

Univerzita Palackého v Olomouci

Přírodovědecká fakulta

Katedra geoinformatiky

**HODNOCENÍ PŘESNOSTI KLASIFIKACE
VYBRANÝCH KRAJINNÝCH JEDNOTEK V
PROSTŘEDÍ GOOGLE EARTH ENGINE**

Diplomová práce

Bc. Natálie KARAMONOVÁ

Vedoucí práce prof. RNDr. Vilém Pechanec, Ph.D.

Olomouc 2023

Geoinformatika a kartografie

ANOTACE

Tato diplomová práce se zabývá přesností klasifikace tří vybraných krajinných jednotek. Klasifikace je provedena pomocí čtyř vybraných algoritmů strojového učení – CART, Random Forest, Minimum Distance a Naïve Bayes. Spuštění klasifikace kompletně probíhá v GEE. V práci jsou použity tři satelitní multispektrální snímky z družic Sentinel-2, Landsat 8 a MODIS.

Dílní část klasifikace je provedena v cloudovém prostředí Google Earth Engine, kdežto již samotné zpracování je realizováno v desktopovém softwaru ArcGIS Pro. Výsledky klasifikace jsou porovnány s referenčními vrstvami pro všechny 3 úrovně – land cover, land use a biotop.

Výsledkem práce je procentuální porovnání klasifikací v kategoriích. A shoda klasifikace s referenční vrstvou určující přesnost klasifikace. Výstupy jsou vypracovány v tabulkové a grafické podobě. Nejlepší výsledky klasifikace prokazuje algoritmus Random Forest, naopak nejslabší výsledky Naïve Bayes. Při porovnání shod v kategoriích, jsou brány v potaz všechny tři zkoumané krajinné jednotky, ukazuje na území Olomouce nejlepší výsledky algoritmus CART a na území Černovic algoritmus Naïve Bayes. Klasifikace s nejvyšším procentem shody vychází pro testovací snímek Sentinel-2.

KLÍČOVÁ SLOVA

Google Earth Engine; řízená klasifikace; algoritmy

Počet stran práce: 68

Počet příloh: 6 (z toho 1 volná a 5 vázaných)

ANOTATION

This thesis deals with the classification accuracy of three selected landscape units. The classification is performed using four selected machine learning algorithms – CART, Random Forest, Minimum Distance and Naïve Bayes. The execution of the classification is completely done in GEE. Three satellite multispectral images from Sentinel-2, Landsat 8 and MODIS satellites are used in this work.

The classification part is performed in the cloud environment of Google Earth Engine, whereas the actual processing is performed in the desktop software ArcGIS Pro. The classification results are compared with reference layers for all 3 levels – land cover, land use and habitat.

The result of the work is a percentage comparison of the classifications in the categories. And the agreement of the classification with the reference layer determining the accuracy of the classification. The outputs are produced in tabular and graphical form. The Random Forest algorithm shows the best classification results, while Naïve Bayes shows the worst results. When comparing the matches in the categories, all three studied landscape units are taken into account, the CART algorithm shows the best results in the territory of Olomouc and the Naïve Bayes algorithm in the territory of Černovice. The classification with the highest percentage of agreement is based on the Sentinel-2 test image.

KEYWORDS

Google Earth Engine; supervised classification; algorithms

Number of pages: 68

Number of appendixes: 6

Prohlašuji, že

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

- jsem si vědom(a), že na moji 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, diplomovou práci užívat (§ 35 odst. 3),

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

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

- použít výsledky a výstupy mé 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

Bc. Natálie Karamonová

Děkuji vedoucímu práce prof. RNDr. Vilému Pechancovi, Ph.D. za podněty a připomínky při vypracování práce.

