
2.2 Klasifikace obrazu.....	23
2.2.1 Postklasifikační úpravy a hodnocení	26
3 METODY A POSTUP ZPRACOVÁNÍ	28
3.1 Použité metody	28
3.1.1 Příprava a zpracování dat	28
3.1.2 Klasifikace	28
3.1.3 Postklasifikační a evaluační metody.....	29
3.2 Použitá data.....	30
3.3 Použité programy a knihovny	30
3.3.1 Použité programy	31
3.3.2 Program Python knihovny.....	32
3.4 Postup zpracování.....	33
4 PŘÍPADOVÁ STUDIE 1:VYSOKÁ HOLE.....	34
4.1 Příprava projektu	34
4.2 Příprava dat.....	35
4.3 Programování klasifikace.....	37
4.3.1 Finální skripty klasifikace.....	39
4.4 Výstupy případové studie	45
5 PŘÍPADOVÁ STUDIE 2: VICÍNOV	46
5.1 Deep learning v ArcGIS Pro	46
5.2 Trénování modelu	47
5.2.1 Příprava trénovacích dat.....	47
5.2.2 Trénování modelu.....	48
5.3 Aplikování modelu na testovací území	49
5.4 Výstupy případové studie	49
6 PŘÍPADOVÁ STUDIE 3: KLASIFIKACE DAT LIDAR.....	50
6.1 Klasifikace dat LIDAR v ArcGIS Pro	51
6.1.1 Klasifikace třídy povrchu země (Ground)	51
6.1.2 Klasifikace šumu	52
6.1.3 Klasifikace budov	52
6.1.4 Klasifikace stromů a vysoké vegetace	53
6.2 Klasifikace dat LIDAR v programu OpenCities Map	54
6.2.1 Klasifikace třídy povrchu země	54
6.2.2 Klasifikace dat do nadzemních prvků.....	55

7	VÝSLEDKY	56
7.1	Výsledky první případové studie: Vysoká hole	56
7.1.1	Výsledky modelu 1	57
7.1.2	Výsledky modelu 2	58
7.1.3	Výsledky modelu 3	60
7.1.4	Výsledky modelu 4	62
7.1.5	Spektrální analýza tříd	65
7.2	Výsledky druhé případové studie: Vicínov	66
7.2.1	Výsledky přístupu per pixel klasifikace	67
7.2.2	Výsledky přístupu detekce objektů	69
7.3	Výsledky třetí případové studie: Klasifikace dat LIDAR.....	70
7.3.1	Výsledky klasifikace dat LIDAR v ArcGIS Pro.....	71
7.3.2	Výsledky klasifikace dat LIDAR v OpenCities Map PV	73
8	DISKUZE	76
9	ZÁVĚR	78
	POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE	
	PŘÍLOHY	

SEZNAM POUŽITÝCH ZKRATEK

Zkratka	Význam
AI	Artificial Intelligence
SVM	Support vector machines
k-NN	K-nearest neighbor
GMM	Gaussian Mixture Model
EM	Expectation-Maximization
PCA	Principal Component Analysis
ANN	Artificial neural networks
CNN	Convolutional neural network
RNN	Recurrent neural network
GPU	Graphics processing unit
DPZ	Dálkový průzkum země
LIDAR	Light Detection And Ranging
KAI	Kappa Index of Agreement
RGB	Red Green Blue
DMR	Digitální model reliéfu
DMP	Digitální model povrchu
CHKO	Chráněná krajinná oblast
LAS	LASer
GIS	Geografický informační systém
TIFF	Tagged Image File Format
CSV	Comma-Seperated Values
JSON	JavaScript Object Notation
NPR	Národní přírodní rezervace
SHP	Shapefile
ML	Machine learning
DL	Deep learning
TIN	Triangulated irregular network

ÚVOD

Vstupujeme do éry, kdy digitální data nejenže prudce narůstají, ale také se stávají stále složitějšími. Mezi tato data patří i data dálkového průzkumu země, jako jsou obrazové snímky nebo lidarová data, která jsou tvořena obrovským množstvím bodů. Tato data nacházejí své uplatnění v širokém spektru oblastí, včetně geografie, urbanismu, ekologie a mnoha průmyslových odvětví.

Tato diplomová práce se zaměřuje na zpracování těchto dat pomocí klasifikace do vybraných tříd. S rostoucím objemem dat se stává klíčovou automatizace těchto procesů pro dosažení rychlých a přesných výsledků. Práce je proto zaměřena na využití moderních metod strojového učení, které jsou vhodné pro klasifikaci těchto dat.

V rámci diplomové práce byly řešeny tři různé případové studie s cílem výběru nejvhodnějších metod a dosažení co nejlepších klasifikačních výsledků.

První případová studie se zaměřila na detailní klasifikaci horské vegetace na druhém nejvyšším vrcholu Hrubého Jeseníku, Vysoké holi. Tato studie byla motivována předchozím projektem hodnotícím stav horské vegetace, který byl řešen manuálním vyhodnocením. Cílem studie bylo dosáhnout co nejlepších výsledků pomocí automatizovaných procesů strojového učení.

Druhá případová studie se věnovala metodám hlubokého učení a možnostem jejich aplikace pro účely detekce stromů. Tato studie byla provedena na území sadu Vicínov u obce Veselíčko mimo vegetační období.

Poslední případová studie se věnovala automatizovaným možnostem klasifikace laserových dat leteckého lidarů. V rámci této studie bylo provedeno testování automatizovaných procesů v programu ArcGIS Pro a OpenCities Map PowerView.

Tato práce nabízí pohled na možnosti využití strojového učení pro klasifikaci obrazových a lidarových dat a ukazuje, jak mohou tyto metody přispět k efektivnějšímu a přesnějšímu zpracování těchto dat. Je to cesta do budoucnosti, kde stroje pomáhají lidem lépe porozumět a využívat velké množství dat, které máme k dispozici.

1 CÍLE PRÁCE

Cílem práce je stanovit optimální postup pro klasifikaci obrazových dat DPZ a dat z laserového skenování. Student na základě provedené rešerše zvolí vhodné klasifikační metody založené na strojovém učení a Deep Learning. Autor stanoví kritéria použitelnosti jednotlivých metod a vytvořený postup aplikuje na minimálně tři případové studie. Jedna ze studií bude zaměřena na obrazová data z fyzickogeografické oblasti.

Text práce student zpracuje v souladu se závaznou šablonou pro kvalifikační práce KGI. O diplomové práci student vytvoří webovou stránku a poster. Celou práci (text, přílohy, výstupy, zdrojová a vytvořená data, poster a web) odevzdá student v digitální podobě na datové úložiště katedry. Do evidence STAG student odevzdá úplný text práce s přílohami, které určí vedoucí práce. Fyzicky student odevzdá výtisk posteru ve formátu A2 a přílohy určené vedoucím práce.

2 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

Kapitola současný stav řešené problematiky má za cíl podat přehled současné literatury, týkající se tématy diplomové práce. Rešerše uvede čtenáře do problematiky metod umělé inteligence pro automatickou a poloautomatickou klasifikaci a segmentaci obrazových a laserových dat.

2.1 Umělá inteligence

Počátek vědní disciplíny umělé inteligence (*Artificial Intelligence, AI*) se obvykle datuje kolem roku 1950. (Nejedlová 2019) První zmínky o AI jsou připisovány dvěma velikánům vědy, a to Alanu Turingovi a Johnovi von Neumannovi. Právě John von Neumann byl přesvědčen, že v krátké době počítače dosáhnou a možná i překonají inteligenční schopnosti člověka. Turing se v disciplíně umělé inteligence prosadil zejména svým Turingovým testem, pomocí kterého se vědecky přesně snažil odpovědět na filozofickou otázku: „Můžou stroje myslet?“. (Nejedlová 2019; Russell a Norvig 2003)

AI má mezi vědními disciplínami poměrně specifické postavení, a to hned z několika důvodů. Prvním důvodem je, že dosud neexistuje všeobecně přijímaná definice umělé inteligence. Dále samotná teorie umělé inteligence není jednotná a spíše volně využívá teorie, techniky a metody jiných vědních oborů, které si spojuje pro úspěšné řešení složitých počítačových úloh jako rozhodování, plánování, predikce a dalších. (Volná 2013)

Umělá inteligence se s jistými zklamáními a krizemi postupně formovala jako interdisciplinární průsečík několika vědních disciplín jako jsou: psychologie, neurologie, kybernetika, teorie rozhodování, teorie her, informatika, matematiky a dalších. (Volná 2013; Russell a Norvig 2003)

Umělá inteligence se zejména v 60. a 70. letech 20. století začala využívat v mnoha oblastech. Mezi ty nejdůležitější patřila robotika, lékařská diagnostika, terapeutika a v posledních letech také počítačem řízená výroba a softwarové inženýrství. Příkladem prvního masivního využití umělé inteligence je dálkové řízení družic NASA. (Volná 2013)

Umělá inteligence je založena na existenci počítače a podle jeho funkcí a využití se dělí na slabou a silnou. *Slabá AI* využívá počítač pouze jako nástroj. Pro *silnou AI* není počítač pouhým nástrojem, ale myslící a pomocí programů chápající jednotka. (Flowers 2019)

Umělá inteligence je rozdělena na tři hlavní myšlenkové proudy: Symbolický funkcionalismus, Konekcionalismus a Robotický funkcionalismus. (Volná 2013)

Vybrané definice umělé inteligence

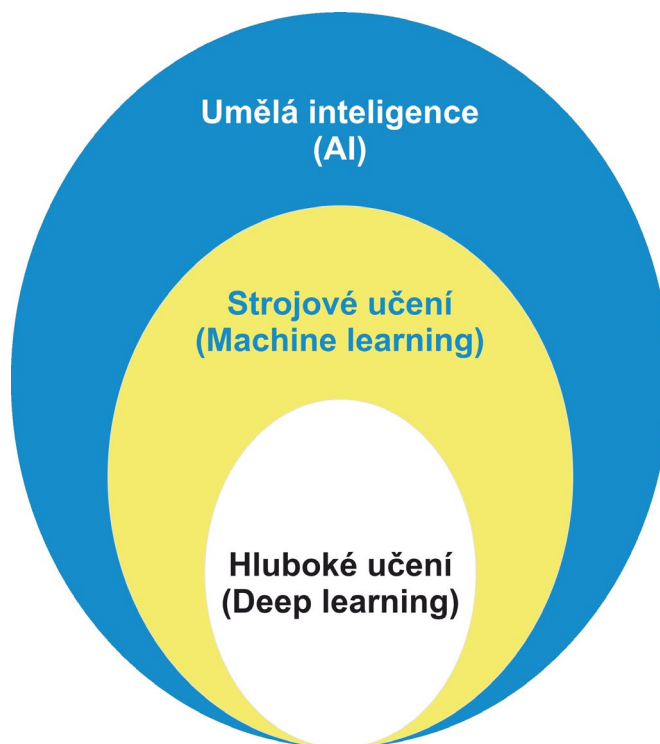
1. Definice Marvina Minského z roku 1967:

AI je věda o vytváření strojů nebo systémů, které budou při řešení určitého úkolu užívat takového postupu, kdyby ho dělal člověk, bychom považovali za projev inteligence. (Nejedlová 2019)

2. Definice Zdeňka Kotka z roku 1983:

AI je vlastnost člověkem uměle vytvořených systémů, vyznačujících se schopností rozpoznávat předměty, jevy a situace, analyzovat, vztahy mezi nimi, a tak přijímat účelná rozhodnutí, za pomoci schopností předvídat důsledky těchto rozhodnutí a objevovat nové zákonitosti mezi různými modely nebo jejich skupinami. (Nejedlová 2019)

V dnešní době se AI stále více začleňuje do analýzy dat a řešení problémů v různých odvětvích a oborech. Systémy jsou učeny provádět úkoly s hlavním cílem zvýšení efektivity, přesnosti a omezení manuálního vstupu zdrojů. Umělá inteligence zahrnuje podtyp nazývaný se strojové učení (machine learning), které je dále děleno na podtyp hlubokého učení (deep learning). (Nejedlová 2019; Volná 2013)



Obr. 1 Diagram podoblastí umělé inteligence

Každý podtyp AI je definován rostoucí úrovní složitosti a autonomie. Strojové i hluboké učení nicméně slouží ke stejnému účelu, analýze velkého množství informací, na jehož základě předpovídají výsledky. (Volná 2013)

2.1.1 Strojové učení (Machine learning)

Strojové učení je podoblast umělé inteligence zabývající se možnostmi, pomocí kterých se počítačový systém dokáže sám učit interpretovat informace na základě vstupů daných modelů. Učení v tomto případě znamená schopnost systému přizpůsobovat se okolnímu prostředí a vnějším vlivům. Strojové učení se velmi úzce prolíná se statistikou a data miningem. Modely strojového učení vyžadují zapojení člověka, který spravuje a případně na základě výsledků upravuje vstupy modelu. (Honzík 2006; Matoušek 2023)

Algoritmy strojového učení lze rozdělit do několika kategorií podle způsobu učení:


- a. Řízené učení
- b. Neřízené učení
- c. Kombinace řízeného a neřízeného učení
- d. Zpětnovazební učení

a. Řízené učení


Řízení učení nebo také nazývané učení s učitelem, v informatice známé jako strojové učení s učitelem (supervised machine learning), je paradigmatem ve strojovém učení. Je definováno používáním označených trénovacích souborů dat (datasets) sloužících ke klasifikaci nebo predikci výsledků. Během vstupu dat do modelu jsou v iteracích upravovány váhy tohoto modelu, dokud není model vhodně přizpůsoben. Tento proces se nazývá křížová validace. Trénovací data se skládají ze vstupních dat a odpovídajících výstupních hodnot (proto „učení s učitelem“), na základě jejichž vztahu se model učí přesně předpovídat interpretaci dosud nezjištěných nových dat (testovaných dat). Vstupní data modelů jsou tedy rozdělena na trénovací data a testovací data. (IBM 2023e; Lindholm et al. 2019)

Při využití modelů a metod strojového učení může dojít k takzvanému přeučení modelu (overfitting). Jedná se o stav, kdy je model příliš přizpůsoben množině trénovacích dat a přesnost predikce je pro data trénovací a testovací odlišná. Takováto situace může nastat například při malém rozsahu trénovací množiny. (IBM 2023e; Lindholm et al. 2019)

Trénovací data



Validační data




Trénování modelu




Predikce



Výsledek predikce



Testovací data




Obr. 2 Znázornění fungování metod řízeného učení

V procesech strojového učení s učitelem se používají různé algoritmy a výpočetní techniky. Mezi nejpoužívanější patří: Neuronové sítě, Naive bayes, Lineární regrese, Logistická regrese, Support vector machines (SVM), K-nearest neighbor a Random forest. Obvykle je jejich výpočet prováděn pomocí programovacích jazyků R nebo Pythonu. (IBM 2023e)

Neuronové sítě (Neural networks)

Neuronové sítě jsou primárně používány pro algoritmy hlubokého učení (viz kapitola 2.1.2). Jsou konstruovány na základě propojení lidského mozku – vrstvy uzlů. Toto propojení je napodobeno i pro zpracování trénovacích dat. Uzly se skládají ze vstupů, vah, případně zkreslení, prahu a výstupu. Pokud výstupní hodnota překročí daný práh, dojde k aktivování uzlu a předání dat do další vrstvy neuronové sítě. Úpravy funkcí jsou zprostředkovány učěním s učitelem, a to na základě tzv. účelové funkce a procesu gradientního sestupu. (IBM 2023e; Petr 2014; Aggarwal 2018)



Obr. 3 Digram vrstev neuronové sítě (IBM 2023a)

Naivní Bayesovský klasifikátor (Naive bayes)

Jedná se o klasifikační přístup, který využívá Bayesovského teorému a jeho podmíněné nezávislosti tříd z Bayesovy věty. Podmíněná nezávislost znamená, že přítomnost jednoho znaku nemá vliv na přítomnost jiného znaku v pravděpodobnosti daného výsledku a zároveň každý prediktor má na tento výsledek stejný vliv. Existují tři typy: Multinomiální, Bernoulliho, Gaussovský. Tato technika je využívána zejména v klasifikaci textu a identifikaci spamu. (IBM 2023e; Scikit-learn developers 2023; Turing 2023)

Lineární regrese (Linear regression)


Je používána k určení vztahu mezi závislou a jednou nebo více nezávislými proměnnými. Existuje-li pouze jedna nezávisle proměnná a jedna závisle proměnná, jedná se o jednoduchou lineární regresi. S vyšším počtem nezávisle proměnných se jedná o vícenásobnou regresi. Pro každý typ lineární regrese je souborem dat proložena přímka nejlepší shody. Obvykle se využívá k předpovědi budoucích výsledků a studiu závislosti dvou a více proměnných. (IBM 2023b; norway grants 2023; Petr 2014)

Logistická regrese (Logistic regression)

Lineární regrese je používána v případě, kdy jsou závisle proměnné spojité. Logistická se volí, když je závisle proměnná kategoriální, což znamená, že má binární výstupy (ano/ne, pravda/nepravda). Logistická regrese je využívána zejména při binárních klasifikačních úlohách, jako je například identifikace spamu. (Meloun 2007; Petr 2014; IBM 2023c)

Metoda podpůrných vektorů (Support vector machines – SVM)

Populární model používaný zejména pro klasifikaci a regresi dat. Při klasifikačních úlohách je množina prvků co neoptimálněji rozdělena nadrovinou (rozhodovací hranicí) vytvářející třídy ležící v opačných poloprostorech. (IBM 2023e) Důležitou součástí SVM je jádrová funkce (transformace), která slouží pro nalezení optimální nadroviny. Metoda je efektivní v multidimenzionálních prostorech, i v prostorech, kde je více dimenzí než dostupných vzorků. (Gandhi 2018; Scikit-learn developers 2024a)



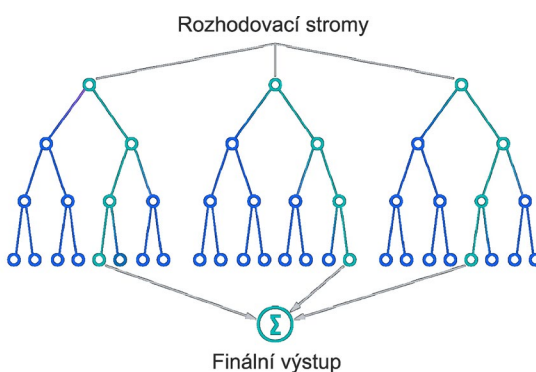
Obr. 4 Princip fungování algoritmu SVM (Gandhi 2018)

K-nejbližších sousedů (K-nearest neighbor)

Algoritmus, také známý pod zkratkou KNN nebo k-NN, je neparametrický algoritmus, sloužící pro klasifikaci a predikce datových prvků, na základě jejich blízkosti a asociace s ostatními datovými prvky. Algoritmus předpokládá, že podobné datové prvky lze nalézt blízko sebe. Algoritmus tedy počítá vzdálenosti mezi prvky (nejčastěji euklidovská vzdálenost), na základě kterých následně přiřazuje třídu. Přiřazení kategorií je obvykle podle nejčastěji se vyskytující kategorie v okolí nebo průměru. KNN je používán pro doporučovací systémy a rozpoznávání obrazu. (IBM 2023f; 2023e)

Random forest

Flexibilní algoritmus pro účely klasifikace a regrese. Jedná se o soubor nekorelovaných rozhodovacích stromů, které jsou následně sloučeny dohromady. Sloučení je z důvodu snížení rozptylu, přesnějších předpovědí a dosažení jednoho finálního výsledku. (Petr 2014; IBM 2023d)



Obr. 5 Random forest a rozhodovací stromy (IBM 2023d)

b. Neřízené učení

Neboli také strojové učení bez učitele využívá algoritmy strojového učení k analýze a shlukování souborů neoznačených dat. Algoritmy odhalují skryté vzory nebo seskupení dat bez nutnosti lidského zásahu. Jedná se o modely, které se neřídí pomocí trénovacího souboru dat a používají se v případech, kdy nemáme k dispozici správné odpovědi nebo neznáme předem výsledky. Díky schopnosti odhalovat podobnosti a rozdíly jsou ideální pro exploratorní analýzy dat, segmentaci nebo rozpoznávání obrazu.

Typicky se tyto metody snaží naučit strukturu, na níž jsou data založena. Například při vizualizaci by byly podobné položky umístěny blízko sebe a odlišné položky dál od sebe. Data používáme k identifikaci skupin prvků navzájem podobných a zároveň lišících se od ostatních prvků množiny. (Šarmanová 2012; Wu 2022)

Přístupy učení bez učitele: Shlukování, Asociační analýza a Redukce dimenzí. (IBM 2024c)


Shlukování (Clustering)

Shlukování je technika data miningu, která shlukuje data na základě jejich podobnosti nebo rozdílu. Shlukovací algoritmy jsou děleny na několik typů: exkluzivní a překrývající se, hierarchické a pravděpodobnostní. (Šarmanová 2012)

Exkluzivní metoda shlukování znamená, že jeden datový prvek může existovat pouze v jednom shluku. Příkladem je algoritmus K-means. K představuje počet shluků. Shluky jsou určovány na základě vzdálenosti od centroidu každé skupiny. Algoritmus K-means se běžně používá pro segmentaci a komprese obrazu.