UNIVERZITA PALACKÉHO V OLOMOUCI

Přírodovědecká fakulta
Akademický rok: 2021/2022

ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Bc. Natálie KARAMONOVÁ**
Osobní číslo: **R21851**
Studijní program: **N0532A330009 Geoinformatika a kartografie**
Téma práce: **Hodnocení přesnosti klasifikace vybraných krajinných jednotek v prostředí Google Earth Engine**
Zadávající katedra: **Katedra geoinformatiky**

Zásady pro vypracování

Cílem práce je provést sérii klasifikací obrazu a na základě dosažených výsledků stanovit vhodnost dostupných algoritmů pro klasifikaci krajinných jednotek v prostředí Google Earth Engine (GEE). Student/ka se seznámí s dostupnými daty a klasifikačními algoritmy, jež jsou dostupné v prostředí GEE. Pro vybrané zájmové plochy v ČR provede sérii klasifikací obrazu v rozhraní GEE a využije strukturní i texturní charakteristiky. Dosažené výsledky vzájemně vyhodnotí a srovná se stavem na kontrolních plochách. Klasifikace bude zaměřena na rozlišení krajinných jednotek na třech úrovních (landcover jednotka, landuse jednotka, biotop jednotka).

Studentka vyplní údaje o všech datových sadách, které vytvořil nebo získal v rámci práce, do Metainformačního systému katedry geoinformatiky a současně zálohu údajů ve formě validovaného XML souboru. Celá práce (text, přílohy, výstupy, zdrojová a vytvořená data, XML soubor) se odevzdá v digitální podobě na CD (DVD) a text práce s vybranými přílohami bude odevzdán ve dvou svázaných výtiscích na sekretariát katedry. O diplomové práci student vytvoří webovou stránku v souladu s pravidly dostupnými na stránkách katedry. Práce bude zpracována podle zásad Voženílek (2002) a závazné šablony pro diplomové práce na KGI. Povinnou přílohou práce bude poster formátu A2.

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

Seznam doporučené literatury:

Oficiální dokumentace k technickým parametrům a způsobu práce

<https://developers.google.com/earth-engine/>

Yang, Y.; Yang, D.; Wang, X.; Zhang, Z.; Nawaz, Z. Testing Accuracy of Land Cover Classification Algorithms in the Qilian Mountains Based on GEE Cloud Platform. *Remote Sens.* 2021, 13, 5064. <https://doi.org/10.3390/rs13245064>

Shunlin Liang, Xiaowen Li, Jindi Wang (eds.) *Advanced Remote Sensing*. 1st Edition. Terrestrial Information Extraction and Applications

William James Frampton, Jadunandan Dash, GaryWatmough, Edward James Milton (2013): Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation
indexované databáze

Vedoucí diplomové práce: **doc. RNDr. Vilém Pechanec, Ph.D.**
Katedra geoinformatiky

Datum zadání diplomové práce: 9. prosince 2021
Termín odevzdání diplomové práce: 5. května 2023

UNIVERZITA PALACKÉHO V OLOMOUCI
PŘÍRODOVĚDECKÁ FAKULTA
KATEDRA GEOINFORMATIKY
17. listopadu 50, 771 46 Olomouc

L.S.

doc. RNDr. Martin Kubala, Ph.D.
děkan

prof. RNDr. Vít Voženílek, CSc.
vedoucí katedry

V Olomouci dne 16. prosince 2021

OBSAH

SEZNAM POUŽITÝCH ZKRATEK	9
ÚVOD	10
1 CÍLE PRÁCE	11
2 METODY A POSTUP ZPRACOVÁNÍ	12
2.1 Použité metody	12
2.2 Použité programy	12
2.3 Použitá data	12
2.4 Postup zpracování	14
2.5 Zájmová území	18
3 DÁLKOVÝ PRŮZKUM ZEMĚ	20
3.1 Zpracování obrazu	20
3.1.1 Fáze digitálního zpracování snímku	20
4 KLASIFIKACE OBRAZU	21
4.1 Řízená klasifikace	21
4.1.1 Trénovací plochy	22
4.1.2 Vymezení trénovacích množin	22
4.2 Klasifikační algoritmy	23
4.2.1 Naïve Bayes	23
4.2.2 Random Forest (RF)	24
4.2.3 Classification and Regression Tree (CART)	24
4.2.4 Minimum Distance	25
4.3 Hodnocení přesnosti klasifikace	25
4.3.1 Klasifikační chybová matice	26
4.3.2 Kappa koeficient	26
5 GOOGLE EARTH ENGINE	27
5.1 Základní princip práce s online platformou GEE	27
5.2 Algoritmy použití při řízené klasifikaci v GEE	30
5.2.1 Random Forest	30
5.2.2 CART	30
5.2.3 Minimum Distance	31
5.2.4 Support Vector Machine (SVM)	31
5.2.5 Naïve Bayes	32
6 VÝSLEDKY	33
6.1 Základní práce s GEE	33
6.2 Výsledky klasifikací provedených na území Olomouce	35
6.2.1 Klasifikace na úrovni 1 (land cover)	35
6.2.2 Klasifikace na úrovni 2 (land use)	37
6.2.3 Klasifikace na úrovni 3 (biotopy)	39
6.3 Výsledky klasifikací provedených na území Černovic	41
6.3.1 Klasifikace na úrovni 1 (land cover)	41

6.3.2	Klasifikace na úrovni 2 (land use)	43
6.3.3	Klasifikace na úrovni 3 (biotopy)	45
6.4	Vyhodnocení přesnosti klasifikace	48
6.4.1	Procentuální shoda na území Olomouce	48
6.4.2	Procentuální shoda na území Černovic u Tábora	49
6.4.3	Procentuální shoda v kategoriích na území Olomouce.....	50
6.4.4	Procentuální shoda v kategoriích na území Černovic.....	56
6.5	Shrnutí poznatků z provedených klasifikací	61
6.6	StoryMap	65
7	DISKUZE.....	66
8	ZÁVĚR	68
	POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE	
	PŘÍLOHY	

SEZNAM POUŽITÝCH ZKRATEK

Zkratka	Význam
API	Application Programming Interface
CART	Classification and Regresion Tree
CLC	Corine Land Cover
GEE	Google Earth Engine
OSM	OpenStreetMap
RF	Random Forest
SVM	Support Vector Machine
WOS	Web of Science

ÚVOD

V dnešní době existuje nespočet programů pro vyhodnocování různých dat. Všechno se snaží být hodně inovativní, a proto spousta firem, provádějící výzkum převážně v environmentálních vědách, pomalu přechází z desktopových programů, které jsou mnohdy placené a závislé na výkonném počítači na cloudové platformy. Jednou takovou čím dál tím víc oblíbenou cloudovou platformou ve vědeckém prostředí je Google Earth Engine. Samotný GEE nabízí široké spektrum geografických databází, přes surová či klimatická, až po data zaměřená jen na jednu oblast, pro sledování a potřebných algoritmů. Data jsou dostupná až několik let dozadu a samozřejmě neustále přibývají i nová, aktualizovaná. Jeho velkou výhodou je dostupnost odkudkoliv a snadné sdílení. Díky celé škále možností bylo velmi atraktivní a motivující naučit se zpracovávat data právě v tomto prostředí. Právě kvůli čím dál většímu trendu, by se práce v Google Earth Engine měla zahrnovat do výuky na vysokých školách zaměřených na environmentální oblast.

Hodnocení přesnosti klasifikace lze provádět pomocí přímé i nepřímé klasifikace. Vyhodnocení klasifikace se nejčastěji provádí na kontrolních bodech nebo plochách, neboť tahle metoda není oproti porovnání s reálným územím tak finančně a časově náročná. Tahle diplomová práce je zaměřena na klasifikaci přímou neboli klasifikaci s učitelem.

V současnosti bylo provedeno již několik vědeckých studií, které zkoumají problematiku vyhodnocování přesnosti klasifikací na satelitních snímcích v cloudovém prostředí Google Earth Engine. Je podloženým faktem, že snímky z družic Sentinel-2 a Landsat 8 jsou daleko vhodnější pro zkoumání vegetačního pokryvu, než je tomu tak u snímku MODIS.

1 CÍLE PRÁCE

Hlavním cílem práce je provést sérii klasifikací obrazu a na základě dosažených výsledků stanovit vhodnost dostupných algoritmů pro klasifikaci krajinných jednotek v prostředí Google Earth Engine (GEE). Před zahájením samotné klasifikace je potřeba se seznámit s dostupnými daty a klasifikačními algoritmy, jež jsou dostupné v prostředí GEE. Pro vybrané zájmové plochy v ČR bude provedena série klasifikací obrazu v rozhraní GEE a využije strukturní i texturní charakteristiky. Dosažené výsledky budou vzájemně vyhodnoceny a srovnány se stavem na kontrolních plochách. Klasifikace bude zaměřená na rozlišení krajinných jednotek na třech úrovních (landcover jednotka, landuse jednotka a biotop jednotka).