Překrývající se shluky se liší tím, že některé datové prvky mohou být zařazeny do více shluků zároveň. Příkladem může být algoritmus soft/fuzzy K-means shlukování. (IBM 2024c)

Hierarchická shluková analýza je neřízený shlukovací algoritmus, který lze dále dělit na dva způsoby, a to aglomerativní a divizní. U aglomerativního přístupu dochází k iterativnímu spojování menších shluků na základě podobnosti až po dosažení jednoho shluku. Tento přístup je také označován jako „od spoda nahoru“. Podobnost je hodnocena nejčastěji těmito metodami: Wardova metoda, nejbližšího souseda, nejvzdálenějšího souseda, průměrné vazby a centroidová metoda. Divizní metoda je definována jako opačný přístup. Jeden shluk prvků je rozdělován na základě rozdílu mezi jednotlivými prvky. Divizní shlukování není často využíváno a pokud ano, tak je vizualizováno pomocí dendrogramu – diagram podobný stromu, který zaznamenává slučování nebo rozdělení prvků v každé iteraci. (Institut biostatistiky a analýz Lékařské fakulty Masarykovy Univerzity 2024)



Obr. 6 Hierarchické shlukování (IBM 2024c)

Pravděpodobnostní shluková analýza řeší problémy odhadu hustoty. Datové body jsou spojovány na základě pravděpodobnosti, s jakou patří do určitého rozdělení. Nejčastěji používanou metodou je GMM (Gaussian Mixture Model). Jedná se o přístup založený na směsných modelech skládajících se z neurčeného počtu funkcí rozdělení pravděpodobnosti. GMM jsou využívány především k určení, ke kterému Gaussovu nebo normálnímu rozdělení pravděpodobnosti daný prvek patří. V případě GMM nejsou známy proměnné jako rozptyl a střední hodnota, tudíž je pro určení rozdělení nutné použít latentní nebo skrytou proměnnou. K odhadu pravděpodobnosti přiřazení daného prvku k určitému shluku je také používán EM algoritmus (Expectation-Maximization), jeho použití ale není nutné. Mixture Model má s vysokou pravděpodobností tyto vlastnosti:

- Rozdělení má vysoké vrcholy (data v shluku jsou si velmi blízka)
- Zachycuje dominantní vzory velmi dobře (Mishra 2017)


Asociační analýza (Association Rules)

Metoda založená na pravidlech sloužících pro hledání vztahů mezi proměnnými v daném souboru dat. Tyto metody jsou nejčastěji používány pro analýzy trhu, který umožňuje lépe pochopit vztahy mezi různými produkty a spotřebními zvyklostmi zákazníků. Příkladem může být: „Zákazníci si také prohlíželi/Zákazníci také zakoupili...“. Algoritmů pro Asociační pravidla je více, nejpoužívanějším je algoritmus *Apriori*. (Lutkevich 2023)

Redukce dimenzionality (Dimensionality reduction)

Velké množství vstupních dat obvykle přináší přesnější výsledky. Může také ale ovlivnit výkonnost algoritmů strojového učení (overfitting). Redukce dimenzionality je technika používaná v případě, že počet prvků nebo dimenzí v daném datovém souboru je příliš velký. Algoritmy snižují počet vstupů a zároveň zachovává integritu datové sady. Redukce dimenzionality se běžně používá ve fázi předzpracování dat a existuje několik metod. (IBM 2024c)

Principal Component Analysis (PCA) neboli *Analýza hlavních komponent* je algoritmus pro zhodnocení vícerozměrných dat. Pokud proměnné navzájem korelují, je obtížné zjistit, jaké informace vlastně reálně získáváme. Cílem je nahrazení velkého počtu proměnných menším počtem, které budou nekorelované a ideálně budou interpretovatelné. Nově vzniklé proměnné jsou nazývány hlavní komponenty. Podmínkou použití je dostatečně silná korelace mezi proměnným.



Obr. 7 Redukce dimenzionality pomocí PCA (Dobešová 2023)

Singular value decomposition neboli *Singulární rozklad* je další přístup ke snížení dimenzionality a je jeden z nejdůležitějších teoretických i praktických nástrojů maticových výpočtů. Algoritmus faktorizuje matici A na tři matice nižšího řádu. Tak jako PCA se běžně používá k redukci šumu, proměnných a kompresi dat, například obrazových souborů. (Šarmanová 2012; Ambrožová 2016; IBM 2024c)

Autoencoders neboli *Vícevrstvý perceptron* je speciálním typem neuronových sítí, který slouží ke kopírování vstupů na výstupy. Dochází ke komprimaci dat a následně znovu vytváření vstupních dat. Proces je rozdělen na tři vrstvy, kdy přechod mezi první a druhou vrstvou je nazýván kódování, mezi druhou a třetí dekódování. Velmi důležitou podmínkou je dostatečně silná korelace mezi vstupními rysy (proměnnými).

Mezi další metody neřízeného učení můžeme zařadit generativní modelování, které se v posledních letech stalo jedním z předních přístupů. (Jordan 2018)

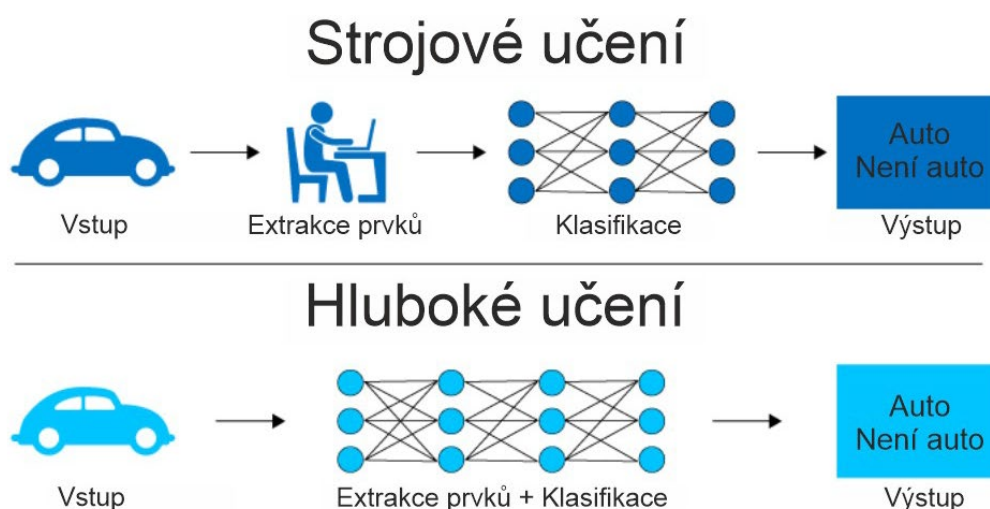
2.1.2 Hluboké učení (Deep learning)

Hluboké učení je podmnožinou strojového učení zabývající se zejména umělými neuronovými sítěmi – ANN (artificial neural networks). V kontextu historie se hluboké učení datuje až do 40. let 20. století a jeho vývoj je možné rozdělit do tří vln. V první vlně (40. až 60. léta 20. století) bylo hluboké učení známé pod názvem *kybernetika*. Druhá vlna, v období 1980 až 1990, byla známá pod názvem *konekcionismus*. Poslední vlna trvající až do dnes začala v roce 2006 pod nynějším názvem *Hluboké učení (Deep learning)*. (IBM 2024b)

Hluboké učení v dnešní době poskytuje velmi výkonné frameworky pro řízené učení, vhodné i pro problémy s rostoucí složitostí.

Umělé neuronové sítě se snaží napodobovat chování lidského mozku a simulovat proces učení z velkého množství dat. Umělé neuronové sítě lze mít jednovrstvé nebo také vícevrstvé. (AWS 2024)

Hluboké učení se od strojového učení liší zejména typem dat a metodami, které se učí tato data zpracovávat. Hluboké učení nevyžaduje některé fáze přípravy dat a je vhodné pro zpracování nestructurovaných dat, jako jsou texty a obrázky. Algoritmy dokážou automaticky rozeznat důležité rysy, pro které by bylo v případě strojového učení zapotřebí vstupu člověka s expertízou v daném oboru. (Sperling 2018; Aggarwal 2018)



Obr. 8 Rozdíl mezi strojovým a hlubokým učení (Sperling 2018)

Jak již bylo zmíněno, hluboké učení si zakládá na umělých neuronových sítích snažících se napodobit lidský mozek. Do neuronové sítě vstupují data, váhy a zkreslení a společně jsou využívány pro rozpoznání, klasifikace a další úlohy. Hluboké neuronové sítě se skládají z několika vrstev, které jsou vzájemně propojeny. Každá vrstva navazuje na předchozí a snaží se zpřesnit výsledky předpovědi a klasifikací. Tato posloupnost operací se nazývá dopředné šíření. Vstupní a výstupní vrstvy jsou nazývány viditelné vrstvy, ostatní jsou skryté. Výstupní vrstva je ta, kde jsou prováděny konečné předpovědi a klasifikace. (IBM 2024b)

Druhým procesem je zpětné šíření, které slouží k výpočtu chyb modelu a úpravě vah a parametrů. Tímto procesem se algoritmus postupně zpřesňuje.

Algoritmy hlubokého učení jsou nicméně extrémně složité. Existuje velkého množství jejich aplikací a různé typy neuronových sítí pro konkrétní problémy.

Mezi základní dva typy neuronových sítí patří konvoluční neuronové sítě (CNN) a rekurentní neuronové sítě (RNN). Konvoluční neuronové sítě jsou využívány především pro klasifikaci obrazu. Dokáží detekovat rysy a vzory v obraze, což je umožňuje využít pro detekci a rozpoznávání objektů. RNN jsou využívány zejména pro rozpoznávání řeči. (Aggarwal 2018)

Konvoluční neuronové sítě (CNN)

Typ umělých neuronových sítí vhodných pro rozpoznávání, klasifikace a další úlohy, probíhající nad obrazovými daty. Před konvolučními neuronovými sítěmi byla identifikace objektů na obrazových daty prováděna manuálně, což bylo časově velmi náročné. CNN jsou velmi škálovatelné a vhodné pro identifikace vzorů, což tyto úlohy může velmi urychlit. Pro identifikace jsou využity metody násobení matic a lineární algebry (operace konvoluce). Nicméně i tento proces může být výpočetně velmi náročný a může vyžadovat výkonné grafické karty (GPU). (Saha 2018)


CNN se od ostatních typů umělých neuronových sítí odlišují zejména výbornou schopností zpracovávat obrazová data, a to extrakce rysů a identifikace vzorů. Sítě CNN využívají řadu vrstev, kdy každá detekuje různé vlastnosti vstupního obrazu. Dle rozsahu se může CNN skládat z desítek až tisíců vrstev, kdy každá vrstva vychází z výstupů předchozích vrstev. (IBM 2024a)

Sít se dělí na tři základní typy vrstev:

- Konvoluční vrstva
- Pooling vrstva
- Plně propojená vrstva (Fully connected, FC)

Konvoluční vrstva

Konvoluční vrstva je první vrstvou CNN a jejím základním stavebním prvkem. Konvolučních vrstev může být několik za sebou. Probíhá v ní většina výpočtů. Do této vrstvy vstupují vstupní data, filtr a mapa rysů (příznaků). Ve většině případů bude do sítě vstupovat barvený obrázek, který je tvořen maticí pixelů. To znamená, že vstup bude mít 3 rozměry: výšku, šířku a hloubku. Dalším důležitým prvkem je jádro, které se pohybuje nad obrazem a kontroluje, zda se požadovaný rys nebo prvek v oblasti vyskytuje. Výsledkem této operace je mapa rysů. Tato mapa pak slouží jako vstup pro další vrstvu. Velikost jádra je většinou matice o rozměrech 3x3 nebo 5x5. Jádro iterativně krok po kroku projde a zkontroluje přítomnost hledaných prvků v celém obrazu. Tento proces kontroly je nazýván konvoluce. V CNN je tímto způsobem vytvářena hierarchická reprezentace obrazu. (Saha 2018)



Obr. 9 Pohyblivé filtrovací jádro (Pilát 2024)

Konvoluční vrstva a filtrovací jádro mají tři základní parametry:

- Počet filtrů – ovlivňuje hloubku výstupu (tři filtry vytvoří hloubku tři)
- Stride – vzdálenost o kolik pixelů se pohybuje jádro nad obrazem (čím vyšší, tím je menší výstup)
- Zero-padding – pokud filtrační jádro neodpovídá vstupujícímu obrazu

Konvoluční vrstvu může následovat další konvoluční vrstva. Pokud nastane taková situace, CNN se tím stává hierarchickou. Jednotlivé vrstvy se tak mohou učit i od sebe v hierarchii a kontrolovat předešle nalezené vzory. Počáteční filtry obvykle detekují základní rysy jako jsou čáry. Filtry následujících vrstev jsou složitější a kombinují dříve zjištěné základní rysy a rozpoznávají složitější vzory. (Craig 2024; Pilát 2024)



Obr. 10 Hierarchické učení vzorů vrstvami CNN (IBM 2024a)

Pooling vrstva

Poolingová vrstva, také známá pod pojmem downsampling (převzorkování), provádí redukci dimenzionality a tím snižuje počet parametrů na vstupu. Stejně jako u konvoluční vrstvy jádro filtru prochází celý obraz s jediným rozdílem, že filtr neobsahuje žádné váhy. Jádro místo toho nese agregační funkci, kterou aplikuje na hodnoty obrazu a vyplňuje nové hodnoty výstupního pole. Existují dva hlavní typy poolingů:

- Max pooling:
 - Pohybující se filtr nad vstupními daty vybírá pixely s nejvyšší hodnotou a zapisuje je do pole výstupu
 - Metoda využívaná ve většině případů
- Average pooling:
 - Pohybující filtr nad vstupem vypočítá průměrnou hodnotu z pixelů pohyblivého okna a zapisuje je do výstupního pole

Poolingová vrstva pro CNN přináší řadu výhod. Při učení pomáhá k redukci složitosti, zvyšuje efektivitu a snižuje riziko nadměrného přizpůsobení (overfitting) vstupnímu datasetu. Nicméně je při tomto kroku ztraceno velké množství informací. (IBM 2024a)

Plně propojená vrstva

Hodnoty pixelů předešlých dvou vrstev nejsou přímo propojeny s výstupní vrstvou. V plně propojené vrstvě je však každý uzel výstupní vrstvy přímo propojen s uzlem předchozí vrstvy a jejich filtrů. Toto spojení pomáhá k přenášení informací ze vstupu do výstupních uzlů. Pro každou vrstvu je předem nutné definovat rozměr vstupu a výstupu.


Plně propojená vrstva používá softmax aktivační funkci pro klasifikaci vstupů a vytvoření pravděpodobnosti od 0 do 1. (Zacha 2019)

2.2 Klasifikace obrazu

Klasifikace je v DPZ (dálkový průzkum země) široké a důležité téma. Běžně do klasifikace vstupují obrazová data, nejčastěji multispektrální nebo hyperspektrální. V poslední době jsou ale obrazová data kombinována s daty laserovými – LIDAR daty (Light Detection And Ranging). Obecně v klasifikaci jde o seskupování vzájemně si podobných prvků do určitých skupin nazývaných třídy. (Zemek 2014)

Jedná se o operace, umožňující identifikovat společné vlastnosti a podle nich prvky ze souboru seskupovat. Entity na nejnižší úrovni v obrazových datech jsou pixely. Při klasifikaci dochází k zařazování jednotlivých pixelů do tříd a vzniká tak klasifikovaný snímek. Originální záznam se tak stává tematickou mapou. (Zemek 2014; Lillesand, M. 2015)

Pro rozpoznávání, do jaké třídy prvek patří, se používá příznakový prostor. Pomocí euklidovské vzdálenosti měříme vzdálenost mezi hodnotami jednotlivých pixelů a centry předpokládaných shluků. Čím blíže se v prostoru body nacházejí, tím podobnější si jsou. (Ústav geoinformačních technologií Lesnická a dřevařská fakulta MENDELU 2023; Lillesand, M. 2015)



Obr. 11 Příznakový prostor (Lillesand, M. 2015)

Klasifikační metody jsou rozdělovány do dvou základních skupin, a to klasifikace per-pixel a objektově orientované klasifikace.

Per-pixel klasifikace

Per-pixel klasifikace zpracovává hodnoty každého pixelu samostatně. Hlavními vlastnostmi pixelu jsou poloha, velikost a hodnota. Na základě těchto vlastností přiřazuje jednotlivé pixely do informačních tříd.

Per-pixel klasifikace je také nazývána bodová spektrální klasifikace. Je to nejpodrobněji rozpracovaná a nejčastěji používaná klasifikační technika. Mezi hlavní metody patří:

- Neřízená klasifikace (Unsupervised classification)
- Řízená klasifikace (Supervised classification)

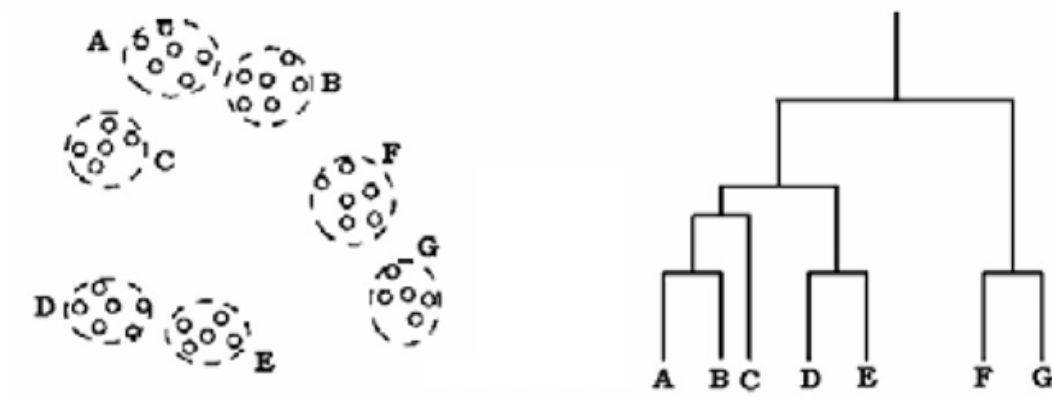
(Zemek 2014; Ústav geoinformačních technologií Lesnická a dřevařská fakulta MENDELU 2023)

Neřízená klasifikace

Metoda, která identifikuje přirozené skupiny nebo struktury z příznakového prostoru. Touto metodou jsou extrahovány dominantní obrazce spektrální odrazivosti (spektrální třídy) za využití shlukových analýz. Význam informačních tříd se zjišťuje až po samotné klasifikaci ve fázi interpretace. To znamená, že se na začátku nevytvářejí trénovací množiny podle klasifikačních tříd, ale jsou určeny spektrální třídy, kterým je následně přiřazována informace. Vymezení odlišných skupin je provedeno pomocí shlukové analýzy. Metody shlukové analýzy se dělí na dva typy a to:

- Hierarchické – aglomerační metoda postupně spojuje jednotlivé pixely do shluků, rozkladová metoda vstupní soubor postupně dělí do více skupin
- Nehierarchické – hledají optimální rozklad podle zvoleného kritéria a využívají iterační metody

(Lillesand, M. 2015)




Obr. 12 Neřízená klasifikace – shluková analýza (Lillesand, M. 2015)

Pro shlukovou analýzu jsou využívány zejména dva algoritmy a to K-means a ISODATA. Algoritmy předpokládají, že známe přibližný počet shluků, do kterých vstupní soubor budeme rozdělovat. Výpočty začínají s náhodnými shluky (algoritmus ISODATA rozděluje středy shluků po diagonále příznakového prostoru), které se následně přesouvají tak, aby minimalizovali variabilitu ve shluku a maximalizovali variabilitu mezi jednotlivými shluky. Prvotní odhad počtu shluků je možné provést selekcí vrcholů z histogramu.

Neřízenou klasifikaci je vhodné použít pouze v případech, kdy nehledáme předem známé informační třídy. To činí její největší nevýhodou. Neřízená klasifikace je také výpočetně a časově náročná. Je jí ale možné využít jako tematickou mapu s předběžnými výsledky před provedením řízení klasifikace. (Lillesand, M. 2015; Campbell, James a Wynne, Randolph 2011)

Řízená klasifikace

Obrazový soubor je rozdělen do předem připravených a stanovených tematických tříd. Tyto třídy mohou být vytvořeny jako finální nebo dále při finalizování slučovány podle potřeby a požadavků. Při procesu klasifikace jsou vssyuzívány předem připravené a získané reprezentativní vzorky nacházejí se v zájmovém území, které lze jednoznačně identifikovat ve vstupujícím obrazu. Tyto vzorky se obvykle nazývají trénovací plochy (množiny). Z trénovacích množin jsou odvozeny statistické charakteristiky (spektrální signatury), na jejichž základě jsou jednotlivé pixely přiřazovány do tematických tříd. Pro proces klasifikace jsou používány soubory operací, tzv. klasifikátory. (Lillesand, M. 2015)



Obr. 13 Řízená klasifikace (Zemek 2014)

Klasifikátory se dělí na tvrdé a měkké. Tvrdé klasifikátory jednoznačně definují rozhodnutí o přiřazení jednotlivých pixelů do tematických tříd. Měkké klasifikátory pracují s pravděpodobností, se kterou pixel do dané třídy náleží. Tyto klasifikátory se využívají ke zjištění smíšených pixelů, které by mohly náležet do více tříd zároveň. Výstupem měkkého klasifikátoru je několik rastrových souborů vyjadřujících pravděpodobnost příslušnosti. Jednotlivé třídy jsou zpracovávány odděleně. (Zemek 2014)

Proces řízené klasifikace je tvořen několika kroky:

1. Nejdříve dojde k definování trénovacích ploch na základě tematických (informačních) tříd.
2. Trénovacím plochám jsou vypočítány statistické charakteristiky, které charakterizují jednotlivé třídy.
3. Jsou vybrána vhodná pásma (pokud jsou k dispozici).
4. Jsou vybrána rozhodovací pravidla klasifikátoru pro přiřazení pixelů do tříd.
5. Hodnocení, interpretace a prezentace výsledků.

Samotná etapa klasifikace je primárně ovlivněna výběrem rozhodovacích pravidel klasifikátoru – metodami řízené klasifikace. Mezi nejčastěji užívané metody patří:

- Klasifikátor minimální vzdálenosti
- Klasifikátor K nejbližších sousedů
- Klasifikátor maximální pravděpodobnosti
- Bayesův klasifikátor

Objektově orientovaná klasifikace

Objektově orientovaný přístup využívá statistické informace pixelů a prostorové uspořádání prvků v obraze. Snaží se tedy určit strukturu i kontext.

Tento přístup je zahájen procesem segmentace obrazu, kdy jsou vytvářena takzvaná objektová primitiva (segmenty) – souvislé skupiny pixelů, které jsou relativně homogenní a s relativně velkým kontrastem oproti okolním pixelům. Tyto skupiny se také vyznačují podobností v dalších vlastnostech. Je to tvar, velikost a textura.

Následně je provedena klasifikace a přiřazení segmentů do informačních tříd. Při klasifikaci je možné využít číselné charakteristiky jako je směrodatná odchylka, průměrné hodnoty veličin a také jejich tvarové charakteristiky.


Takovýto přístup klasifikace lépe odpovídá lidskému myšlení a rozšiřuje možnosti klasifikace. (Zemek 2014; Lillesand, M. 2015)

2.2.1 Postklasifikační úpravy a hodnocení

Postklasifikační úpravy

Hlavní metodou úprav klasifikovaných výstupů bodových klasifikátorů jsou nízkofrekvenční filtrace. Tyto filtry shlazují výsledky pomocí modální filtrace (pro shlazení je využíván modus) nebo Sieve filtru, který pomocí síta odstraňuje plošky určité velikosti. Pro úpravy se využívá také vektorizace a generalizace tvarů pomocí matematické morfologie.

(Ústav geoinformačních technologií Lesnická a dřevařská fakulta MENDELU 2023)



Obr. 14 Nízkofrekvenční filtrace (Ústav geoinformačních technologií Lesnická a dřevařská fakulta MENDELU 2023)

Hodnocení přesnosti klasifikace

Přesnost klasifikace se nejčastěji hodnotí pomocí klasifikační chybové matice (confusion matrix). Tato matice vyjadřuje vztah referenčních dat skutečnosti a výsledků klasifikace a hodnotí, jak se od sebe liší. Jedná se o čtvercovou matici $n \times n$, kdy n je počet informačních tříd. Hodnoty matice vyjadřují počet pixelů v dané třídě. Ve sloupcích jsou zpravidla zapsány hodnoty klasifikace, v řádcích referenční hodnoty. Vyhodnocení je velmi jednoduché – počty pixelů (procenta) mimo hlavní diagonálu reprezentují chyby v klasifikaci. Je zde jednoduše možné vyčíst, zda klasifikátor data nezpracovává chybně pouze v jedné třídě a podobně. Chybová matice se obvykle počítá z dat trénovacích ploch. Proto se trénovací data mohou někdy dále dělit na trénovací (k trénování klasifikátoru) a validační. Toto dělení ale není zcela nutné.

Pro hodnocení se dále používají tyto charakteristiky přesnosti:

- Omyl z opomenutí (omission error) OO
- Omyl z nesprávného zařazení (commission error) OP
- Přesnost zpracovatele (producer's accuracy) PZ
- Přesnost uživatele (user's accuracy) PU
- Celková přesnost klasifikace (overall classification accuracy) PK

Další charakteristikou hodnocení přesnosti je Kappa koeficient KAI (Kappa Index of Agreement). Tento index porovnává výsledek klasifikace s klasifikací náhodnou. (Lillesand, M. 2015; Ústav geoinformačních technologií Lesnická a dřevařská fakulta MENDELU 2023)

Mezi další velmi často používané metriky hodnotící klasifikační modely patří: accuracy, precision, recall a f1-score.

- Accuracy (Přesnost) je metrika měřící poměr správně klasifikovaných případů vůči celkovému počtu případů:

$$Accuracy = \frac{\text{Počet správně klasifikovaných případů}}{\text{Celkový počet případů}}$$

- Precision (Preciznost/Přesnost) je metrika měřící poměr správně klasifikovaných pozitivních případů vůči celkovému počtu případů, které byly klasifikovány jako pozitivní:

$$Precision = \frac{\text{Počet správně klasifikovaných pozitivních případů}}{\text{Počet případů klasifikovaných jako pozitivní}}$$

- Recall (Úplnost) je metrika určující poměr správně klasifikovaných pozitivních případů vůči celkovému počtu skutečně pozitivních případů:

$$Recall = \frac{\text{Počet správně klasifikovaných pozitivních případů}}{\text{Celkový počet skutečně pozitivních případů}}$$

- F1-score je harmonickým průměrem přesnosti a úplnosti:

$$f1\text{-score} = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

3 METODY A POSTUP ZPRACOVÁNÍ

Kapitola představuje metody použité při zpracování praktické části diplomové práce. Dále se věnuje popisu použitých dat, programů, programovacích jazyků a knihoven. Je ukončena postupem zobrazujícím návaznost kroků.

3.1 Použité metody

Diplomová práce byla zahájena podrobným studiem odborné literatury, která byla zaměřena zejména na umělou inteligenci, strojové a hluboké učení a klasifikace v DPZ.

V samotné praktické části diplomové práce lze metody rozdělit do několika kategorií: metody využitě při přípravě a zpracování dat, metody klasifikační, metody postklasifikační a evaluační.

3.1.1 Příprava a zpracování dat

Pro přípravu a zpracování dat bylo využito několik metod. V první řadě byla nutná rasterizace manuálně klasifikovaných dat. *Rasterizace* v kontextu vektorové grafiky je proces, při kterém se vektorový obraz složený z přesně definovaných tvarů a křivek převede na rastrový obrázek tvořený maticí pixelů. (Bada 2018)

Dalším krokem zpracování dat bylo převzorkování rastrových dat a zarovnání rastru manuální klasifikace s referenčním RGB (red green blue) rastrem. *Převzorkování* je metoda využívána pro změny rozměru. Tento proces je prováděn zmenšením nebo zvětšením pixelů. Převzorkování na vyšší rozlišení zvyšuje počet pixelů v obraze a zdánlivě zpřesňuje a zostřuje původní obraz. Převzorkování na nižší rozlišení snižuje objem dat, ale také kvalitu obrazu. (Plánka 2024)

Výšková data – DMR (digitální model reliéfu) a DMP (digitální model povrchu) byla vytvořena interpolací z bodových mračen. *Interpolace* je matematická metoda umožňující odhad hodnot mezi dvěma a více známými hodnotami. V kontextu digitálních výškových modelů (DMR a DMP) se interpolace využívá k vytvoření spojitého povrchu z diskretních bodů s naměřenými výškami. Interpolace tedy umožňuje vytvořit celistvý model terénu, který pokrývá celou oblast zájmu, a to i v místech, kde nejsou k dispozici přímá měření. Přesnost modelu závisí na kvalitě vstupních dat a na zvolené interpolační metodě. (Bek 2015)

Pro zpracování výškových dat bylo využito jednoduchých metod rastrové algebry: odčítání hodnot rastrů pro výpočet rozdílového rastru a relativních výšek objektů na povrchu. Rastrová algebra je sada operací, které je možné provádět nad rastrovými daty. Tyto operace mohou být jednoduché jako je sčítání a odčítání nebo také složitější nad určitým okolím. Rastrová algebra je klíčovou součástí analýzy geoprostorových dat. (Klufová 2020)

3.1.2 Klasifikace

Hlavním úkolem diplomové práce je klasifikace obrazových a lidarových dat dálkového průzkumu země. *Klasifikace* je proces, při kterém dochází k zařazení jednotlivých pixelů obrazového záznamu nebo bodů do klasifikačních tříd, čímž vzniká klasifikovaný snímek nebo mračno bodů. Originální záznam se tímto způsobem stává tematickým výstupem. Cílem digitální klasifikace je získat utříděný soubor prvků nesoucích informace o povrchu země. Klasifikace je dělena na základě způsobu učení na *řízenou* a *neřízenou klasifikaci*. V kontextu obrazových dat (vstupem je rastr) je možné klasifikaci dále dělit na základě jednotek, které jsou nejmenším vstupem klasifikace.

Pokud je vstupem nejmenší prvek obrazu – pixel, jedná se o metodu *per pixel*. V druhém případě je vstupní obraz nejprve rozdělen do takzvaných objektových primitiv (segmentů) – souvislé a relativně homogenní skupiny pixelů, následně vstupujících základních prvků do procesu klasifikace. Tato metoda se nazývá *objektově orientovaná klasifikace*. (Zemek 2014; Lillesand, M. 2015)

3.1.3 Postklasifikační a evaluační metody

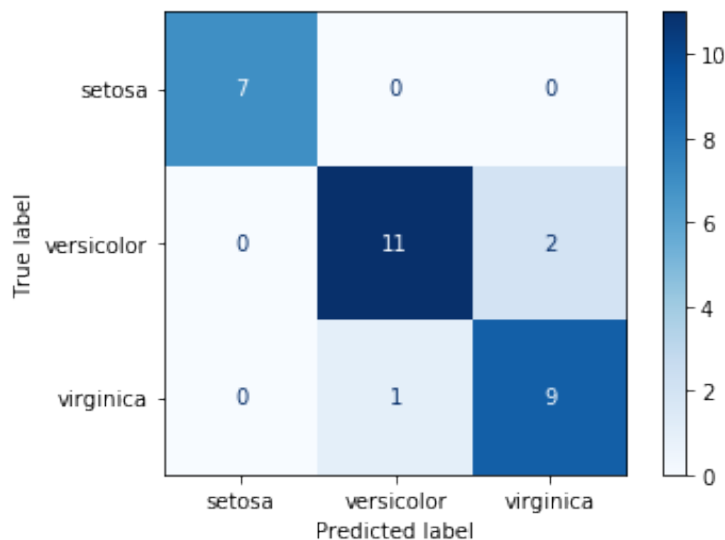
V klasifikovaných datech se může vyskytovat velké množství chyb nebo šumu. Některé z nich je možné eliminovat nebo snížit jejich výskyt v souboru dat. Pro tyto účely slouží postklasifikační úpravy. Mezi nejčastěji využívané metody se řadí nízkofrekvenční filtrace. Tyto filtry shlazují výsledky a potlačují šum vzniklý typicky u metody klasifikace *per pixel* – sůl a pepř. K odstranění tohoto typu šumu je využíván mediánový filtr. (Švanda 2012) Tento filtr nahrazuje hodnotu každého pixelu mediánem hodnot sousedních pixelů. Je velmi efektivní, protože dokáže potlačit šum bez ztráty ostrosti obrazu. (Švanda 2012)



Obr. 15 Šum v datech – sůl a pepř (Švanda 2012)

Mezi další nízkofrekvenční filtry patří Sieve filtr, který je využíván zejména pro korekce po klasifikacích obrazu. Sieve filtr odstraňuje izolované pixely, které jsou nahrazeny například průměrem jeho hodnoty a okolních pixelů z pohyblivého se „síta“ (matice s lichým počtem řádků a sloupců). (Ústav geoinformačních technologií Lesnická a dřevařská fakulta MENDELU 2023)

Finálním krokem klasifikace je ohodnocení její přesnosti. Nejčastěji používanou metodou je klasifikační chybová matice. Jedná se o čtvercovou matici vyjadřující vztah výsledků klasifikace a referenčních tréninkových dat. Hodnoty vyjadřují počet pixelů v dané klasifikační třídě nebo také procentuální rozmístění. Ve sloupcích jsou zpravidla hodnoty výsledné klasifikace a v řádcích tréninková referenční data. (Lillesand, M. 2015; Ústav geoinformačních technologií Lesnická a dřevařská fakulta MENDELU 2023)



Obr. 16 Matice záměn (Vidnerova a Diba 2020)

3.2 Použitá data

Pro účely první případové studie v oblasti CHKO Jeseníky (Vysoká Hole) byla Katedrou geoinformatiky zpřístupněna ortomozaika s rozlišením 4 cm na pixel z roku 2019 a podrobná klasifikovaná data vegetace na tomto území v roce 2019 ve formátu shapefile. Z projektu tvorby ortomozaiky bylo dále vytvořeno fotogrammetrické bodové mračno ve formátu LAS (LASer).

Pro druhou případovou studii byla firmou Renofarmy, a.s. zapůjčena ortomozaika sadu ve Vicínově u obce Veselíčko.

Pro účely poslední případové studie byly od Katedry geoinformatiky poskytnuta letecká data LIDAR v oblasti Olomouce a vesnic v CHKO Litovelské Pomoraví – Střeň a Březové.

3.3 Použité programy a knihovny

V průběhu diplomové práce byla použita a testována řada programů a knihoven. Programy byly využity pro účely zpracování, přípravy dat, pro testování a uskutečnění klasifikací, přípravu scriptů a ohodnocení, popis a vizualizace výstupů.

Dále byla v rámci přípravy dat a vývoje modelu strojového učení využita řada programovacích knihoven v jazyce Python.

3.3.1 Použité programy

QGIS

QGIS dříve známý pod názvem Quantum GIS je multiplatformní, svobodný a otevřený geoinformační systém. Jedná se o software vhodný pro práci s geografickými daty, jejich správu, analýzu a vizualizace. Projekt QGIS je součástí Open Source Geospatial Foundation (OSGeo). V diplomové práci byl využit pro účely přípravy dat, testování objektově orientované klasifikace pomocí knihovny OTB a vizualizace výsledků klasifikace. (QGIS 2024; GISMentors 2024)

ArcGIS Pro

Je proprietární desktopový GIS (geografický informační systém) software od firmy Esri umožňující práci s geografickými daty od základní správy dat až po komplexní analýzy a modelování. Jedná se o jeden z nejvyužívanějších a nejpokročilejších geoinformačních softwarů. ArcGIS Pro nabízí řadu pokročilých možností pro klasifikaci obrazových i lidarových dat. Využívá metody strojového učení a velmi pokročilé metody hlubokého učení jako jsou neuronové sítě.

V procesu zpracování diplomové práce byl ArcGIS Pro využit pro přípravu vektorových i rastrových dat. Dále byly využity pokročilé možnosti vizualizace dat. V konečné fázi byly také testovány možnosti klasifikací tohoto softwaru a modelů strojového a hlubokého učení od firmy Esri. (Esri 2024a)

CloudCompare

Jedná se o software sloužící pro práci s bodovými mračky, jejich zobrazení, vizualizace, filtrování a pokročilé analýzy. Je robustní, otevřené řešení pracující s velkou řadou formátů zaměřených na laserová a 3D data.

Pro účely diplomové práce byl využit při zpracování lidarových dat, filtrování, testování klasifikací a vizualizace. (CloudCompare 2024)

Agisoft Metashape Professional

Software zaměřený na fotogrammetrii, práci s 3D daty a bodovými mračky. Robustní nástroj pro zpracování digitálních obrazových dat, automatické generování fotogrammetrických mračen, tvorbu spojitých modelů, texturování a dalších pokročilých operací.

Program byl využit pro klasifikaci bodových mračen a tvorbu digitálních modelů reliéfu a povrchu (DMR a DMP). (AgiSoft LLC 2023)

Visual Studio Code

Výkonný editor zdrojového kódu od společnosti Microsoft s vestavěnou podporou velkého množství programovacích jazyků. Je optimalizován pro vývoj a ladění moderních webových i desktopových aplikací, skriptování a automatizaci.

V rámci diplomové práce byl využit pro programování scriptů v jazyce Python a tvorbu modelu strojového učení pro klasifikaci obrazových dat. (Microsoft 2024)

OpenCities Map PowerView

OpenCities Map PowerView je geoprostorový software od společnosti Bentley Systems, který umožňuje práci s 2D i 3D daty. Díky propojení s programem TerraSolid je v tomto programu možné používat pokročilé funkce pro práci s daty dálkového průzkumu země a daty bodových mračen. (Bentley Systems 2024)

3.3.2 Program Python knihovny

Scikit-learn

Výkonná Python knihovna poskytující velké množství nástrojů pro strojové učení a statistické modelování. Mezi nejpoužívanější nástroje patří klasifikace, regrese, shlukování a redukce dimenzionality. Pro klasifikaci obrazových dat Scikit-learn nabízí několik algoritmů, jako jsou Support Vector Machines, random forest, Gradient Boosting a další. Tyto algoritmy mohou být využity i pro klasifikace, analýzy a interpretace dat dálkového průzkumu země. Knihovna mimo jiné nabízí nástroje pro předzpracování dat a jejich vyhodnocení. (Scikit-learn developers 2024d)

Rasterio

Knihovna umožňující číst, prohlížet, vizualizovat a zpracovávat geoprostorová rastrová data. Rasterio podporuje řadu formátů jako GeoTIFF (Tagged Image File Format) a je schopná pracovat i s družicovými snímky, digitálními modely terénu a produkty z dronů. Knihovna je založena na práci s n-dimenzionálními poli. Nejnovější Rasterio pracuje s Pythonem 3.8 a vyšší, Numpy 1.8 a vyšší a GDAL 3.1+. (Mapbox 2018b)

Pandas

Otevřená knihovna poskytující výkonné nástroje a datové struktury pro analýzu dat. Nabízí datové struktury jako Series a DataFrame, které umožňují práci s daty různých formátů. Dokáže snadno operovat se soubory ve formátu CSV (Comma-separated values), JSON (JavaScript Object Notation) a provádět filtrování, transformace dat a jejich analýzy. Je vhodná pro práci s geoprostorovými daty pomocí svého rozšíření GeoPandas. (NumFOCUS 2024a; GeoPandas developers 2022)

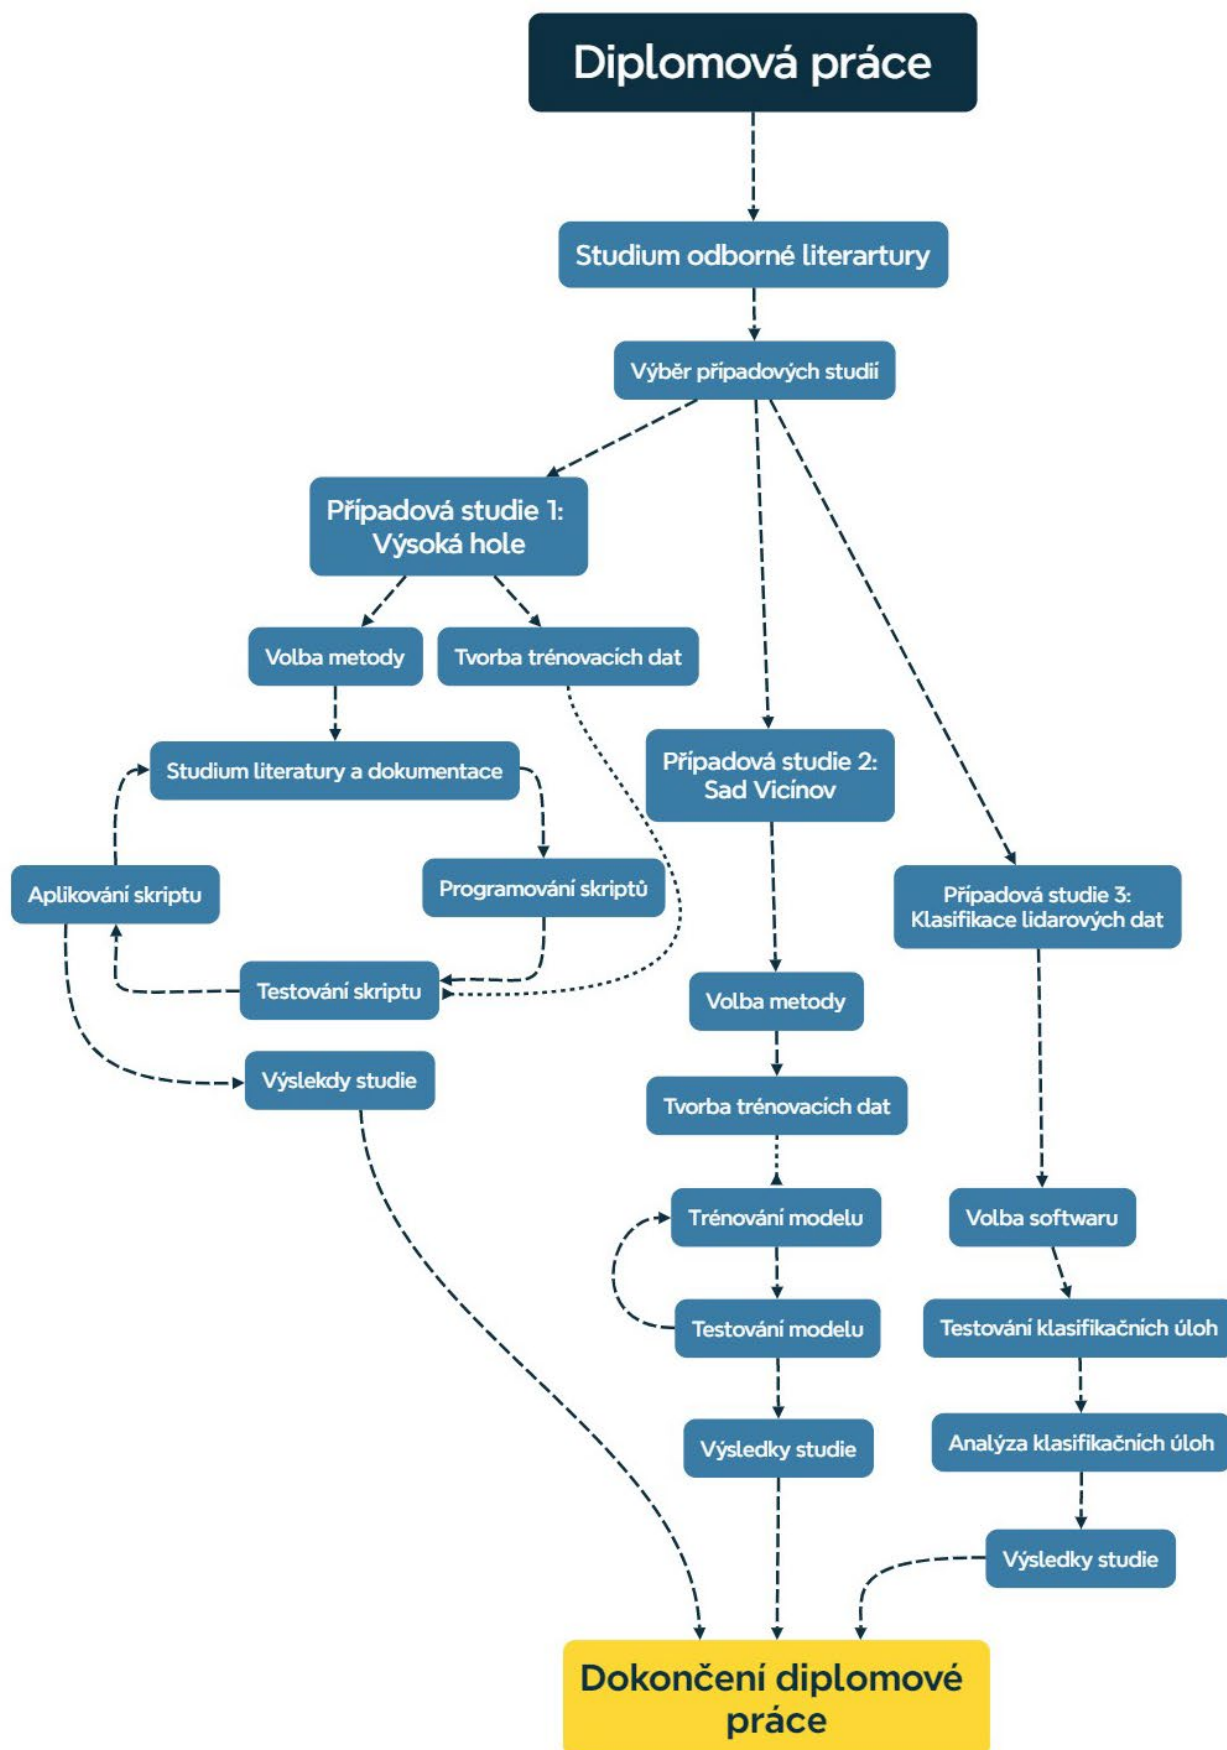
NumPy

Klíčová knihovna podporující práci s velkými, multi-dimenzionálními poli a maticemi. Obsahuje také velký soubor matematických funkcí, které lze na matice a pole použít. Jedná se o základní balíček pro vědecké výpočty. Mezi základní operace patří lineární algebra, Furierovy transformace a další. Díky své efektivitě a jednoduchosti je tato knihovna široce používána pro datové analýzy, strojové učení a výzkum. (NumPy team 2024a)