Tato diplomová práce je rozdělena do několika částí. V první řadě je nutné získat znalosti z již dostupných prací a studií, které se zabývají podobnou problematikou. Následně je nezbytné zvolit vhodné metody a daty. Daty jsou vybrány z katalogu, který je dostupný přímo v prostředí Google Earth Engine.

Další krok vede k samotnému spuštění klasifikace v rozhraní GEE pro 2 vybrané zájmové oblasti, v tomto případě obec Černovice u Tábora a město Olomouc a k následnému zpracování klasifikace v desktopovém softwaru ArcGIS Pro.

V poslední části diplomové práce jsou shrnuty výsledky a zhodnocení kvality přesnosti klasifikace a stanovena vhodnost jednotlivých algoritmů.

2 METODY A POSTUP ZPRACOVÁNÍ

2.1 Použité metody

V první, teoretické, části bylo potřebné nastudovat odbornou literaturu a udělat rešerši z již dostupných studií, zabývající se hodnocením přesnosti klasifikace pomocí řízené klasifikace. Případové studie vyhledávány v databázi Web of Science (WOS) – pomocí pole title, do kterého bylo zadáno anglické znění algoritmu pro klasifikaci obrazu.

Mezi další metody patří vytvoření skriptu pro spuštění řízené klasifikace v prostředí GEE, export snímku z GEE, předzpracování obrazu, ořez obrazu podle zájmového území a další dílčí metody potřebné k hodnocení přesnosti klasifikace.

2.2 Použité programy

Google Earth Engine

Jedná se o online platformu vyvinutou společností Google. Jde o platformu, která umožňuje kombinovat obrovské masy satelitních a geografických dat. Slouží pro analýzu a vizualizaci geoprostorových dat. Více informací viz. Kap. 5.

GEE byl použit ke spuštění algoritmů řízené klasifikace. Před samotným začátkem práce v rozhraní GEE, si autorka prohlédla všechny tutoriály a prohlédla katalog s daty k řízené klasifikaci, které GEE nabízí.

ArcGIS Pro

Jde o desktopovou aplikaci vyvinutou společností Esri. Software slouží především k vytváření mapových výstupů a tvorbu prostorových databází. Obsahuje stovky funkcí k vytváření analýz. V ArcGIS Pro je možné vizualizovat data jak ve 2D, tak ve 3D. K přípravě dat, analýz, vizualizací byla využita verze ArcGIS Pro 2.8.3.

Microsoft Excel

Software ve verzi 16.75.2 (2023) sloužil ke zpracování veškerých tabulkových a grafických výstupů.

2.3 Použitá data

Ke zpracování klasifikace byly použity data přímo z katalogu v GEE. Hlavními zdroji byly multispektrální snímky ze 3 družic Sentinel-2, Landsat 8 a MODIS. Data k vytvoření referenční vrstvy pro úroveň 1 (land cover) a úroveň 2 (land use), byly převzaty z Data50, OSM a Corine Land Cover 2018, kde jsou data dostupná pouze ve formě rasteru. K úrovni 3 (biotop) byla data poskytnuta vedoucím práce.

Sentinel-2

Družice Sentinel-2 poskytuje velké množství dat a snímků. Snímky z družice jsou multispektrální se širokým záběrem a vysokým rozlišením (10-60 m). Obsahuje 13 spektrálních pásem. Je vhodný pro pozorování vegetace, půdy, vodních povrchů a mapování půdy (ESA, 2023). Klasifikací snímku Sentinel-2 se ve své studii zabývá E. Kroupí, M. Kesa a kol. (2019).