SciPy

Knihovna poskytující soubor matematických algoritmů a funkcí pro manipulaci a vizualizaci dat. Je postavena na knihovně NumPy a rozšiřuje ji o příkazy a funkce. Mezi nejzajímavější algoritmy této knihovny patří možnosti optimalizace, integrace a interpolace dat. Mezi další rozšíření patří moduly pro statistiku a lineární algebru. (SciPy community 2024)

3.4 Postup zpracování



Obr. 17 Postup zpracování diplomové práce

4 PŘÍPADOVÁ STUDIE 1:VYSOKÁ HOLE

První případová studie v rámci diplomové práce se zaměřuje na klasifikaci horské vegetace v oblasti Vysoké hole.

Vysoká hole je druhý nejvyšší vrchol Hrubého Jeseníku, nachází se v CHKO Jeseníky a NPR Praděd.

Volba tématu této případové studie nebyla náhodná, nýbrž byla motivována projektem, zabývajícím se podrobným hodnocením vegetace na tomto území. Díky tomuto výzkumu byly pro účely studie k dispozici data o vegetaci, která byla přesně ručně zaznamenána s vysokou mírou detailu.


Katedrou geoinformatiky byla zpřístupněna tato data:

- ortomozaika (2019)
- vektorová vrstva manuální klasifikace vegetace ve formátu SHP (shapefile) (2019)
- fotogrammetrické mračno ve formátu LAS (2019)

4.1 Příprava projektu

Případová studie byla zahájena definováním klasifikačních tříd, na jejichž základě byla vybrána vhodná zájmová území pro tvorbu trénovacích dat a testování vytvořeného modelu.

Analýzou území Vysoké hole bylo vybráno sedm klasifikačních tříd: ostatní, tráva, stromy, kleč, keře, kapradiny a skály a kamenná pole. Poté bylo území rozděleno do shodných čtvercových oblastí (kladu) o velikosti 20 x 20 m, z nichž byly vybrány vhodné území pro tvorbu trénovacích a testovacích dat. Výběr vhodných oblastí probíhal s ohledem na dostupnost veškerých potřebných dat a místa jejich překryvu. Pro tvorbu trénovacích dat bylo vyčleněno území o rozloze 40 hektarů, zatímco pro testování byla vyhrazena oblast o rozloze 20 hektarů.



Obr. 17 Přibližný zakres zájmového území Vysoké hole

4.2 Příprava dat

Vstupem učení klasifikačního modelu jsou trénovací data splňující požadavky daného modelu a skriptu. Klíčovou podmínkou bylo zachování konzistentní velikosti a rozlišení vstupujících rastrů. Z toho důvodu byla vytvořena čtvercová mřížka o rozměrech 20 x 20 metrů, která sloužila k vytvoření konzistentních trénovacích dat. Tato mřížka také posloužila k výběru vhodných oblastí pro tvorbu dat.

Referenční datová sada

První sadou zpracovaných dat byla referenčních datová sada vytvořená z ortomozaiky. Tato datová sada byla zpracována v programu ArcGIS Pro. Nejprve byla do projektu importována veškerá potřebná vstupní data, včetně samotné ortomozaiky a mřížky, která byla použita k vytvoření dlaždic. Jednotlivé dlaždice pixelů byly vytvořeny pomocí nástroje Clip Raster nakonfigurovaného pro export dlaždic podle výběru z mřížky do formátu TIF. Výsledkem byly dlaždice o rozměrech 500 x 501 pixelů s rozlišením 4 cm na pixel. Tímto způsobem bylo vyexportováno celkem 100 dlaždic trénovacích referenčních dat. Pro účely testování modelu byly také vyexportovány dvě větší dlaždice o rozměrech 100 x 100 metrů (2500 x 2501 pixelů).



Obr. 18 Ukázka dlaždic referenční datové sady vytvořené z ortomozaiky

Datová sada manuální klasifikace

Druhý datový soubor byl generován z poskytnutých dat vytvořených manuální klasifikací v rámci dlouhodobého výzkumu vegetace na území Vysoké hole. Analogicky k ortomozaice byla tato data vybrána za rok 2019. Manuální klasifikace byla rozdělena do celkového počtu 10 tříd. Z těchto dat byly cíleně vybrány pouze oblasti obsahující 7 předem definovaných tříd, jak je podrobněji popsáno v kapitole 4.1 Příprava projektu. Tento datový soubor byl poskytnut ve vektorovém formátu SHP.

Prvním krokem v přípravě druhého datového souboru byla rasterizace. Tento proces byl proveden pomocí nástroje Polygon to Raster v softwaru ArcGIS Pro. S cílem minimalizovat počet kroků a dosáhnout shodného výstupu, jako u prvního datového souboru. Bylo nezbytné tento nástroj správně nastavit. Shodného výstupu bylo nutné dosáhnout na základě požadavků naprogramovaného skriptu pro klasifikaci, který vyžaduje shodný počet pixelů (rozměr rastru) a velikost pixelu (rozlišení rastru). V nástroji bylo tedy nezbytné nastavit velikost pixelu dle prvního datového souboru, zarovnání rastrů a rozsah shodný s dlaždicemi referenčního datového souboru.



Obr. 20 Ukázka dlaždic datové sady manuální klasifikace

Datová sada relativních výšek


Poslední datová sada vstupující do klasifikace byla vytvořena z fotogrammetrického mračna, vypočteného v rámci projektu tvorby ortomozaiky. Fotogrammetrické mračno bylo z důvodu velikosti dat zpřístupněno pouze v části území a stalo se tak mimo jiné důležitým faktorem výběru zájmových oblastí.

Pro vytvoření rozdílového rastru – rastru relativních výšek objektů nad povrchem, bylo v první řadě nutné provést základní klasifikaci bodového mračna, a to na povrch (třída Ground) a body nad povrchem. Ze všech bodů byl následně interpolací vytvořen spojitý model území – digitální model povrchu (DMP). Z bodů podle třídy Ground bylo možné pomocí interpolace vytvořit spojitý model reliéfu – digitální model reliéfu (DMR), reprezentující pouze body na povrchu země. Klasifikace mračna byla provedena v programu Agisoft Metashape Professional, kde byly následně provedeny interpolace a export spojitých modelů ve formátu TIF.

Vyexportované rastry DMP a DMR byly následně nahrány do projektu programu ArcGIS Pro, kde pomocí nástroje Raster Calculator došlo k jejich odečtení a vytvoření rozdílového rastru:

$$RR = DMP - DMR$$

Výsledný rastr bylo nutné rozřezat na shodné dlaždice, tak jako referenční datový set a tím zajistit identické hodnoty rozměru dlaždice a rozlišení pixelu. To bylo provedeno převzetím velikosti buňky (pixelu), zarovnáním pixelů na referenční data a omezením rozsahu. Výsledkem byl datový set 100 dlaždic s výškami objektů (vegetace) nad reliéfem.



Příprava dat v kontextu klasifikace je klíčovým úkolem. Přesnost klasifikace je z velké části závislá na kvalitě, množství a podrobnosti trénovacích dat. V rámci této případové studie a vybrané metody klasifikace byla klíčová také shodnost jednotlivých datových sad, a to jak formát dat, rozměru a velikosti jednotlivých rastrů. Analýze a přípravě dat bylo tedy na základě podrobné rešerše věnováno dostatečně velké množství času.

4.3 Programování klasifikace

V průběhu zpracování první případové studie byl vyvíjen skript procesu klasifikace. Programování skriptu bylo provedeno v jazyce Python s využitím řady knihoven. Výběr knihoven byl na základě podrobné rešerše a doporučení.

Proces klasifikace je tvořen řadou důležitých kroků. Pro každý z nich bylo nutné využít vhodné knihovny. Nejdůležitější volbou byla knihovna pro samotnou část klasifikace a učení ML (machine learning) modelu. Pro tyto účely byla vybrána knihovna Scikit-learn. Jedná se o bezplatnou open source knihovnu vhodnou pro vývoj modelů strojového učení a statistického modelování. Tato knihovna nabízí velké množství statistických metod, do kterých se řadí klasifikační algoritmy. (Scikit-learn developers 2024f) Pro další kroky klasifikace byly dále využity knihovny: numpy, rasterio, joblib, pandas, scipy a glob.

Programování skriptu bylo rozděleno do několika fází, kdy s každým vyvíjeným skriptem byly programovány a testovány nové funkce.

Základní skripty sloužily ke čtení rastrových dat s kontrolou vhodnosti pro vyvíjený klasifikační skript.

```
import rasterio

# Nacteni souboru
with rasterio.open('REFERENCNI/REF3_1.tif') as raster1,
rasterio.open('ROZDIL_RASTR/RR3_1.tif') as raster2:
    # Zjisteni rozliseni pixelu obou rastru
    res1 = raster1.res
    res2 = raster2.res

    # Zjisteni poctu pixelu v kazdem smeru
    num_pixels1 = (raster1.width, raster1.height)
    num_pixels2 = (raster2.width, raster2.height)

    # Vypsani zjistenyh informaci
    print(f'Pixel resolution of raster1: {res1[0]} x {res1[1]}')
    print(f'Number of pixels in raster1: {num_pixels1[0]} (width) x
{num_pixels1[1]} (height)')
    print(f'Pixel resolution of raster2: {res2[0]} x {res2[1]}')
    print(f'Number of pixels in raster2: {num_pixels2[0]} (width) x
{num_pixels2[1]} (height)')

    # Kontrola zda jsou hodnoty shodne
    if res1 == res2:
        print('The pixel resolutions of the two rasters are the same.')
    else:
        print('The pixel resolutions of the two rasters are not the same.')
```

Vývoj klasifikačního skriptu začal od základů s načtením jedné rastrové dlaždice z referenční datové sady a datové sady manuální klasifikace. Na těchto dvou vrstvách byla testována řada nastavení skriptu a samotná klasifikace. Ve skriptu bylo nutné definovat, která data slouží v procesu učení ke čtení informací (data z ortomozaiky), a která k rozhodování o skutečné třídě (manuální klasifikace).

Během vývoje prvního skriptu došlo k testování různých klasifikátorů dostupných v knihovně scikit-learn a jejich nastavení pro neoptimálnější výsledky s přijatelnou náročností na výpočetní čas. (Scikit-learn developers 2024b)

```
# Trénování klasifikátoru Random Forest
print("Training the Random Forest classifier...")
clf = RandomForestClassifier(n_estimators=10, random_state=0)
clf.fit(X.T, y)
```

V druhé fázi, kdy byly definované základy a vybrány vhodné klasifikátory, došlo k rozšíření skriptu pro načtení všech dlaždic z definovaných adresářů. Tímto byl model trénován na všech vytvořených datech a stal se komplexnější pro definované území. Důležitou částí bylo upravit skript, aby trénování proběhlo nad spojeným datovým souborem, a nikoliv jednotlivými dlaždicemi, čímž by došlo k přeučení modelu. Tento základní skript zobrazoval výsledky klasifikace pouze formou tisku informací o celkové přesnosti modelu v konzoli. Proto v této druhé fázi došlo také k přidání funkce převedení a exportu klasifikovaných dat na rastry ve formátu TIF, pro ověření správného fungování skriptu a klasifikačního modelu. Druhým výstupem, který byl v této části přidán, byl export excelovské tabulky s metrikami a podrobným hodnocením přesnosti natrénovaného modelu.

```
# Načtení klasifikovaných dat a referenčních RGB dat z adresaru
labeled_images = glob.glob('KLASIFIKOVANE/*.tif')
reference_images = glob.glob('REFERENCNI/*.tif')
```

V třetí fázi došlo k přidání funkce filtrace dat. Výsledky klasifikace z druhé fáze vykazovaly poměrně velké množství chyb v důsledku šumu, který je typický pro metody per pixel klasifikace. Tyto chyby je možné částečně eliminovat pomocí postklasifikačních úprav. Nejčastěji používanou metodou jsou nízkofrekvenční filtrace, které shlazují výsledky a potlačují šum. Funkce této metody byly v této fázi programování do skriptu přidány a testovány. Dle rešerše byly testovány dva nejvhodnější filtry, a to Sieve a mediánový filtr.

```
# Aplikování mediánového filtru
print("Applying median filter to the predicted labels...")
predicted_labels = median_filter(predicted_labels, size=3)
```

V poslední fázi vývoje skriptu došlo k jeho finalizaci. Jednotlivé funkce byly vhodně spojeny do série úloh. Došlo k definování adresářů se vstupy a výstupy exportovaných dat, názvů výstupních souborů. Posledním velmi důležitým krokem bylo přidání funkce uložení modelu. Tento krok byl klíčový pro jeho opakované užití a zejména jeho validaci nad testovacími daty.

```
# Ukládání modelu
print("Saving the trained model...")
dump(clf, 'MODELKY/_Model_kNN-Vysoka_Hole.joblib')
```

4.3.1 Finální skripty klasifikace

Výše popsanými fázemi vývoje byly celkem vytvořeny 4 finální skripty pro trénování modelů. Jednotlivé skripty jsou rozděleny dle vstupních dat a dle použitého klasifikátoru.

Dle vstupních dat do trénovací fáze modelu jsou skripty rozděleny na jednodušší (trénování modelu pouze nad souborem referenčních RGB dat) a složitější (trénování modelu kombinací referenčního souboru RGB dat a souboru rastrů s relativními výškami objektů nad povrchem).

Dle použitého klasifikátoru jsou skripty děleny na modely trénované klasifikačním algoritmem kNN (k nejbližších sousedů) a algoritmem random forest. Výběr klasifikačních algoritmů vycházel z testování v první fázi programování skriptů a rešerše. Algoritmus kNN byl zvolen díky své jednoduchosti, flexibilitě a byl vybrán jako vhodný algoritmus pro úvodní a základní testování skriptů. Naopak algoritmus random forest byl zvolen kvůli své robustnosti a přesnosti, vhodné pro předpovědní a klasifikační modely. Velkou výhodou random forest je také jeho odolnost vůči přeučení. Výhodou obou vybraných modelů je nelinearita, která znamená schopnost algoritmů zachytit složité vztahy v datech.

Pro aplikování natrénovaných modelů na testovací data byly vytvořeny další dva skripty. Tyto skripty jsou rozděleny podle vstupních dat (jednodušší – rastr RGB a složitější – rastr RGB + rastr relativních výšek).

Skripty pro trénování modelů

Výpis skriptů podle využitých dat a klasifikátorů:

- Skript 1:
 - Vstup: Referenční datová sada + Datová sada manuální klasifikace
 - Klasifikátor: algoritmus kNN
- Skript 2:
 - Vstup: Referenční datová sada + Datová sada manuální klasifikace
 - Klasifikátor: algoritmus Random Forest
- Skript 3:
 - Vstup: Referenční datová sada + Datová sada relativních výšek + Datová sada manuální klasifikace
 - Klasifikátor: algoritmus kNN
- Skript 4:
 - Vstup: Referenční datová sada + Datová sada relativních výšek + Datová sada manuální klasifikace
 - Klasifikátor: algoritmus Random Forest

Všechny vypsání skripty jsou koncepčně totožné, pouze s výše uvedenými rozdíly ve vstupních datech a použitých klasifikátorech modelu. Z tohoto důvodu budou detailně popsány klíčové části pouze jednoho skriptu pro trénování modelu a jednoho skriptu aplikující tento model.

Popis částí skriptu pro trénování modelu

V první části skriptu dochází k importu potřebných knihoven:

- numpy – knihovna pro práci s maticemi (NumPy team 2024b)
- rasterio – knihovna pro čtení a zápis rastrových dat (Mapbox 2018a)
- sklearn.ensemble – modul knihovny scikit-learn, obsahující metody pro ensemble learning, včetně klasifikátoru Random Forest (Scikit-learn developers 2024c)
- joblib – knihovna pro ukládání a načítání modelů (Joblib 2024)
- sklearn.metrics – modul knihovny scikit-learn obsahující metriky pro vyhodnocení výkonu modelů (Scikit-learn developers 2024e)
- pandas – knihovna pro manipulaci a analýzu dat (NumFOCUS 2024b)
- scipy.ndimage – modul knihovny SciPy pro práci s n-dimenzionálními obrázky (The SciPy community 2024)
- glob – modul pro nalezení cest k souborům (Python Software Foundation 2024)

```
# Import knihoven
import numpy as np
import rasterio
from sklearn.ensemble import RandomForestClassifier
from joblib import dump, load
from sklearn.metrics import confusion_matrix, accuracy_score,
classification_report
import pandas as pd
from scipy.ndimage import median_filter
import glob
```

Druhá část skriptu načítá rastrové obrázky z definovaných adresářů. V tomto případě dochází k načtení všech trénovacích dat: referenční datové sady, datové sady manuální klasifikace a datové sady relativních výšek.

```
# Cesty k souborům
labeled_images = glob.glob('KLASIFIKOVANE/*.tif')
reference_images = glob.glob('REFERENCNI/*.tif')
elevation_images = glob.glob('ROZDIL_RASTR/*.tif')

X_list = []
y_list = []
```

V třetí části skriptu dochází k trénování klasifikátoru na všech trénovacích datech. Pro každou dlaždici jsou načteny její informace a dojde k přeformátování rastru. Přeformátování je provedeno z toho důvodu, že data jsou načtena jako 3D pole (kanály, výška a šířka). Pro trénování je ale nutné jejich převedení na 2D pole. To je provedeno pomocí funkce `numpy.reshape`, která rozměry výšky a šířky spojí do jednoho rozměru reprezentujícího počet vzorků. Dále dochází k vytvoření masky pro platná data (informace z datové sady manuální klasifikace) a k jejímu aplikování. Platná data neboli data spadající do určité třídy jsou následně přidány do seznamu. Všechna vytvořená data jsou nakonec spojena a použita k natrénování klasifikátoru.

```
# Zahajeni trenovani modelu
clf = RandomForestClassifier(n_estimators=25, random_state=0)

# Cyklus pro trenovani klasifikatoru nad vsemi vstupnimi rastry
```



```

for i in range(len(labeled_images)):

    # Nacteni klasifikovanych dat
    print(f"Loading the labeled image {i+1}...")
    with rasterio.open(labeled_images[i]) as src:
        label_data = src.read(1)

    # Nacteni referencnich rgb dat
    print(f"Loading the aerial image {i+1}...")
    with rasterio.open(reference_images[i]) as src:
        aerial_data = src.read()

    # Nacteni dat relativni vysky
    print(f"Loading the elevation image {i+1}...")
    with rasterio.open(elevation_images[i]) as src:
        elevation_data = src.read()

    # Pretransformovani
    print("Reshaping the arrays...")
    n_samples = (aerial_data.shape[1] * aerial_data.shape[2])
    reshaped_aerial_data = aerial_data.reshape((aerial_data.shape[0],
        n_samples))
    reshaped_label_data = label_data.reshape(n_samples)
    reshaped_elevation_data = elevation_data.reshape((1,
        n_samples))

    # Vytvoreni masky pro platna data
    print("Creating a mask for valid data...")
    mask = reshaped_label_data > 0

    # Aplikovani masky
    print("Applying the mask to the data...")
    full_data = np.vstack([reshaped_aerial_data,
        reshaped_elevation_data])
    the reshaped elevation data
    X = full_data[:, mask]
    y = reshaped_label_data[mask]

    X_list.append(X.T)
    y_list.append(y)

# Spojeni vsech dat
print("Concatenating all the data...")
X_all = np.concatenate(X_list)
y_all = np.concatenate(y_list)

# Trenovani klasifikatoru - naplneni daty
print("Training the classifier - fit all the data...")
clf.fit(X_all, y_all)

```

Čtvrtá část skriptu slouží k uložení natrénovaného modelu pomocí funkce dump z knihovny joblib.

```
print("Saving the trained model...")
dump(clf, 'MODEL_Y/_Model_RF-Vysoka_Hole.joblib')
```

V páté části je aplikován natrénovaný klasifikátor pro testování správné funkcionality. Pro každou dlaždici jsou načtena data, dojde k jejímu přeformátování a je aplikován klasifikátor pro předpověď třídy každého pixelu obrazu. Následně dojde k částečné eliminaci šumu pomocí mediánového filtru. Seznamy informací jsou přeformátovány do původního tvaru obrazu a jednotlivé dlaždice jsou uloženy ve formátu TIF.

```
# Inicializace prazdnych seznamu pro ulozeni skutecnych a
predikovanych trid pixelu vseh obrazku
y_all = []
predicted_labels_all = []

# Cyklus pro aplikovani klasifikatoru na dlazdice
for i in range(len(labeled_images)):
    # Nacteni klasifikovanych dat
    print(f>Loading the labeled image {i+1}...")
    with rasterio.open(labeled_images[i]) as src:
        label_data = src.read(1)

    # Nacteni referencnich rgb dat
    print(f>Loading the aerial image {i+1}...")
    with rasterio.open(reference_images[i]) as src:
        aerial_data = src.read()

    # Nacteni dat relativni vysky
    print(f>Loading the elevation image {i+1}...")
    with rasterio.open(elevation_images[i]) as src:
        elevation_data = src.read()

    # Pretransformovani
    print("Reshaping the arrays...")
    n_samples = (aerial_data.shape[1] * aerial_data.shape[2])
    reshaped_aerial_data = aerial_data.reshape((aerial_data.shape[0],
    n_samples))
    reshaped_elevation_data = elevation_data.reshape((1,
    n_samples))

    # Shomazdeni pretransformovanych referencnich rgb dat a dat
    relativnich vysek
    full_data = np.vstack([reshaped_aerial_data,
    reshaped_elevation_data])

    # Predpoved trid vseh pixelu dlazdice
    print("Predicting the classes of the entire image...")
    predicted_labels = clf.predict(full_data.T)
```

```

# Aplikovani medianového filtru
print("Applying median filter to the predicted labels...")
predicted_labels = median_filter(predicted_labels, size=3)

# Transformovani predikci klasifikovanych dat do rastru
print("Reshaping the predicted labels to the original image
shape...")
predicted_labels = predicted_labels.reshape(aerial_data.shape[1],
shape...)

# Ulozeni klasifikovanych dlazdic (predikce)
print("Saving the classified image...")
with rasterio.open(reference_images[i]) as src:
    kwargs = src.meta
    kwargs.update(
        dtype=rasterio.uint8,
        count=1)

    with rasterio.open(f'PREDIKCE/RF_PREDIKCE_{i+1}.tif',
'w', **kwargs) as dst:
        dst.write(predicted_labels.astype(rasterio.uint8), 1)

print(f"Image {i+1} done!")

# Spojeni predikovanych seznamu a seznamu z dat skutecnosti
(manualni klasifikace)
y_all.append(y_list[i])
predicted_labels_all.append(predicted_labels.reshape(-1))

```

V poslední části skriptu dochází k výpočtu a uložení metrik pro celý dataset, včetně matice záměn, celkové přesnosti predikce (klasifikace) a klasifikačního reportu.

```

# Prevod seznamu na pole numpy
y_all = np.concatenate(y_all)
predicted_labels_all = np.concatenate(predicted_labels_all)

# Vypocet metrik pro cely dataset
print("Calculating metrics for the entire dataset...")
classification_report_all = classification_report(y_all,
predicted_labels_all)
confusion_matrix_all = confusion_matrix(y_all, predicted_labels_all)
accuracy_score_all = accuracy_score(y_all, predicted_labels_all)

# Ulozeni metrik do excel souboru
print("Saving the metrics to an Excel file...")
with pd.ExcelWriter('METRIKY/RF_METRIKY.xlsx') as writer:
    df_classification_report_all =
pd.DataFrame.from_dict(classification_report(y_all,
predicted_labels_all, output_dict=True))

```

```

df_classification_report_all.to_excel(writer,
sheet_name='Classification Report All')

df_confusion_matrix_all = pd.DataFrame(confusion_matrix(y_all,
predicted_labels_all))
df_confusion_matrix_all.to_excel(writer, sheet_name='Confusion
Matrix All')

df_accuracy_score_all = pd.DataFrame([accuracy_score_all],
columns=['Accuracy Score'])
df_accuracy_score_all.to_excel(writer, sheet_name='Accuracy Score
All')

print("All done!")

```

Popis částí skriptu pro testování a aplikování modelu

Tento skript je na rozdíl od výše popsaného určen pro klasifikaci obrazových dat pomocí předem natrénovaného modelu. Tak jako skript pro trénování modelu je rozdělen do několika částí. Velké množství těchto částí je převzato.

V první části skriptu dochází k importu knihoven. Novou knihovnou je pouze knihovna `os`, která pomocí Pythonu poskytuje funkce pro interakci s operačním systémem a zejména se souborovým systémem. V tomto skriptu je použita pro získání seznamu obrázků pomocí funkce `os.listdir()` s filtrem, aby načetla pouze soubory s příponou `.tif`. Další využitou funkcí je `os.path.join()`, která je použita k vytvoření úplných cest k souborům obrázků.

V druhé části jsou obdobně, tak jako u předchozího skriptu, definovány cesty k adresářům se soubory.

Třetí část je nová a slouží k načtení připraveného natrénovaného modelu pro klasifikaci.

```

# Nactení natrenovaneho modelu
print("Loading the trained model...")
clf = load('MODEL_Y/_Model_RF_Vysoka_hole.joblib')

```

Zbylé části skriptu jsou obdobné tak jako u výše popsaného skriptu. Nejprve dojde k načtení a transformaci všech dlaždic pro testování modelu. Na načtené obrázky je aplikován natrénovaný klasifikátor. Predikce jsou následně filtrovány mediánovým filtrem pro částečné vyčištění šumu. V posledním kroku klasifikace jsou obrázky transformovány zpět do původního tvaru a uloženy ve formátu TIF do vybraného adresáře.

Poslední část provede výpočet metrik – matici záměn, klasifikační report a celkovou přesnost klasifikace. Všechny metriky jsou uloženy do souboru excel `.xlsx`.

Tak jako u skriptu pro trénování jsou vstupem pro klasifikace referenční data RGB hodnot z letecké ortomozaiky, rastr relativních výšek objektů nad reliéfem a manuálně klasifikovaná data. První dvě datové sady slouží pro rozhodování modelu o přiřazení jednotlivých pixelů do tříd. Manuálně klasifikovaná data slouží jako informace o skutečném výskytu tříd a pro výpočet metrik a evaluaci modelu.

4.4 Výstupy případové studie

- Trénovací data
 - Referenční datová sada
 - Datová sada manuální klasifikace
 - Datová sada relativních výšek
- Skripty
 - Pro trénování modelu
 - Pro testování a aplikování modelu
- Modely
- Predikovaná data
- Metriky

5 PŘÍPADOVÁ STUDIE 2: VICÍNOV

Druhá případová studie se zaměřuje na aplikaci pokročilých metod hlubokého učení pro detekci stromů v ovocném sadu mimo vegetační období. Studie byla konkrétně zaměřena na sad ve Vicínově, který je součástí obce Veselíčko v Olomouckém kraji.

Pro tento výzkum byla využita ortomozaika získaná z dronových snímků poskytnutá společností Renofarmy, a.s.

Detekce stromů pomocí metod hlubokého učení byla prováděna v prostředí softwaru ArcGIS Pro. Došlo k testování dvou přístupů: per pixel klasifikace a detekce objektů. Oba přístupy byly testovány pomocí konvolučních neuronových sítí dostupných v prostředí ArcGIS Pro.

Před samotným zahájením testování však došlo k pečlivému určení trénovacích a testovacích oblastí. Trénovací oblast byla vybrána o výměře 18,24 ha a testovací 10,05 ha.



Obr. 22 Zájmové území sadu Vicínov u obce Veselíčko

5.1 Deep learning v ArcGIS Pro

Software ArcGIS Pro nabízí několik nástrojů a možností, jak využít metod hlubokého učení dostupných pro rastrová data a bodová mračna. Všechny tyto nástroje však vyžadují instalaci požadovaných frameworků a knihoven hlubokého učení. Všechny požadované nástroje je možné nainstalovat pomocí připraveného instalačního souboru dostupného od firmy Esri na githubu. Instalační balíček zajišťuje instalaci všech potřebných komponent jako jsou PyTorch, TensorFlow, Fast.ai, scikit-learn a dalších knihoven nutných pro vykonávání úloh strojového a hlubokého učení. Instalační soubor přidá všechny komponenty do výchozího arcgispro-py3 prostředí bez nutnosti přidávání nových python prostředí. V případě, že je vytvořeno vlastní prostředí, všechny balíčky jsou automaticky přidány i do nich. (Esri 2024f)


5.2 Trénování modelu

Abychom mohli využít model pro detekci objektů, jako jsou stromy, je nejprve nutné ho natrénovat. Trénování modelu hlubokého učení je podobné trénování tradičních klasifikačních modelů strojového učení. V prvním kroku je třeba vytvořit a poskytnout trénovací data (manuální klasifikace) a vstupní data (ortomozaika). Poté trénujeme model, aby se naučil rozpoznávat vybrané rysy a objekty.

Následně je natrénovaný model možné aplikovat na testovací data a analyzovat výsledky. (Esri 2024e)

5.2.1 Příprava trénovacích dat

V programu ArcGIS Pro je tvorba trénovacích dat pro DL (deep learning) modely provedena pomocí nástroje Label Objects for Deep learning. Jedná se o panel sloužící k manuálnímu shromažďování trénovacích dat do předem definovaných tříd. V případě této případové studie byla třída pouze jedna a to stromy. V panelu tohoto nástroje bylo nejprve definováno nové schéma trénovacích dat, do kterého byla následně přidána klasifikační třída stromy s hodnotou 1. Po definování tříd jsou aktivovány nástroje pro manuální tvorbu trénovacích ploch. V předem vybraném území pro trénování modelu došlo k manuálnímu zakreslení všech stromů s co nejvyšší přesností. Celkem bylo vytvořeno 249 polygonu stromů a polygonová vrstva byla uložena v geodatabázi projektu. Pomocí nástroje Label Objects for Deep learning následně došlo k exportu trénovacích dat ve formátech vhodných pro vstup do trénování modelů: Classified Tiles, PASCAL Visual Object Classes, RCNN Masks, a Imagenet. Export proběhl do vybraných adresářů. (Esri 2024g)



Obr. 23 Trénovací data druhé případové studie

5.2.2 Trénování modelu

Pro trénování modelu s využitím připravených trénovacích dat byl použit nástroj Train Deep Learning Model. Tento nástroj poskytuje možnost výběru různých typů modelů a parametrů na základě formátu vstupních trénovacích dat. V rámci této případové studie bylo testováno velké množství typů modelů a parametrů, z nichž byly následně pro podrobnější testování parametrizace vybrány ty s nejvyšší úspěšností predikce. Testovány byly typy modelu s přístupem per pixel a detekce objektů.

Na základě vytvořených formátů trénovacích dat došlo k testování typů modelů:

- RCNN Masks – MaskRCNN (detekce objektů)
- Imagenet – Feature classifier (objektová klasifikace)
- Classified Tiles – U-Net (per pixel klasifikace)
- Classified Tiles – DeepLabV3 (per pixel klasifikace)
- Classified Tiles – Pyramid Scene Parsing Network (per pixel klasifikace)
- Classified Tiles – MMSegmentation (per pixel klasifikace)
- PASCAL Visual Object Classes – Single Shot Detector (detekce objektů)
- PASCAL Visual Object Classes – RetinaNet (detekce objektů)
- PASCAL Visual Object Classes – YOLOv3 (detekce objektů)
- PASCAL Visual Object Classes – Faster RCNN (detekce objektů)
- PASCAL Visual Object Classes – MMDetection (detekce objektů)

Pro podrobnější testování byly však vybrány pouze:


- Classified Tiles – U-Net (per pixel klasifikace)
- Classified Tiles – DeepLabV3 (per pixel klasifikace)
- Classified Tiles – Pyramid Scene Parsing Network (per pixel klasifikace)
- Classified Tiles – MMSegmentation (per pixel klasifikace)
- PASCAL Visual Object Classes – RetinaNet (detekce objektů)

Při podrobnějším ladění modelů byly zkoumány efekty různých nastavení parametrů a byly analyzovány rozdíly při změnách maximálního počtu epoch. Jedna epocha představuje jeden průchod trénovacích dat dopředu i dozadu neuronovou sítí. Výchozí nastavení nástroje je 20 epoch, ale během testování na datech této studie bylo zjištěno, že pro některé modely je optimální nastavit 30 epoch a pro jiné dokonce 100. Zvýšení maximálního počtu epoch výrazně ovlivnilo výpočetní čas, který se zdvojnásobil při přechodu z 30 na 100 epoch. Přestože je možné nastavit vyšší počet epoch, není to striktní pravidlo. Pokud se model při dalším trénování nezlepšuje, trénování je zastaveno aniž by byl dosažen nastavený maximální počet průchodů. (Esri 2024i)

Druhým nastavovaným parametrem byla předkonfigurovaná neuronová síť, tvořící architekturu pro trénování modelu. Testováním byl vybrán model s architekturou ResNet-34. ResNet-34 je model strukturován jako konvoluční neuronová síť s 34 vrstvami a využívá koncept zvaný reziduální bloky, který umožňuje přeskočit jednu i více vrstev v síti a tím lépe optimalizovat model pro vyšší přesnost. (He et al. 2015)

Ověření modelu bylo provedeno s defaultně nastavenými a doporučenými 10 % dat.

Výstupem fáze trénování modelu je uložený model do definovaného adresáře. V adresářové struktuře je uložen soubor s definicí modelu ve formátu vhodném pro navazující nástroje, obsahující informace o natrénovaném modelu a adresář s charakteristikami modelu. Důležitou součástí výstupů je soubor obsahující metriky hodnotící natrénovaný model – precision, recall a f1. Soubor s metrikami také obsahuje reprezentativní vzorky vyhodnocení a srovnává data manuálně klasifikovaná a predikovaná tímto modelem.



Obr. 24 Srovnání dat manuálně klasifikovaných (vlevo) a predikovaných modelem (vpravo) ze souboru metrik procesu trénování modelu

5.3 Aplikování modelu na testovací území

V poslední fázi případové studie došlo k testování a aplikování natrénovaných modelů na datech testovacího území. Testovací data do trénovací fáze modelu nevstupovala, a tudíž jsou pro model neznámé. Aplikování modelů bylo provedeno pomocí dvou nástrojů. Pro aplikování modelů s přístupem per pixel byl použit nástroj Classify Pixels Using Deep Learning. Vstupem do nástroje byl oříznutý rastr testovací oblasti a definiční soubor testovaného modelu. Výstupem modelu byl rastr ve formátu TIF s klasifikovanými pixely stromů.

Testování modelů s přístupem detekce objektů bylo provedeno pomocí nástroje Detect Object Using Deep Learning. Vstupem do nástroje byl stejný oříznutý rastr testovací oblasti, tak jako u přístupu per pixel a definiční soubor modelu. Výstupem detekce stromů byla na rozdíl od per pixel přístupu vrstva ve formátu SHP obsahující pravoúhelníky predikující výskyt stromů.

5.4 Výstupy případové studie

- Trénovací data
- Modely
- Metriky
- Predikovaná data

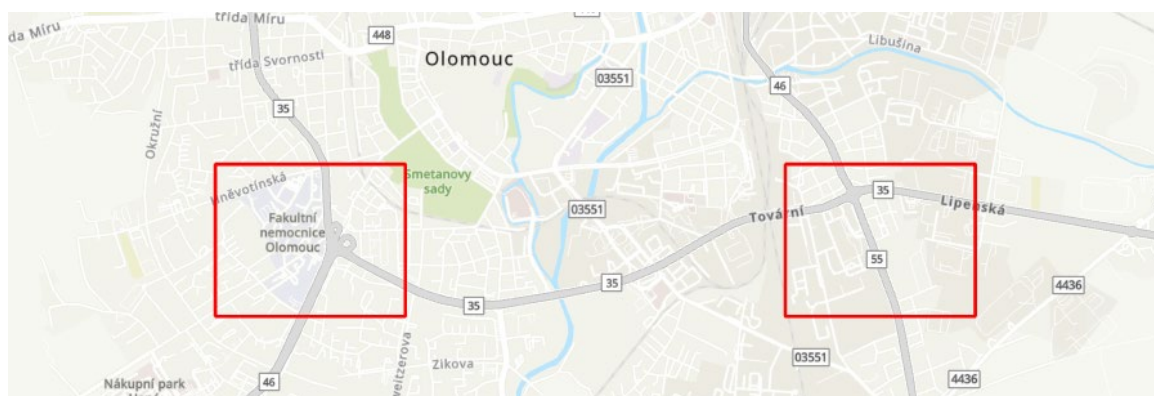
6 PŘÍPADOVÁ STUDIE 3: KLASIFIKACE DAT LIDAR

Poslední případová studie se věnuje možnostem automatické klasifikace bodových mračen pořízených metodou LIDAR. V rámci případové studie došlo k testování dostupných programů a jejich automatizovaných nástrojů pro klasifikaci dat bodových mračen.

Katedrou geoinformatiky byla pro tyto účely zpřístupněna data z leteckého lidaru v oblasti CHKO Litovelského Pomoraví a Olomouce. Cílem poslední případové studie bylo testování rozdílu mezi nástroji na vybraných klasifikačních třídách v urbánních oblastech. V CHKO Litovelské Pomoraví byla pro tyto účely vybrána data za dvě obce, a to Střeň a Březová, které mají charakter vesnického typu urbánní oblasti. V Olomouci byly za městský charakter území zvoleny dva výřezy pokrývající co nejširší rozsah typů zástavby urbánních ploch i vegetace.



Obr. 25 Zájmové oblasti reprezentující vesnický charakter území v CHKO Litovelské Pomoraví – Střeň a Březová



Obr. 26 Zájmové oblasti reprezentující městských charakter území v Olomouci

6.1 Klasifikace dat LIDAR v ArcGIS Pro

Program ArcGIS Pro pracuje s daty LIDAR pomocí LAS datasets. Jedná se o datovou sadu, která uchovává odkazy na soubory LAS na disku i s dalšími prvky povrchu. Soubor s koncovkou .las je binární formát pro ukládání dat leteckého lidarů. LAS dataset umožňuje rychlou a snadnou práci s tímto formátem i jejich statistickými informacemi. Výhodou datové sady je, že neimportuje bodová data obsažená v souborech, ale pouze na ně odkazuje. (Esri 2024h)

Lidarová data byla Katedrou geoinformatiky zpřístupněna v komprimovaném formátu LAZ, který není LAS datovou sadou podporován. Pro nahrání do programu muselo tedy nejdříve dojít ke konverzi. To bylo provedeno v ArcGIS Pro nástrojem Convert LAS, který kromě konverze souboru automaticky provede i vytvoření nového LAS datasetu.


Program ArcGIS Pro v nástrojové sadě 3D Analyst Tools nabízí řadu automatizovaných klasifikačních postupů. Mezi základní patří klasifikace povrchu (Ground) a šumu (Noise). Pokročilejšími automatickými klasifikačními úlohami jsou klasifikace budov (Buildings) a překryvů (Overlaps).

6.1.1 Klasifikace třídy povrchu země (Ground)

Klasifikace povrchu je provedena pomocí nástroje Classify LAS Ground. Tento nástroj je velmi jednoduchý a intuitivní. Vstupem do nástroje je LAS dataset. Nástroj nabízí možnost výběru metody detekce povrchu: defaultně nastavenou standardní klasifikaci, konzervativní a agresivní. Standardní metoda klasifikace umožňuje zachytit pozvolné zvlnění topografie terénu, které by konzervativní varianta obvykle přehlédla. V porovnání s agresivní metodou však nedokáže zachytit ostré sklony svahu a často a ostře se měnící reliéf. Konzervativní metoda používá přísnější pravidla omezení variability sklonu terénu, které jí umožňují lépe odlišit terén od nízké vegetace. Je vhodná pro topografické poměry s minimálním zakřivením. Opakem je metoda agresivní, sloužící k detekci povrchu země v oblastech s ostřejším reliéfem jako jsou hřebeny a vrcholy kopců. Tato metoda je nevhodná pro použití v městských a rovinatých venkovských oblastech, u kterých může docházet k chybné klasifikaci budov a výše položených objektů do třídy povrchu země.