Tabulka 1 Spektrální pásma družice Sentinel-2 (zdroj: Google Earth Engine)

Název	Popis	Rozlišení	Vlnová délka
B1	Aerosols	60 meters	443.9nm (S2A) / 442.3nm (S2B)
B2	Blue	10 meters	496.6nm (S2A) / 492.1nm (S2B)
B3	Green	10 meters	560nm (S2A) / 559nm (S2B)
B4	Red	10 meters	664.5nm (S2A) / 665nm (S2B)
B5	Red Edge 1	20 meters	703.9nm (S2A) / 703.8nm (S2B)
B6	Red Edge 2	20 meters	740.2nm (S2A) / 739.1nm (S2B)
B7	Red Edge 3	20 meters	782.5nm (S2A) / 779.7nm (S2B)
B8	NIR	10 meters	835.1nm (S2A) / 833nm (S2B)
B8A	Red Edge 4	20 meters	864.8nm (S2A) / 864nm (S2B)
B9	Water vapor	60 meters	945nm (S2A) / 943.2nm (S2B)
B10	Cirrus	60 meters	1373.5nm (S2A) / 1376.9nm (S2B)
B11	SWIR 1	20 meters	1613.7nm (S2A) / 1610.4nm (S2B)
B12	SWIR 2	20 meters	2202.4nm (S2A) / 2185.7nm (S2B)

Landsat 8

Družice Landsat 8 se skládá ze dvou přístrojů – operačního snímkovače země (OLI) a termálního infračerveného senzoru (TIRS). Tyto dva senzory zajišťují sezónní pokrytí globálního povrchu s prostorovým rozlišením 30 metrů (viditelná oblast, NIR, SWIR), 100 metrů (termální oblast) a 15 metrů (panchromatická oblast) (NASA, 2023). Snímky z družice jsou vhodné pro analýzu krajinného pokryvu. Klasifikaci snímku Landsat 8, určené k identifikaci antarktických jezer, ve své práci zkoumal Halberstadt (Halberstadt, 2020).

Tabulka 2 Spektrální pásma družice Landsat 8 (zdroj: Google Earth Engine)

Název	Popis	Rozlišení	Vlnová délka
B1	Coastal aerosol	30 meters	0.43 – 0.45 μm
B2	Blue	30 meters	0.45 – 0.51 μm
B3	Green	30 meters	0.53 – 0.59 μm
B4	Red	30 meters	0.64 – 0.67 μm
B5	Near infrared	30 meters	0.85 – 0.88 μm
B6	Shortwave infrared 1	30 meters	1.57 – 1.65 μm
B7	Shortwave infrared 2	30 meters	2.11 – 2.29 μm
B8	Band 8 Panchromatic	15 meters	0.52 – 0.90 μm
B9	Cirrus	30 meters	1.36 – 1.38 μm
B10	Thermal infrared 1, resampled from 100 m to 30 m	100 meters	10.60 – 11.19 μm
B11	Thermal infrared 2, resampled from 100 m to 30 m	100 meters	11.50 – 12.51 μm

MODIS

MODIS neboli Moderate Resolution Imaging Spectroradiometer, je přístroj obsažený na sondách Terra a Aqua. Obsahuje 36 pásem. Data jsou ve třech rozlišeních – 250 m, 500 m a 1000 m (USGS, 2023). Baeza a Paruelo ve své studii zkoumali na snímku MODIS změnu využití země v travnatých oblastech Rio de la Plaza v časových řadách NDVI (Baeza, 2020).

Tabulka 3 Spektrální pásma družice MODIS (zdroj: Google Earth Engine)

Název	Popis	Rozlišení	Vlnová délka
sur_refl_b01	Surface reflectance for band 1	500 meters	620 – 670nm
sur_refl_b02	Surface reflectance for band 2	500 meters	841 – 876nm
sur_refl_b03	Surface reflectance for band 3	500 meters	459 – 479nm
sur_refl_b04	Surface reflectance for band 4	500 meters	545 – 565nm
sur_refl_b05	Surface reflectance for band 5	500 meters	1230 – 1250nm
sur_refl_b06	Surface reflectance for band 6	500 meters	1628 – 1652nm
sur_refl_b07	Surface reflectance for band 7	500 meters	2105 – 2155nm