Dalším nastavitelným parametrem je výběr detekčního algoritmu. Na výběr je mezi nejnovějším a algoritmem první generace. Nejnovější algoritmus nabízí vylepšenou práci se šumem a odlehlými body.

Nástroj také nabízí využít již klasifikované body třídy povrchu a pouze nově klasifikované body do třídy přidat. Toto nastavení je vhodné využít při agresivním nastavení metody detekce. Dále lze nastavit rozlišení digitálního modelu výšek a výpočet statistik. (Esri 2024c)



Obr. 27 Reprezentativní ukázka klasifikace třídy Ground (body hnědé barvy) (Esri 2024c)

6.1.2 Klasifikace šumu

Nástroj Classify LAS Noise klasifikuje body do třídy šumu na základě odchylek prostorových vlastností bodů. Šum v datech má nepříznivý dopad na analýzu a klasifikaci dat. Odhalení, klasifikace a redukce šumu je velmi důležitou částí zpracování tohoto typu dat. Šum může být způsoben odrazem bodů od letících ptáků, nečistot v ovzduší, vodní plochy a dalších podnětů způsobujících rozptýlení impulsů.

Proces filtrace šumu je klíčovým krokem zpracování pro správné výsledky odvozených dat jako jsou digitální modely a další.

Nástroj nabízí výběr metod filtrace šumu a to, na základě izolace bodů, relativní výšky od země a filtrace dle absolutní výšky. Výšky všech metod lze manuálně nastavit a testovat dle potřeb vstupujících dat. Součástí výpočtu je také přepočítání statistik. (Esri 2024d)

6.1.3 Klasifikace budov


Kromě základních klasifikačních úloh program ArcGIS Pro nabízí pokročilý nástroj pro klasifikaci střech a stěn budov. Je dostupný v sadě nástrojů 3D Analyst v sekci bodových mračen.

Nástroj požaduje nastavení minimální výšky střechy a její minimální plochy. Defaultně jsou nastaveny hodnoty 2 metry výšky a 6 m² plochy.

Parametry dále nabízí výběr metody klasifikace z možností standartní, konzervativní a agresivní, tak jako u klasifikace třídy povrchu země. Agresivní metoda detekuje body střechy s relativně vysokou tolerancí k odlehlým hodnotám. Metodu je vhodné využít pro dobře kalibrovaná data. Výchozím nastavením klasifikace je standartní metoda, která rovinné charakteristiky střech detekuje s relativně střední tolerancí pro nepravidelné body. Konzervativní metoda má nejnižší toleranci pro nepravidelné body a je vhodná v případech, kdy nelze jednoznačně rozeznat rovinu střechy od okolních rovinných ploch pokrytých body.

Mezi další nastavení patří možnosti výběru, zda se jedná o bodové mračno vytvořené fotogrammetrickým způsobem.

V případě, že chceme do třídy budov přidat stěny nebo střešní konstrukce jako například komíny, nástroj tyto možnosti nabízí v položkách klasifikací prvků nad a pod střechou. (Esri 2024b)



Obr. 28 Reprezentativní ukázka klasifikace do třídy budov (červené body) (Esri 2024b)

6.1.4 Klasifikace stromů a vysoké vegetace


Poslední testovanou klasifikační třídou byla vysoká vegetace (stromy). Tato úloha klasifikace se již v programu ArcGIS Pro neřadí mezi automatické klasifikace bodových mračen, ale využívá klasifikačních metod hlubokého učení a nástroje Classify Point Cloud Using Trained Model. Klasifikace stromů a vysoké vegetace je řešena metodami DL, z důvodu složitosti geometrické struktury. Zatímco tradiční, jednodušší prostředky nejsou schopné tyto struktury zachytit, modely hlubokého učení jsou toho velmi schopné s vynikajícími výsledky.

Pro účely této klasifikace byl stažen volně dostupný model Tree Point Classification, vyvinutý a natrénovaný společností Esri. Tento model byl natrénován na souborech dat z leteckého lidarů a je pro tato data nejvhodnější. Model využívá architekturu konvolučních neuronových sítí PointCNN. (Esri 2021)

Tabulka 1 Přesnost klasifikačního modelu na souboru validačních dat:

	Precision	Recall	f1
Stromy / Vysoká vegetace	0,975374	0,965929	0,970628

Natrénovaný model je možné využít pomocí nástroje Classify Point Cloud Using Trained Model. Do nástroje je načten požadovaný LAS dataset, odkazující na mračno bodů a definiční soubor natrénovaného modelu. V případě, že jsou již některé třídy mračna klasifikovány, parametrem nástroje je možné určit třídy, které do klasifikace nebudou použity.

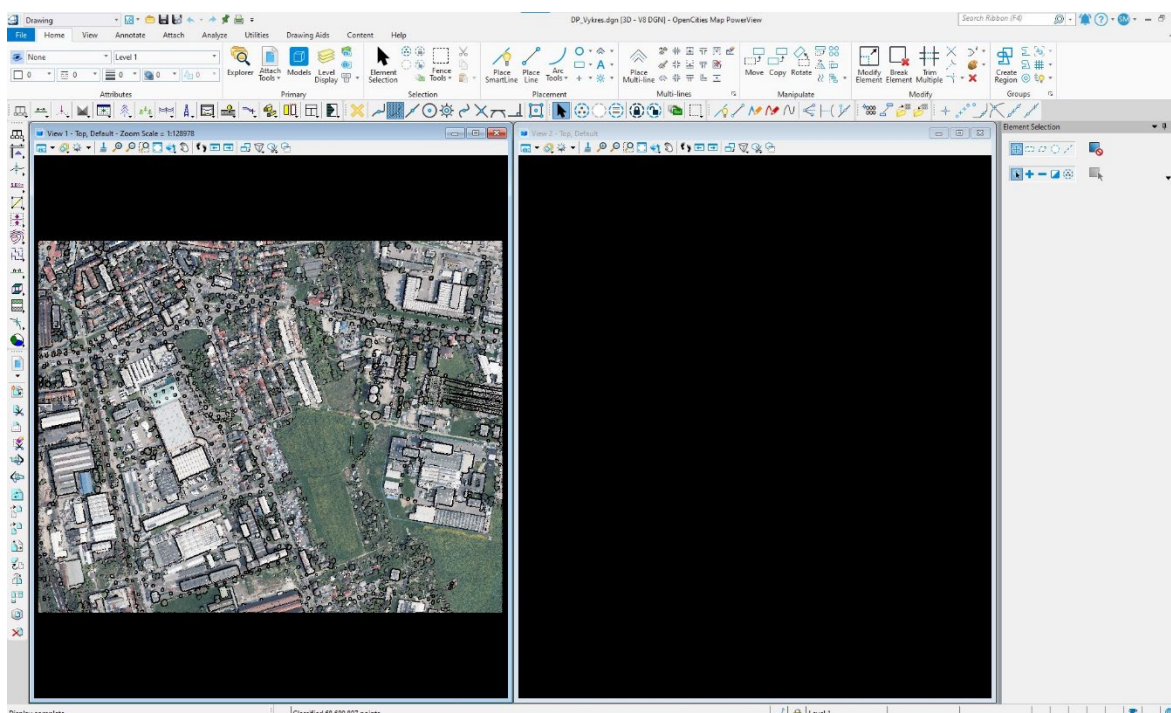


Obr. 29 Reprezentativní ukázka klasifikace do třídy stromů a vysoké vegetace (Esri 2021)

6.2 Klasifikace dat LIDAR v programu OpenCities Map

V rámci poslední případové studie bylo provedeno testování programu OpenCities Map Power View od společnosti Bentley Systems. Tento software je speciálně navržen pro práci s daty bodových mračen a daty dálkového průzkumu země. OpenCities nabízí širokou škálu nástrojů určených pro detailní analýzu dat v 3D prostoru. Software je tvořen moduly TerraSolid, TerraScan a mnoha dalšími, postavenými na programu MicroStation. Mezi hlavní funkce tohoto softwaru patří široké možnosti automatizovaných klasifikací bodových mračen, které slouží jako vstupní data pro nadstavbové nástroje.

Nadstavbové nástroje jsou zaměřeny na pokročilou digitalizaci a mapování měst (tvorbu digitálních dvojčat), správu sítí (mapování a modelování elektrických vedení, železnic, cest) a na mnoho dalších průmyslových odvětví. (TerraSolid 2024c)



Obr. 30 Ukázka prostředí OpenCities Map PowerView v modulu Drawing

V tomto programu došlo k testování dostupných automatizovaných klasifikací do dvou typů: třída povrchu země (Ground) a nadzemních prvků.

6.2.1 Klasifikace třídy povrchu země

V procesu zpracování dat LIDAR v programu TerraSolid je klasifikace třídy povrchu země (Ground) považována za základní a klíčovou úlohu. Tato klasifikace je nezbytná, protože poskytuje základní informace pro další, pokročilejší klasifikování do podrobnějších tříd.

Před samotnou klasifikací do třídy Ground proběhla série přípravných kroků. Prvním krokem bylo shlazení mračna bodů. Tento proces zahrnuje aplikaci algoritmů pro snížení variability dat a zlepšení celkové kvality datové sady.

Následně došlo k očištění dat od šumu. Izolované body, které by mohly být považovány za šum, byly odfiltrovány do speciální třídy. Tato třída není pro další zpracování využita, což zajišťuje, že pouze relevantní a kvalitní data jsou použita pro další klasifikování dat.

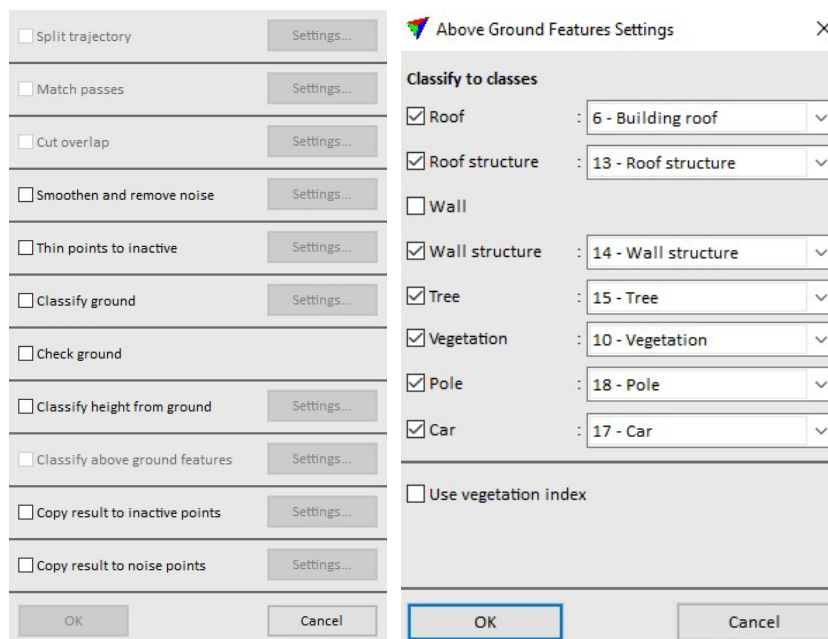
Po těchto přípravných krocích byla data připravena pro klasifikaci do třídy Ground. Tento proces zahrnuje aplikaci algoritmů, které identifikují body odpovídající povrchu země. Klasifikace probíhá v iteracích tvorbou triangulovaného modelu. Proces začíná výběrem místních nízkých bodů, které jsou jistými zásahy na zem. V dalším kroku rutina vytváří TIN (Triangulated irregular network) model povrchu. V první iteraci je většina modelu pod úrovní povrchu a pouze vrcholy se ho dotýkají. V dalších iteracích dochází ke zvyšování modelu a přidávání více a více bodů. Hlavním parametrem ovlivňujícím jaké body jsou přidány do povrchu je Iteration angle. Menší hodnoty jsou vhodné pro rovinný terén a vyšší hodnoty (hodnota 10) pro hornatý terén. Dalším důležitým parametrem je Iteration distance zajišťujícím, že nedojde k velkým skokům nahoru ve výšce při iteraci, pokud jsou trojúhelníky velké. Tím se eliminuje přidávání bodů nízké vegetace a nižších částí budov do třídy Ground. (TerraSolid 2024b)

Výstupem klasifikace jsou data ve výchozí třídě s hodnotou 1 a třídě povrchu 2.

6.2.2 Klasifikace dat do nadzemních prvků

Prvním typem rutiny klasifikace bodů nad povrchem je Classify height from ground. Tato rutina je závislá na referenčním povrchu, který je nejdříve nutné vytvořit. Nejčastěji je používána předem klasifikovaná třída Ground, popsaná výše v kapitole 6.2.1. Rutina Classify height from ground klasifikuje body nacházející se v daném výškovém rozmezí vzhledem k referenčnímu povrchu. Rutina je využívána například pro klasifikace bodů do různých tříd vegetace. Zejména je ale používána pro předzpracování pro podrobnější klasifikace, například do třídy budov, elektrických vedení nebo k detekci stromů. (TerraSolid 2024a)

Předzpracování mračen touto rutinou také využívá rutina Classify above ground features, která nabízí podrobnou klasifikaci do vybraných tříd: střech, střešních konstrukcí, zdí, konstrukčních prvků zdí, stromů, vegetace, sloupů a aut. Výstupem této rutiny je detailně klasifikované mračno do předem vybraných tříd.



Obr. 31 Posloupnost kroků klasifikace v programu OpenCities Map PowerView

7 VÝSLEDKY

Kapitola výsledky podává podrobné informace o výstupech a výsledcích všech případových studií diplomové práce. Výsledky z jednotlivých případových studií jsou rozděleny a podrobně popsány v dílčích podkapitolách.

7.1 Výsledky první případové studie: Vysoká hole

Mezi výsledky první případové studie patří výstupní natrénované modely, jejich metriky a klasifikovaná data.

V rámci první případové studie došlo k testování metod strojového učení pro účely per pixel klasifikace obrazových dat. Byly testovány klasifikační algoritmy dostupné v knihovně scikit-learn, z nichž byly vybrány klasifikátory kNN a random forest. Tyto klasifikátory byly využity v naprogramovaných skriptech pro trénování modelu.

Trénování modelů proběhlo pomocí dvou přístupů za využití pouze referenčních dat RGB (barevné ortomozaiky pouze s informacemi viditelné části elektromagnetického záření) a pomocí kombinace referenčních dat RGB a dat relativních výšek objektů nad terénem.

Výsledkem tak byly 4 modely:

- Model 1
 - Klasifikátor: kNN
 - Vstupní trénovací data: referenční data RGB
- Model 2
 - Klasifikátor: random forest
 - Vstupní trénovací data: referenční data RGB
- Model 3
 - Klasifikátor: kNN
 - Vstupní trénovací data: referenční data RGB, data relativních výšek
- Model 4
 - Klasifikátor: random forest
 - Vstupní trénovací data: referenční data RGB, data relativních výšek

Testování modelů proběhlo na vytyčeném testovacím území rozděleném na dvě oblasti.

7.1.1 Výsledky modelu 1


První model byl natrénován pomocí základního klasifikátoru kNN a referenčními RGB daty. Proto od tohoto modelu nebyly očekávány zvláště dobré výsledky, což se testováním na obou testovacích oblastech potvrdilo.

Celková přesnost modelu u první oblasti dosáhla pouze hodnoty 20,897 %. Na základě metrik a zejména matice záměn je možné konstatovat, že největším problémem modelu byla predikce do tříd kleč, skály a kameny a keře. Model chybně vyhodnotil 795 488 pixelů jako kleč, která se ale v testovací oblasti 1 dle skutečnosti (manuální klasifikace) vůbec nevyskytovala. Stejně tak chybně vyhodnotil 797 pixelů jako skály a kameny, které se také v oblasti 1 neměly vyskytovat. Velký problém měl model také s třídou keře, které byly téměř z 80 % chybně zařazeny do třídy tráva a z 12 % do třídy stromů. Třída keře nabývá v mtrice precision výborných hodnot. To je pouze z důvodu, že do této třídy bylo zařazeno pouze 9 931 pixelů, ze kterých bylo 8 494 vyhodnoceno správně. Správně mělo být do třídy keře vyhodnoceno 4 177 367 pixelů a tato metrika se v tomto případě stává pro hodnocení irelevantní.

Tabulka 2 Matice záměn a metriky Modelu 1 v testovací oblasti 1

Celková přesnost modelu: 20,897 %			Predikce				
			1	2	3	4	6
			Tráva	Stromy	Kleč	Keře	Skály a kameny
Skutečnost	1	Tráva	677406	47121	30642	1196	58
	2	Stromy	257434	620680	440292	239	65
	3	Kleč	0	0	0	0	0
	4	Keře	3338505	505138	324554	8496	674
	6	Skály a kameny	0	0	0	0	0

precision	0,15852	0,52917	0	0,8555	0
recall	0,89554	0,47067	0	0,00203	0
f1-score	0,26936	0,49821	0	0,00406	0
support	756423	1318710	0	4177367	0




Obr. 32 Porovnání výsledků klasifikace (vlevo) modelu 1 v testovací oblasti 2 s manuální klasifikací (uprostřed) a ortomozaikou (vpravo)

V případě oblasti 2 byly výsledky velmi podobné. Celková přesnost modelu se zlepšila o necelých 12 % na hodnotu 32,6026 %. Model měl i u oblasti 2 stejný problém s třídou kleč, u které byla tato třída chybně vyhodnocena, ale ve skutečnosti se vůbec nevyskytovala. Stejně jako u oblasti 1 došlo k velmi špatné predikci keřů, zaměňovaných do třídy tráva a stromy. Velmi špatně model také detekoval skály a kameny, které nejčastěji zaměňoval do třídy tráva.

Tabulka 3 Matice záměn a metriky Modelu 1 v testovací oblasti 2

Celková přesnost modelu: 32,6026 %		Predikce					
		0	1	2	3	4	
		Tráva	Stromy	Kleč	Keře	Skály a kameny	
Skutečnost	0	Tráva	1811757	38549	14243	408	7
	1	Stromy	107294	222344	155815	440	0
	2	Kleč	0	0	0	0	0
	3	Keře	3172259	426275	274925	4263	98
	4	Skály a kameny	15320	2120	5090	1180	113

precision	0,35479	0,32257	0	0,67763	0,518348624
recall	0,97147	0,4576	0	0,0011	0,004743315
f1-score	0,51975	0,3784	0	0,0022	0,009400607
support	1864964	485893	0	3877820	23823



Obr. 33 Porovnání výsledků klasifikace (vlevo) modelu 1 v testovací oblasti 2 s manuální klasifikací (uprostřed) a ortomozaikou (vpravo)

7.1.2 Výsledky modelu 2


Druhý model byl natrénován pomocí robustnějšího klasifikátoru random forest a referenčními RGB daty.

Celková přesnost modelu u první oblasti dosáhla výrazně vyšší úspěšnosti a to hodnoty 49,963 %. Na základě metrik lze konstatovat, že došlo k výraznému zlepšení modelu u třídy keře, kde u oblasti 1 bylo do této třídy správně zařazeno 2 328 891 pixelů , zatímco u oblasti 1 s modelem 1 pouze 8 494. Tak jako u modelu 1 i tento model chybně klasifikoval pixely do tříd kleč, skály a kameny, které se v této oblasti ve skutečnosti nevyskytovaly.

Tabulka 4 Matice záměn a metriky Modelu 2 v testovací oblasti 1

Celková přesnost modelu: 49,963 %			Predikce				
			1	2	3	4	6
			Tráva	Stromy	Kleč	Keře	Skály a kameny
Skutečnost	1	Tráva	485663	21888	61186	187385	301
	2	Stromy	111640	311467	758583	136824	196
	3	Kleč	0	0	0	0	0
	4	Keře	1221221	122269	503345	2328891	1641
	6	Skály a kameny	0	0	0	0	0

precision	0,26706	0,68361	0	0,8778	0
recall	0,64205	0,23619	0	0,5575	0
f1-score	0,37722	0,35108	0	0,68191	0
support	756423	1318710	0	4177367	0




Obr. 34 Porovnání výsledků klasifikace (vlevo) modelu 2 v testovací oblasti 1 s manuální klasifikací (uprostřed) a ortomozaikou (vpravo)

U testovací oblasti 2 byly výsledky téměř totožné. Celková přesnost modelu dosáhla hodnoty 52,4988 %. Došlo k chybné detekci třídy kleč. Oproti modelu 1 dokázal model klasifikovat více pixelů do třídy skály, ale stále s extrémně nízkou úspěšností.

Tabulka 5 Matice záměn a metriky Modelu 2 v testovací oblasti 2

Celková přesnost modelu: 52,4988 %		Predikce					
		0	1	2	3	4	
		Tráva	Stromy	Kleč	Keře	Skály a kameny	
Skutečnost	0	Tráva	1622918	32664	55875	153429	78
	1	Stromy	48224	123280	270042	44306	41
	2	Kleč	0	0	0	0	0
	3	Keře	1563410	159945	618560	1535597	308
	4	Skála a kameny	6857	757	5276	10238	695

precision	0,50068	0,38933	0	0,88072	0,61942959
recall	0,87021	0,25372	0	0,39599	0,029173488
f1-score	0,63564	0,30722	0	0,54634	0,05572259
support	1864964	485893	0	3877820	23823



Obr. 35 Porovnání výsledků klasifikace (vlevo) modelu 2 v testovací oblasti 2 s manuální klasifikací (uprostřed) a ortomozaikou (vpravo)

7.1.3 Výsledky modelu 3

Třetí model byl vytvořen přístupem kombinujícím referenční RGB data a data relativních výšek objektů nad terénem. Jako klasifikační algoritmus byl testován klasifikátor kNN.


Od klasifikačního modelu testujícího tento přístup byly očekávány lepší výsledky díky více informacím, které byly tomuto modelu dodány. Tato domněnka se následujícím testováním potvrdila. Celková přesnost modelu 3 dosáhla v testovací oblasti 1 hodnoty 51,7874 %. Při porovnání s klasifikátorem kNN modelu 1 došlo ke zlepšení úspěšnosti o 30,8904 %. Model 3, nicméně tak jako předchozí modely, chybně klasifikoval pixely do tříd kleč, skály a kameny i přes to, že se v této oblasti nevyskytují.

Na základě metriky f-1 score, která objektivně hodnotí falešně pozitivní i falešně negativní hodnoty lze vidět zlepšení při klasifikaci keřů a stromů. Jako nejhorší třídu v tomto ohledu lze hodnotit třídu tráva, do které bylo zařazeno velké množství pixelů, které měly být klasifikovány jako keře.

Tabulka 6 Matice záměn a metriky Modelu 3 v testovací oblasti 1

Celková přesnost modelu: 51,7874 %			Predikce				
			1	2	3	4	6
			Tráva	Stromy	Kleč	Keře	Skály a kameny
Skutečnost	1	Tráva	459614	60959	55162	180590	98
	2	Stromy	99061	607066	547138	65210	235
	3	Kleč	0	0	0	0	0
	4	Keře	1319791	286831	398879	2171330	536
	6	Skály a kameny	0	0	0	0	0

precision	0,2446752	0,63577	0	0,89831	0
recall	0,6076151	0,46035	0	0,51978	0
f1-score	0,3488678	0,53402	0	0,65853	0
support	756423	1318710	0	4177367	0



Obr. 36 Porovnání výsledků klasifikace (vlevo) modelu 3 v testovací oblasti 1 s manuální klasifikací (uprostřed) a ortomozaikou (vpravo)


U testovací oblasti 2 byly výsledky modelu 3 velmi podobné. Celková přesnost modelu dosáhla hodnoty 50,0659 %. Velmi nízké přesnosti klasifikace model dosahoval u třídy skály a kameny, které zaměňoval zejména za třídu tráva. Velmi podobné výsledky dosahovaly třídy keře, stromy a tráva, které se pohybovaly u metriky f1-score okolo hodnoty 50 %.

Tak jako u předchozích modelů došlo k chybné klasifikaci do třídy kleč nevyskytující se v této oblasti.

Tabulka 7 Matice záměn a metriky modelu 3 v oblasti 2

Celková přesnost modelu: 50,0659 %		Manuální klasifikace					
		1	2	3	4	6	
		Tráva	Stromy	Kleč	Keře	Skály a kameny	
Predikce	1	Tráva	1573818	38752	30034	222326	34
	2	Stromy	47284	221593	186168	30818	30
	3	Kleč	0	0	0	0	0
	4	Keře	2125671	150355	266780	1334865	149
	6	Skály a kameny	13885	356	1463	8023	96

precision	0,4185	0,53908	0	0,83636	0,310679612
recall	0,84389	0,45605	0	0,34423	0,004029719
f1-score	0,55952	0,4941	0	0,48772	0,007956241
support	1864964	485893	0	3877820	23823



Obr. 37 Porovnání výsledků klasifikace (vlevo) modelu 3 v testovací oblasti 2 s manuální klasifikací (uprostřed) a ortomozaikou (vpravo)


7.1.4 Výsledky modelu 4

Poslední model byl natrénován stejným přístupem jako model 3, s rozdílem využití robustnějšího klasifikátoru random forest. Na základě předešlých testování byly od tohoto modelu očekávány nejlepší výsledky, což se následně potvrdilo. Celková přesnost klasifikace u testované oblasti 1 dosáhla hodnoty 57,7068 %. Oproti modelu s klasifikátorem kNN došlo ke zlepšení o 7,7438 %. Na testovací oblasti 1 model vykazoval velmi dobré výsledky u třídy keře, kde metrika f1-score dosáhla hodnoty 73,671 %. Model naopak měl větší problém s vyhodnocováním třídy tráva, kde hodnota metriky f-1 score dosáhla pouze na 37,643 %. Tak jako u předchozích modelů došlo k chybnému vyhodnocení pixelů do tříd kleče, skály a kameny, které se v oblasti nevyskytovaly.

Tabulka 8 Matice záměn a metriky modelu 4 v oblasti 1

Celková přesnost modelu: 57,7068 %		Manuální klasifikace					
		1	2	3	4	6	
		Tráva	Stromy	Kleč	Keře	Skály a kameny	
Predikce	1	Tráva	394463	56314	70353	235062	231
	2	Stromy	64795	592639	576344	82055	2877
	3	Kleč	0	0	0	0	0
	4	Keře	880133	214592	459627	2621016	1999
	6	Skály a kameny	0	0	0	0	0

precision	0,29451	0,68629	0	0,89207	0
recall	0,52148	0,44941	0	0,62743	0
f1-score	0,37643	0,54314	0	0,73671	0
support	756423	1318710	0	4177367	0




Obr. 38 Porovnání výsledků klasifikace (vlevo) modelu 4 v testovací oblasti 1 s manuální klasifikací (uprostřed) a ortomozaikou (vpravo)

U testované oblasti 2 model dosáhl nejvyšší celkové přesnosti a to 58,9154 %. Přesnost klasifikace tříd byla velmi podobná, kde třídy keře a tráva se pohybovaly kolem hodnot 60 % u metriky f1-score a třída stromů dosáhla hodnoty 51,9177 %. Model nebyl úspěšný při klasifikaci třídy skály a kameny, kde docházelo k chybné klasifikaci do tříd tráva a keře. Tak jako u předchozích modelů došlo k chybné klasifikaci třídy kleč, která se v oblasti nevyskytovala.

Tabulka 9 Matice záměn a metriky modelu 4 v oblasti 2

Celková přesnost modelu: 58,9154 %		Manuální klasifikace					
		1	2	3	4	6	
		Tráva	Stromy	Kleč	Keře	Skály a kameny	
Predikce	1	Tráva	1473623	35760	35732	319752	97
	2	Stromy	24815	215410	204652	40778	238
	3	Kleč	0	0	0	0	0
	4	Keře	1543518	92672	246702	1994486	442
	6	Skály a kameny	11908	78	346	11325	166

precision	0,482544	0,626338	0	0,842857	0,176033934
recall	0,790162	0,443328	0	0,514332	0,006968056
f1-score	0,599176	0,519177	0	0,638832	0,013405475
support	1864964	485893	0	3877820	23823



Obr. 39 Porovnání výsledků klasifikace (vlevo) modelu 4 v testovací oblasti 2 s manuální klasifikací (uprostřed) a ortomozaikou (vpravo)

7.1.5 Spektrální analýza tříd

Tabulka 10 Spektrální analýza klasifikačních tříd testovací oblasti – srovnání průměrných hodnot tříd manuální klasifikace a predikce

Průměrné hodnoty spektrálních informací tříd klasifikace						
	Dle manuální klasifikace			Dle predikované klasifikace		
	Pásmo R	Pásmo G	Pásmo B	Pásmo R	Pásmo G	Pásmo B
Keře	90,04	79,82	39,84	78,33	69,24	33,65
Tráva	131,09	113,61	67,44	132,53	114,28	64,52
Stromy	98,42	98,36	38,37	104,47	103,47	39,30
Skály a kameny	130,52	125,57	95,25	175,49	175,36	144,96
Kleč	null	null	null	74,44	76,22	33,23

Tabulka 11 Spektrální analýza klasifikačních tříd trénovací oblasti – průměrné hodnoty tříd manuální klasifikace

Průměrné hodnoty spektrálních informací tříd klasifikace			
	Dle manuální klasifikace		
	Pásmo R	Pásmo G	Pásmo B
Keře	96,44237	81,03019	43,04284
Tráva	158,3054	134,6086	83,56665
Stromy	85,50242	84,35846	37,03795
Skály a kameny	122,342	122,1992	110,154
Kleč	55,12791	56,26306	25,60231

7.2 Výsledky druhé případové studie: Vicínov

Druhá případová studie byla zaměřena na detekci stromů pomocí metod hlubokého učení dostupných v programu ArcGIS Pro. Detekce stromů proběhla dvěma metodami, a to per pixel klasifikací označující pixely, které odpovídají stromům v sadu a objektovou detekcí.

Výsledkem případové studie byly dvěma výše zmíněnými přístupy natrénované modely na vybraném trénovacím území a výsledná data z automatické klasifikace.

Výsledné modely per pixel klasifikace:

- Model 1:
 - Typ modelu: DeepLabV3
 - Počet epoch: 100
 - Základní síť: ResNet-34
- Model 2:
 - Typ modelu: MMSegmentation
 - Počet epoch: 100
 - Základní síť: ResNet-34
- Model 3:
 - Typ modelu: Pyramid Scene Parsing (PSPNet)
 - Počet epoch: 30
 - Základní síť: ResNet-34
- Model 4:
 - Typ modelu: U-Net
 - Počet epoch: 30
 - Základní síť: ResNet-34

Výsledné modely detekce objektů:

- Model 1:
 - Typ modelu: RetinaNet
 - Počet epoch: 20
 - Základní síť: ResNet-34
- Model 2:
 - Typ modelu: RetinaNet
 - Počet epoch: 30
 - Základní síť: ResNet-34
- Model 3:
 - Typ modelu: RetinaNet
 - Počet epoch: 100
 - Základní síť: ResNet-34

7.2.1 Výsledky přístupu per pixel klasifikace

Detekce stromů přístupem per pixel klasifikace byla úspěšně provedena pomocí 4 vybraných natrénovaných modelů. Tyto modely byly natrénovány nad trénovacím územím s 249 manuálně zakreslenými stromy. Velké množství CNN modelů hlubokého učení bylo podrobně testováno, ze kterých byly vybrány 4 nejúspěšnější.

Tabulka 12 Metriky natrénovaných modelů CNN per pixel klasifikace


	Stromy			
	U-Net	DeepLabV3	MMSegmentation	PSPNet
precision	0,761562	0,84688	0,829971	0,824804
recall	0,421519	0,546251	0,624971	0,749034
f1-score	0,542673	0,664129	0,713029	0,785095

Dle metrik byl nejméně úspěšný model s typem modelu U-Net, který dokázal správně zařadit 42,1519 % pixelů ze všech pixelů odpovídající třídě stromy při validaci modelu. Tento model také dosáhl nejnižší metriky f1-score s hodnotou 54,2673 %, která udává harmonický průměr mezi metrikami precision a recall.




Obr. 40 Výsledky per pixel klasifikace pomocí modelu s typem U-Net (modrá barva) při porovnání s manuálně zakreslenými stromy (polygony se žlutým obrysem)

Druhým nejméně úspěšným modelem byl vyhodnocen model používající typ DeepLabV3 s hodnotou metriky f1-score 66,4129 %. Tento model byl nicméně nejúspěšnější v metrice precision s hodnotou 84,688 %, která podává informaci o tom, kolik procent z vyhodnocených pixelů do třídy stromy bylo dle manuální klasifikace vyhodnoceno správně. Velkým nedostatkem modelu je jeho chybné vyhodnocování na okrajích vstupujících rastrových dat, které je nutné následně očistit.



Obr. 41 Výsledky per pixel klasifikace pomocí modelu s typem DeepLabV3 (modrá barva) při porovnání s manuálně zakreslenými stromy (polygony se žlutým obrysem)

Druhým nejúspěšnějším modelem je model využívající typ MMSegmentation s hodnotou f1-score 71,3029 %. Tento model má velmi vysoké hodnoty všech metrik a lze označit za velmi úspěšný. Jeho velkou výhodou je, že nedochází k problémům při vyhodnocování okrajových míst vstupních rastrů, tak jako u modelů s typem DeepLabV3 a PSPNet.



Obr. 42 Výsledky per pixel klasifikace pomocí modelu s typem MMSegmentation (modrá barva) při porovnání s manuálně zakreslenými stromy (polygony se žlutým obrysem)

Dle metrik je jako nejúspěšnější model vyhodnocen model s typem PSPNet. Tento model u metriky f1-score dosáhl nejvyšší hodnoty 78,5095 %. Dále dosáhl nejvyšší hodnoty metriky recall s velmi vysokou hodnotou 74,9034 %. Tato metrika udává v procentech počet správně vyhodnocených pixelů do třídy stromy v porovnání se všemi pixely, které byly do této třídy vyhodnoceny manuálně. Nevýhodou tohoto typu modelu je chybné vyhodnocení pixelů na okrajích vstupních rastrů, které je nutné následně očistit.



Obr. 43 Výsledky per pixel klasifikace pomocí modelu s typem PSPNet (modrá barva) při porovnání s manuálně zakreslenými stromy (polygony se žlutým obrysem)

7.2.2 Výsledky přístupu detekce objektů

Detekce stromů s přístupem Object detection byla testována pomocí velkého množství modelů. Z testovaných modelů byl vybrán jako přijatelný pouze typ modelu RetinaNet, který bohužel také nelze považovat za úspěšný. Model RetinaNet byl testován s různými nastaveními parametrů, maximálními počty průchodů (epochy), ale ani tak výsledek nebyl dostatečně dobrý. Všechny modely při testování na testovací oblasti vykazovaly obrovské množství chybných detekcí a zejména malých polygonů, které bylo nutné pracně vyčistit. Metriky modelu vypočtené na validačních datech hodnotí přesnost detekce 42,81 % s nastavením maximálního počtu průchodů na 30 epoch. Při použití tohoto modelu ale dochází k detekci příliš velkého množství falešně pozitivních ploch a ani tento nejlépe hodnocený model není možné použít.



Obr. 44 Výsledky objektové detekce stromů pomocí modelu RetinaNet s nastavením 20 epoch – po vyčištění



Obr. 45 Výsledky objektové detekce stromů pomocí modelu RetinaNet s nastavením 30 epoch



Obr. 46 Výsledky objektové detekce stromů pomocí modelu RetinaNet s nastavením 100 epoch

7.3 Výsledky třetí případové studie: Klasifikace dat LIDAR

Poslední případová studie se zabývala možnostmi automatických klasifikací dat LIDAR v dostupných programech. Klasifikace byly testovány v programech ArcGIS Pro a OpenCities Map PowerView. K testování klasifikačních úloh byly vybrány třídy povrch, vysoká vegetace a budovy. Tyto třídy byly vybrány na základě dostupných klasifikací v softwaru ArcGIS Pro, aby bylo možné výsledky těchto dvou softwarů porovnat.

Výsledkem této případové studie jsou klasifikovaná data LIDAR a statistiky bodů mračen.

7.3.1 Výsledky klasifikace dat LIDAR v ArcGIS Pro

Tabulka 13 Počet zařazených bodů do klasifikačních tříd


	OLONMOUC 9-1_2	OLONMOUC 7-1_1	Střeň	Březové
Povrch	43041430	41597821	57795488	54098051
Vysoká vegetace	9175285	3655587	6145658	17019792
Budova	15307345	17080915	3690811	1283333

Výsledky klasifikace dat v oblasti Olomouce



Obr. 47 Výsledky klasifikace dat LIDAR v programu ArcGIS Pro – průmyslová oblast (vlevo), a obytná zástavba (vpravo)

Klasifikace dat LIDAR v ArcGIS Pro proběhla do tří tříd: povrch (světle hnědá), vysoká vegetace (zelená) a budovy (červená). V průmyslové oblasti měla automatická klasifikace největší problém s klasifikací budov, kde do této třídy byly zařazeny autobusy. Dalšími problémovými prvky byly vysoké prvky, reklamní panely, komíny a další, které byly chybně řazeny do třídy vysoké vegetace.




Obr. 48 Výsledky klasifikace dat LIDAR v programu ArcGIS Pro – průmyslová oblast vlevo, obytná zástavba vpravo (boční pohled)

Výsledky klasifikace dat v oblasti CHKO Litovelské Pomoraví – Střeň, Březové



Obr. 49 Výsledky klasifikace dat LIDAR v programu ArcGIS Pro – Střeň (vlevo), Březové (vpravo)

Ve vesnických oblastech proběhla klasifikace do třídy budov velmi úspěšně. Pouze v pár případech došlo k zařazení do této třídy části vegetace v blízkém okolí budovy. Správně byly vyhodnoceny i menší budovy na zahradách.



Obr. 50 Výsledky klasifikace dat LIDAR v programu ArcGIS Pro – Střeň (vlevo), Březové (vpravo) – boční pohled


Mezi nejčastější chyby v těchto oblastech patřila klasifikace nižších prvků na zahradách, jako jsou ploty do třídy vysoké vegetace. Chybně byly také do této třídy zařazeny sloupky a kabely elektrického vedení.

7.3.2 Výsledky klasifikace dat LIDAR v OpenCities Map PV

Tabulka 14 Počet zařazených bodů do klasifikačních tříd


	OLONMOUC 9-1_2	OLONMOUC 7-1_1	Střeň	Březové
Povrch	8342072	10012749	8562499	8404787
Vysoká vegetace	7346504	2496934	5979998	15512586
Budova	8954026	10012749	2193972	776687

Výsledky klasifikace dat v oblasti Olomouce



Obr. 51 Výsledky klasifikace dat LIDAR v programu OpenCities Map PowerView (pohled z vrchu)


V programu OpenCities Map PowerView lze provádět velmi pokročilé automatizované klasifikace dat LIDAR. Klasifikace do třídy povrchu je znázorněna tmavě hnědou barvou. Celkově do této třídy bylo klasifikováno v první průmyslovější oblasti Olomouce (Olomouc 9-1_2) 8 342 072 bodů a v druhé oblasti Olomouce (Olomouc 7-1_1) 10 023 749 bodů. Klasifikace vysoké vegetace je v tomto softwaru rozdělena do dvou tříd: vysoká vegetace a stromy. Tyto třídy se mezi sebou poměrně hodně překrývají, jak je možné vidět na obr. 51 vpravo zelenou (vysoká vegetace) a tmavě zelenou barvou (stromy). Třída budov je tvořena celkově třemi třídami, a to střecha budovy (červená), střešní konstrukce (béžová) a konstrukce stěn (světle modrá).



Obr. 52 Výsledky klasifikace dat LIDAR v programu OpenCities Map PowerView – průmyslová oblast (Olomouc 7-1_1)


V datovém náhledu obr. 52 je možné vidět problematická místa automatické klasifikace střech, kdy dochází k chybné klasifikaci střech autobusů. Vzhledem k velikosti a rovné střeše autobusu jsou tyto plochy algoritmem zařazeny do špatné třídy. Tuto chybu je možné eliminovat zvýšením minimální plochy střech.

Na rozdíl od programu ArcGIS Pro, tento program nabízí širší možnosti klasifikací do tříd aut (žluté body), sloupy (růžové body) a dalších.




Obr. 53 Výsledky klasifikace dat LIDAR v programu OpenCities Map PowerView – oblast s bytovou zástavbou (Olomouce 9-1_2)

Výsledky klasifikace dat v oblasti CHKO Litovelské Pomoraví – Střen, Březové



Obr. 54 Výsledky klasifikace dat LIDAR v programu OpenCities Map PowerView v CHKO Litovelské Pomoraví

U klasifikace dat vesnické zástavby je možné pozorovat větší množství chyb při zařazování bodů zejména do třídy konstrukce stěn (světle modrá). Do této třídy jsou v mnoha místech zařazeny i menší objekty na zahradách, ploty a podobně. Mezi další chybně zařazované prvky se řadí sloupy a kabely elektrického vedení, které jsou ve vesnických oblastech tříděny nejčastěji do vysoké vegetace (zelená barva).



Obr. 55 Výsledky klasifikace dat LIDAR v programu OpenCities Map PowerView v CHKO Litovelské Pomoraví – možnost zobrazení pouze vybraných tříd pro pokročilejší analýzu dat

Pro podrobnější analýzu chybně klasifikovaných částí bylo využito možnosti zobrazení pouze vybraných tříd. Například pro analýzu budov lze vypnout třídy vysoké vegetace a stromů, čímž se náhled dat vycistí.

8 DISKUZE

Diplomová práce na téma strojového učení v dálkovém průzkumu země byla velmi obtížnou zkouškou. Téma umělé inteligence a její podoblasti strojového učení jsou velmi složité disciplíny a samotné základní porozumění je velmi obtížné. Opakování statistiky, data miningu a následné rozšíření znalostí pro účely strojového učení byly časově velmi náročné. Studium teorie ale rešerší nekončilo. Ještě větší část proběhla během vlastního zpracování případových studií, kdy před každým krokem, každou použitou funkcí bylo nejprve nutné si vše dobře nastudovat a promyslet.

Vlastní zpracování bylo zahájeno první případovou studií věnující se tématu podrobné klasifikace horské vegetace na Vysoké holi. Před samotným zahájením byl zvolen přístup programování skriptů pro trénování modelu strojového učení a následné aplikování těchto modelů. Tento přístup byl velmi ambiciózní, což autor postupem času zjistil. Časová náročnost pochopení funkcí knihoven a jejich kombinací byla velmi vysoká. Vypořádání se s množstvím chyb při programování v konečném důsledku relativně krátkých skriptů bylo vyčerpávající a velmi pracné. Původní plán otestovat více přístupů, například i metody hlubokého učení a zejména konvolučních neuronových sítí, tedy nebylo z časového hlediska možné realizovat. Srovnání tedy bylo možné pouze mezi přístupy vstupujících dat do učení modelu (referenční RGB data X kombinace referenčních RGB dat a rastrů relativních výšek). První případová studie byla časově i realizačně nejnáročnější. Výsledky případové studie nebyly příliš významné a přístup strojového učení lze říci, že nebylo pro takto složitý typ klasifikační úlohy nejvhodnější. Pro pokračování v této případové studii by bylo vhodné vytvořit výrazně vyšší počet trénovacích dat a otestovat přístupy hlubokého učení a konvolučních neuronových sítí. Případovou studii by bylo také vhodné rozšířit o více vstupních dat, například s upraveným barevným prostorem, multispektrálních dat a dalších, které by modelu daly více informací pro rozhodování. Dalším vylepšením by mohla být podrobná analýza spektrálních hodnot pásem a možnosti, jak s těmito informacemi lépe pracovat.