2.4 Postup zpracování

Začátkem celého postupu bylo zhlédnutí pomocných tutoriálů a zorientování se v rozhraní Google Earth Engine, zhlédnutí online kurzů k lepšímu pochopení jednotlivých řádků kódů. Následně probíhalo testování algoritmů řízené klasifikace a upravování scriptu. Data byla použita přímo z katalogu obsaženém v samotném GEE. Dalším krokem bylo spuštění klasifikace. Výsledný snímek klasifikace z GEE byl vyexportován ve formátu .GeoTIFF do ArcGIS Pro. Výstup klasifikací byl následně porovnán s referenčními vrstvami v ArcGIS Pro. V poslední fázi došlo k procentuálním výpočtům, v kolika procentech se jednotlivé kategorie shodují s referenční vrstvou.

Klasifikační metody


Prvotně bylo v úmyslu použít 5 klasifikátorů řízené klasifikace dostupné v Google Earth Engine. Těmito algoritmy jsou CART (Classification and Regression Tree), Random Forest, Minimum Distance, Naïve Bayes a Support Vector Machine (SVM). Algoritmus SVM po spuštění klasifikace nevykazoval validní zobrazení, proto od něj bylo upuštěno.

Trénovací množiny

Trénovací množiny byly zaznačeny manuálně přímo do zobrazovacího okna v rozhraní Google Earth Engine. Ke každé třídě bylo přiděleno 4-5 trénovacích množin.



Obr. 1, 2 Rozmístění trénovacích množin pro úroveň 1 – land cover (vlevo Olomouc, vpravo Černovice).



Obr. 3, 4 Rozmístění trénovacích množin pro úroveň 2 – land use (vlevo Olomouc, vpravo Černovice).



Obr. 5, 6 Rozmístění trénovacích množin pro úroveň 3 – biotopy (vlevo Olomouc, vpravo Černovice).

Rozdělení kategorií

Hodnocení přesnosti klasifikace bylo prováděno na 3 úrovních detailu klasifikace krajinného pokryvu. Těmito úrovněmi jsou klasifikace do tříd land cover, klasifikace do tříd land use a klasifikace na úrovni biotopů. Každá úroveň byla popsána v nomenklatuře obvyklými kategoriemi.

Úroveň 1 – land cover

Land cover užívá krajiny a vegetace, která pokrývá zemský povrch. Dá se říct, že je v daném čase kombinací land use (Sklenička, 2003).

Rozděleno do 5 kategorií: les, voda, zástavba, TTP (trvalé travní porosty) a holá půda. Pro obě území jsou kategorie stejné.

Úroveň 2 – land use

Definice pro land use existuje celá řada. Bičík (2010) ve své publikaci definuje land use jako dělení území do kategorií ploch odvozených od způsobu využití. Sklenička říká, že land use je složeno ze dvou částí – biofyzikální a socioekonomické. Jedná se o dynamický pojem, jež zahrnuje formu analýzy a hodnocení krajiny (Sklenička, 2003).

U úrovně 2 se liší kategorie mezi Olomoucí a Černovicemi. Obec Černovice u Tábora byla rozdělena do 12 tříd:

- roztroušená městská zástavba
- průmyslová (výrobní zóna)
- komunikace zpevněné
- komunikace nezpevněné
- orná půda – obhospodařovaná
- orná půda – úhor (holá)
- mix travní a keřové vegetace
- pastviny a louky (TTP)
- listnaté lesy
- jehličnaté lesy
- smíšené lesy
- vodní plocha

Olomouc je rozdělena do 15 kategorií:

- souvislá městská zástavba
- roztroušená městská zástavba
- průmyslová (výrobní zóna)
- staveniště
- komunikace zpevněné
- komunikace nezpevněné
- městské zelené plochy (hřiště)
- orná půda – obhospodařovaná
- orná půda – úhor (holá)
- mix travní a keřové vegetace
- pastviny a louky (TTP)
- listnaté lesy
- jehličnaté lesy

- smíšené lesy
- vodní plocha

Úroveň 3 – biotopy

Sklenička (2003) definuje biotop jako jednotku abiotického prostředí, která se mnohdy týká konkrétního jedince, populaci či společenstva.