Z časových důvodů a náročnosti programování vlastních klasifikačních skriptů byla druhá případová studie provedena v programu ArcGIS Pro. Na základě výsledků z první případové studie byl zvolen jiný přístup využívající metod hlubokého učení. Pro případovou studii byla firmou Renofarmy a.s. zpřístupněna ortomozaika. Sběr dat byl proveden v mimo-vegetačním období, čímž bylo manuální zakreslení stromů a vytváření trénovacích dat výrazně náročnější. V některých místech ortomozaiky docházelo k deformacím vlivem použitého digitálního modelu, což mohlo zkreslovat výsledky.

Poslední případová studie byla zaměřena na klasifikaci leteckých lidarových dat. Tak jako u druhé případové studie byl z časových důvodů zvolen přístup testování automatických klasifikačních procesů v dostupných programech. Snahou případové studie bylo testovat automatické nástroje v dostupných programech a analyzovat výsledky. Pro hodnocení výsledků nebyl nalezen žádný vhodný nástroj, který by automaticky vytvářel hodnotící metriky tak jako u dat rastrových. Hodnocení klasifikací bylo nutné provést analýzou dat a manuálním přepisem vyhodnocení bodů do tříd. Vhodným rozšířením této případové studie by bylo vytvoření vlastních trénovacích dat (velkého množství) a natrénování klasifikačního modelu. Tento proces by byl ale časově náročný a vyžadoval by výkonný počítač s vhodnou grafickou kartou.

Limitující složkou všech případových studií byl již zmíněný výpočetní výkon použitého počítače. Všechny výpočty, trénování modelů, i jejich následné aplikace by bylo vhodnější spouštět na výkonnějších strojích, což si autor zpětně uvědomuje.

Časová náročnost všech případových studií byla velmi vysoká. Případové studie by bylo možné dále rozšířit o stovky hodin testování dalších metod, přípravou většího množství kvalitnějších dat a také podrobnějším studiem literatury a případových studií.

9 ZÁVĚR

Diplomová práce na téma *Využití metod strojového učení pro klasifikaci obrazových a lidarových dat* si kladla za cíl stanovit optimální postup pro klasifikaci obrazových dat DPZ a dat z laserového skenování. Cílem práce bylo zvolit vhodné metody založené na strojovém učení a stanoveným postupem je aplikovat na tři případové studie.

Prvním krokem diplomové práce bylo podrobné nastudování literatury zabývající se statistikou, data miningem, umělou inteligencí a strojovým učení. Následně došlo k rešerši klasifikačních metod, dostupných knihoven a softwarů nabízejících tyto funkce. Na základě studia odborné literatury mohlo dojít k výběru případových studií a jejich realizaci.

Jako první případová studie byla vybrána klasifikace horské vegetace na území Vysoké hole nacházející se v CHKO Jeseníky. Na základě dostupných dat došlo k volbě zájmového území a oblastí pro tvorbu trénovacích a testovacích dat. Navrženým postupem byly vyexportovány tři trénovací datové sady, a to vytvořené z referenční ortomozaiky, vypočteného rastru relativních výšek objektů nad povrchem a manuálně klasifikovaných ploch tříd vegetace. Stejným postupem byla vyexportována data pro testování modelu. Následně došlo k naprogramování skriptů pro trénování klasifikačních modelů, výpočet metrik a aplikování natrénovaných modelů na testovacích datech. Skripty pro natrénování modelů byly testovány s různými klasifikátory a nastaveními. Na základě testování byly zvoleny dva klasifikační algoritmy kNN a random forest, se kterými byly natrénovány 4 modely. Vybrané modely byly aplikovány na testovacích datech a výsledky byly pomocí metrik ohodnoceny a analyzovány.

Druhá případová studie se zabývala detekcí stromů v mimo-vegetačním období v sadu u obce Veselíčko. Pro účely případové studie byly zvoleny metody hlubokého učení dostupné v programu ArcGIS Pro: konvoluční neuronové sítě pro per pixel klasifikaci a objektovou detekci. Na základě dostupné ortomozaiky došlo k podrobnému zakreslení polygonů stromů. Z těchto dat byla vyexportována trénovací data ve vhodných formátech pro trénování modelů per pixel klasifikace i objektové detekce. Ve fázi trénování modelu proběhlo testování různých nastavení, zejména nastavení více typů modelů neuronových sítí. Testováním byly vybrány nejúspěšnější kombinace a tyto modely byly aplikovány na oblast, která do trénování nevstupovala. Výsledné modely, klasifikovaná data a detekované stromy byly analyzovány a hodnoceny.

Poslední případová studie byla zaměřena na možnosti automatizovaných klasifikací leteckých lidarových dat v dostupných softwarech. Pro účely případové studie byly vybrány dva softwary, a to ArcGIS Pro a OpenCities Map PowerView. V obou softwarech byly testovány dostupné klasifikační úlohy do tříd povrch, budovy a vysoká vegetace. Testování klasifikací proběhlo v oblastech s vesnickým i městským charakterem zástavby. Pro tyto účely byla Katedrou geoinformatiky zpřístupněna data Olomouce a data v CHKO Litovelské Pomoraví za obce Březové a Střeň. Výsledná klasifikovaná mračna byla vizuálně analyzována. Na základě analýzy došlo k porovnání výsledků klasifikačních úloh dostupných softwarů.

Tato diplomová práce nabízí pohled na možnosti využití strojového učení pro klasifikaci obrazových a lidarových dat a ukazuje, jak mohou tyto metody přispět k jejich efektivnějšímu a rychlejšímu zpracování.

POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE

AGGARVAL, Charu, 2018. *Neural Networks and Deep Learning* [online]. ISBN 978-3-319-94463-0. Dostupné z: doi:<https://doi.org/10.1007/978-3-319-94463-0>

AGISOFT LLC, 2023. *Metashape 2.0 - Intelligent Photogrammetry* [online]. Dostupné z: chrome-extension://efaidnbmnnnibpcajpcgiclfefindmkaj/https://www.agisoft.com/pdf/metashape_presentation.pdf

AMBROŽOVÁ, Klára, 2016. *Analýza hlavních komponent* [online]. Dostupné z: chrome-extension://efaidnbmnnnibpcajpcgiclfefindmkaj/https://is.muni.cz/el/1431/jaro2016/Z2069/um/54271982/56272282/PCA_prez_pondelniskupiny.pdf

AWS, 2024. *What is Deep Learning?* [online]. Dostupné z: <https://aws.amazon.com/what-is/deep-learning/>

BADA, Tomáš, 2018. Jaký je rozdíl mezi rastrovou a vektorovou grafikou. *Vektorová grafika* [online]. Dostupné z: <https://vektorova-grafika.cz/rastrova-a-vektorova-grafika-jaky-je-rozdil/>

BEK, Stanislav, 2015. *Prostorová interpolace a modelování eroze půd* [online]. B.m. Univerzita Kralova v Praze. Dostupné z: <https://dspace.cuni.cz/bitstream/handle/20.500.11956/81304/140044145.pdf?sequence=1>

BENTLEY SYSTEMS, 2024. *OpenCities Map* [online]. Dostupné z: <https://www.bentley.com/software/opencities-map/>

CAMPBELL, JAMES, B. a W. WYNNE, RANDOLPH, 2011. *Introduction to Remote Sensing* [online]. Fifth edit. ISBN 978-60918-176-5. Dostupné z: https://istncrg.files.wordpress.com/2019/09/introduction_to_remote_sensing_www.gisman.ir_.pdf

CLOUDCOMPARE, 2024. *CloudCompare - Introduction* [online]. Dostupné z: <https://www.danielgm.net/cc/>

CRAIG, Lev, 2024. Convolutional neural network (CNN) [online]. Dostupné z: <https://www.techtarget.com/searchenterpriseai/definition/convolutional-neural-network>

ESRI, 2021. *Tree Point Classification* [online]. Dostupné z: <https://www.arcgis.com/home/item.html?id=58d77b24469d4f30b5f68973deb65599>

ESRI, 2024a. *ArcGIS Pro* [online]. Dostupné z: <https://www.esri.com/en-us/arcgis/products/arcgis-pro/overview>

ESRI, 2024b. *Classify LAS Building* [online]. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/3d-analyst/classify-las-building.htm>

ESRI, 2024c. *Classify LAS Ground* [online]. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/3d-analyst/classify-las-ground.htm>

ESRI, 2024d. *Classify LAS Noise* [online]. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/3d-analyst/classify-las-noise.htm>

ESRI, 2024e. *Deep learning in ArcGIS Pro* [online]. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/deep-learning/deep-learning-in-arcgis-pro.htm>

ESRI, 2024f. *Deep Learning Libraries Installers for ArcGIS* [online]. Dostupné z: <https://github.com/Esri/deep-learning-frameworks>

ESRI, 2024g. *Label objects for deep learning* [online]. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/image-analyst/label-objects-for-deep-learning.htm>

ESRI, 2024h. *LAS datasets* [online]. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/help/data/las-dataset/what-is-a-las-dataset-.htm>

ESRI, 2024i. *Train Deep Learning Model* [online]. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/train-deep-learning-model.htm>

FLOWERS, Johnathan Charles, 2019. *Strong and Weak AI: Deweyan Considerations* [online]. B.m. Worcester State University. Dostupné z: <https://ceur-ws.org/Vol-2287/paper34.pdf>

GANDHI, Rohith, 2018. Support Vector Machine — Introduction to Machine Learning Algorithms. *Data Science* [online]. Dostupné z: <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>

GEPANDAS DEVELOPERS, 2022. *About GeoPandas* [online]. Dostupné z: <https://geopandas.org/en/stable/about.html>

GISMENTORS, 2024. *QGIS - Nejrozšířenější Open Source desktopový GIS* [online]. Dostupné z: <https://gismentors.cz/skoleni/qgis/>

HE, Kaiming, Xiangyu ZHANG, Shaoqing REN a Jian SUN, 2015. *ResNet 34* [online]. Dostupné z: <https://roboflow.com/model/resnet-34>

HONZÍK, Petr, 2006. *Strojové učení* [online]. Dostupné z: http://midas.uamt.feec.vutbr.cz/STU/others/Honzik - Strojove_uceni_S.pdf

IBM, 2023a. *What is a neural network?* [online]. Dostupné z: <https://www.ibm.com/topics/neural-networks>

IBM, 2023b. *What is linear regression?* [online]. Dostupné z: <https://www.ibm.com/topics/linear-regression>

IBM, 2023c. *What is logistic regression?* [online]. Dostupné z: <https://www.ibm.com/topics/logistic-regression>

IBM, 2023d. *What is random forest?* [online]. Dostupné z: <https://www.ibm.com/topics/random-forest>

IBM, 2023e. *What is supervised learning?* [online]. Dostupné z: <https://www.ibm.com/topics/supervised-learning>

IBM, 2023f. *What is the KNN algorithm?* [online]. Dostupné z: <https://www.ibm.com/topics/knn>

IBM, 2024a. *What are convolutional neural networks?* [online]. Dostupné z: <https://www.ibm.com/topics/convolutional-neural-networks>

IBM, 2024b. *What is deep learning?* [online]. Dostupné z: <https://www.ibm.com/topics/deep-learning>

IBM, 2024c. *What is unsupervised learning?* [online]. Dostupné z: <https://www.ibm.com/topics/unsupervised-learning>

INSTITUT BIostatistiky A ANALÝZ LEKAŘSKÉ FAKULTY MASARYKOVY UNIVERZITY, 2024. *Hierarchické shlukování* [online]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analiza-a-hodnoceni-biologickych-dat--vicerozmerne-metody-pro-analizu-dat--shlukova-analyza--shlukova-hierarchicka-analyza--hierarchicke-shlukovani>

JOBLIB, 2024. *Joblib: running Python functions as pipeline jobs* [online]. Dostupné z: <https://joblib.readthedocs.io/en/stable/>

JORDAN, Jeremy, 2018. *Introduction to autoencoders* [online]. Dostupné z: <https://www.jeremyjordan.me/autoencoders/>

KLUFOVÁ, Renata, 2020. *Rastrová data. Impresum* [online]. Dostupné z: http://home.ef.jcu.cz/~klufova/GIS/GIS1/_book/rastrova-data.html

LILLESAND, M., Thomas, 2015. *Remote Sensing and Image Interpretation*. Seventh Ed. ISBN 978-1-118-34328-9.

LINDHOLM, Andreas, Niklas WAHLSTRÖM, Fredrik LINDSTEN a Thomas SCHÖN, 2019. *Supervised Machine Learning* [online]. B.m. Uppsala University. Dostupné z: <https://mwns.co/blog/wp-content/uploads/2020/01/Supervised-Machine-Learning.pdf>

LUTKEVICH, Ben, 2023. *Association rules. TechTarget* [online]. Dostupné z: <https://www.techtarget.com/searchbusinessanalytics/definition/association-rules-in-data-mining>

MAPBOX, 2018a. *Rasterio: access to geospatial raster data* [online]. Dostupné z: <https://rasterio.readthedocs.io/en/stable/>

MAPBOX, 2018b. *Rasterio – Introduction* [online]. Dostupné z: <https://rasterio.readthedocs.io/en/stable/intro.html>

MATOUŠEK, Václav, 2023. *Strojové učení* [online]. Dostupné z: https://www.kiv.zcu.cz/studies/predmety/uzi/Folie_ZS/Stroj_uceni.pdf

MELOUN, Milan, 2007. *Logistická regrese* [online]. B.m. Univerzita Pardubice. Dostupné z: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://meloun.upce.cz/docs/lecture/c-hemometrics/slidy/lr-ncss.pdf>

MICROSOFT, 2024. Documentation for Visual Studio Code - Getting Started [online]. Dostupné z: <https://code.visualstudio.com/docs>

MISHRA, Sanatan, 2017. Unsupervised Learning and Data Clustering. *Towards Data Science* [online]. Dostupné z: <https://towardsdatascience.com/unsupervised-learning-and-data-clustering-eeecb78b422a>

NEJEDLOVÁ, Dana, 2019. *Umělá inteligence*.

NORWAY GRANTS, 2023. *Jednoduchá lineární regrese* [online]. Dostupné z: <https://mathstat.econ.muni.cz/media/19031/linearni-regrese.pdf>

NUMFOCUS, Inc., 2024a. *About pandas* [online]. Dostupné z: <https://pandas.pydata.org/about/>

NUMFOCUS, Inc., 2024b. *pandas* [online]. Dostupné z: <https://pandas.pydata.org/>

NUMPY TEAM, 2024a. *NumPy - About Us* [online]. Dostupné z: <https://numpy.org/about/>

NUMPY TEAM, 2024b. *NumPy* [online]. Dostupné z: <https://numpy.org/>

PETR, Pavel, 2014. *Metody Data Miningu*. ISBN 978-80-7395-872-5.

PILÁT, Martin, 2024. Neuronové sítě - konvoluční sítě a zpracování obrazu [online]. Dostupné z: <https://martinpilat.com/cs/prirodou-inspirovane-algoritmy/neuronove-site-konvolucni-site-zpracovani-obrazu>

PLÁNKA, Ladislav, 2024. *Dálkový průzkum Země: Zpracování dat* [online]. Dostupné z: https://www.hgf.vsb.cz/export/sites/hgf/544/.content/galerie-souboru/planka/dpz/DPZ_07_ZPRAC_DAT_STUDENTI.pdf

PYTHON SOFTWARE FOUNDATION, 2024. *glob — Unix style pathname pattern expansion* [online]. Dostupné z: <https://docs.python.org/3/library/glob.html>

QGIS, 2024. Úvod do QGIS [online]. Dostupné z: https://docs.qgis.org/2.18/cs/docs/gentle_gis_introduction/introducing_gis.html

RUSSELL, Stuart a Peter NORVIG, 2003. *Artificial Intelligence A modern Approach*. Second Edi. ISBN 0-13-790395-2.

SAHA, Sumit, 2018. A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way [online]. Dostupné z: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>

ŠARMANOVÁ, Jana, 2012. *Metoda analýzy dat*. 169.

SCIKIT-LEARN DEVELOPERS, 2023. *Naive Bayes* [online]. Dostupné z: https://scikit-learn.org/stable/modules/naive_bayes.html

SCIKIT-LEARN DEVELOPERS, 2024a. *1.4. Support Vector Machines* [online]. Dostupné z: <https://scikit-learn.org/stable/modules/svm.html>

SCIKIT-LEARN DEVELOPERS, 2024b. *Classifier comparison* [online]. Dostupné z: https://scikit-learn.org/stable/auto_examples/classification/plot_classifier_comparison.html

SCIKIT-LEARN DEVELOPERS, 2024c. *Ensemble methods* [online]. Dostupné z: https://scikit-learn.org/stable/auto_examples/ensemble/index.html

SCIKIT-LEARN DEVELOPERS, 2024d. *Getting Started – scikit-learn* [online]. Dostupné z: https://scikit-learn.org/stable/getting_started.html

SCIKIT-LEARN DEVELOPERS, 2024e. *Metrics and scoring: quantifying the quality of predictions* [online]. Dostupné z: https://scikit-learn.org/stable/modules/model_evaluation.html

SCIKIT-LEARN DEVELOPERS, 2024f. *scikit-learn* [online]. Dostupné z: <https://scikit-learn.org/stable/index.html>

SCIPY COMMUNITY, 2024. *SciPy User Guide* [online]. Dostupné z: <https://docs.scipy.org/doc/scipy/tutorial/index.html#user-guide>

SPERLING, Ed, 2018. *Deep Learning Spreads* [online]. Dostupné z: <https://semiengineering.com/deep-learning-spreads/>

ŠVANDA, Michal, 2012. *Šum a jeho potlačení* [online]. Dostupné z: https://sirrah.troja.mff.cuni.cz/~svanda/AST001/F_sum_mrizky_prezentace.pdf

TERRASOLID, 2024a. *By height from ground* [online]. Dostupné z: <https://terrasolid.com/guides/tscan/crbyheightfromground.html>

TERRASOLID, 2024b. *Ground* [online]. Dostupné z: <https://terrasolid.com/guides/tscan/crground.html>

TERRASOLID, 2024c. *TerraSolid* [online]. Dostupné z: <https://terrasolid.com/>

THE SCIPY COMMUNITY, 2024. *Multidimensional image processing* [online]. Dostupné z: <https://docs.scipy.org/doc/scipy/reference/ndimage.html>

TURING, 2023. *An Introduction to Naive Bayes Algorithm for Beginners* [online]. Dostupné z: <https://www.turing.com/kb/an-introduction-to-naive-bayes-algorithm-for-beginners>

ÚSTAV GEOINFORMAČNÍCH TECHNOLOGIÍ LESNICKÁ A DŘEVAŘSKÁ FAKULTA MENDELU, 2023. *Dálkový průzkum Země* [online]. Dostupné z: http://uhulag.mendelu.cz/files/pagesdata/cz/vgdp/vdgp_dpz4.pdf

VIDNEROVA, Petra a Roman DIBA, 2020. *Klasifikační metricky* [online]. Dostupné z: https://nauce.python.cz/2020/pydata-praha-jaro/pydata/classification_metrics/

VOLNÁ, Eva, 2013. *UMĚLÁ INTELIGENCE* [online]. Ostrava: Ostravská univerzita v Ostravě. Dostupné z: https://web.osu.cz/~Volna/Umela_inteligence_skripta.pdf

WU, Wei, 2022. Unsupervised Learning [online]. 20. Dostupné z: https://na.uni-tuebingen.de/ex/ml_seminar_ss2022/Unsupervised_Learning_Final.pdf

ZACHA, Jiří, 2019. *Konvoluční neuronové sítě pro klasifikaci objektů z LiDARových dat* [online]. B.m. České vysoké učení technické v Praze. Dostupné z: https://dspace.cvut.cz/bitstream/handle/10467/82351/F3-BP-2019-Zacha-Jiri-Konvolucni_neuronove_site_pro_klasifikaci_objektu_z_LiDARovych_dat.pdf

ZEMEK, František a kol., 2014. *Letecký dálkový průzkum Země*. ISBN 978-80-87902-07-3.

PŘÍLOHY

SEZNAM PŘÍLOH

Volné přílohy

Příloha 1 Poster

Příloha 2 Skripty

1_1_Classification_kNN.py

1_2_Classification_kNN_ELEVATION.py

1_3_Classification_RF.py

1_4_Classification_RF_ELEVATION.py

2_1_USING_TRAINED_MODEL_ON_OTHER_SET.py

2_2_USING_TRAINED_MODEL_ON_OTHER_SET-ELEVATION.py

Příloha 3 Modely

Model případové studie 1:

Model_kNN-Vysoka_Hole-RGB.joblib

Model_kNN-Vysoka_Hole-RGB_ELEVATION.joblib

Model_RF-Vysoka_Hole-RGB.joblib

Model_RF-Vysoka_Hole-RGB_ELEVATION.joblib

Modely případové studie 2:

1_Modely (adresář)

Popis struktury odevzdávaných digitálních dat na datové úložiště katedry

Poster

Text_Prace

Vstupni_Data

Skripty

Modely

Data – trénovací a testovací

Vystupni_Data

WEB