Vymezení kategorií pro úroveň 3 byla převzata z Detailní kombinované vrstvy biotopů (Czechglobe, 2018), nomenklatura odpovídá Katalogu biotopů ČR (Chytrý et al. 2010). Z důvodu malých ploch, byly po domluvě s vedoucím práce některé biotopy sloučené do příbuzných skupin. Černovice jsou rozděleny do 13 a Olomouc do 16 kategorií.

Tabulka 4 Přehled kategorií biotopů na území Olomouce

Kód biotopu	Název biotopu
K1 + K3	Mokřadní vrbiny + Vysoké mezofilní a xerofilní křoviny
L1 + L2.2	Mokřadní olšiny + Údolní jasanovo-olšové luhy
L2.4	Tvrdé luhy nížinných řek
L2.3 + L2.3B	Měkké luhy nížinných řek
L3.1	Hercynské dubohabřiny
L5.1 + L5.4	Květnaté bučiny + Acidofilní bučiny
L7.1 + L7.2	Suché acidofilní doubravy + Vlhké acidofilní doubravy
M1.1 + M1.3	Rákosiny eutrofních stojatých vod + Eutrofní vegetace bahnitých substrátů
M1.4 + M1.7	Říční rákosiny + Vegetace vysokých ostríc
S1.2	Štěrbínová vegetace silikátových skal a drolin
T1.1	Mezofilní ovsíkové louky
T1.4	Aluviální psárkové louky
T1.5 + T1.6 + T1.9	Vlhké pcháčové louky + Vlhká tužebníková lada + Střídavě vlhké bezkolencové louky
T3.4D	Širokolisté suché trávníky
T4.2	Mezofilní bylinné lemy
V1F + V1G + V4B	Makrofytní vegetace přirozeně eutrofních a mezotrofních stojatých vod + Makrofytní vegetace vodních toků

Tabulka 5 Přehled kategorií biotopů na území Černovic

Kód biotopu	Název biotopu
K1	Mokřadní vrbiny
K2.1 + K3	Vrbové křoviny hlinitých a písčitých náplavů + Vysoké mezofilní a xerofilní křoviny
L1 + L2.2 + L2B	Mokřadní olšiny + Údolní jasanovo-olšové luhy
L5.4	Acidofilní bučiny
L7.1	Suché acidofilní doubravy
L9.2B	Rašelinné a podmáčené smrčiny
M1.5 + M1.7	Pobřežní vegetace potoků + Vegetace vysokých ostríc
R1.4 + R2.2 + R2.3	Lesní prameniště bez tvorby pěnoveců + Nevápnitá mechová slatiniště + Přechodová rašeliniště
T1.1	Mezofilní ovsíkové louky
T1.3	Poháňkové pastviny
T2.3 + T2.3B + T5.5	Aluviální psárkové louky + Vlhké pcháčové louky + Střídavě vlhké bezkolencové louky
T1.4 + T1.5 + T1.6 + T1.9	Podhorské až horské smilkové trávníky + Podhorské acidofilní trávníky
V1F + V1G	Makrofytní vegetace přirozeně eutrofních a mezotrofních stojatých vod

2.5 Zájmová území

Olomouc

Statutární město Olomouc se nachází ve stejno jmenném kraji na území Moravy. Olomouc se skládá z 26 městských částí. Jedná se o jedno z nejvýznamnějších historické měst v České republice. Rozléhá se v nížinné a úrodné krajině Hané v povodí řeky Moravy. Dříve bylo sídlem králů a arcibiskupů. V dnešní době je Olomouc rozvíjející se a dynamické město s bohatou kulturou. Sídlí zde mnoho ekonomických a průmyslových firem, obchodů či univerzit. Olomouc má převážně rovinný reliéf, pouze v okolí Radíkova a Svatého Kopečku je zvýšený georeliéf. Na území města Olomouce se nachází spousta zeleně a parků.

Černovice u Tábora

Černovice u Tábora jsou malá obec rozkládající se v malebné krajině na pomezí Kraje Vysočina a Jihočeského kraje v okrese Pelhřimov. Zájmové území Černovice spadá pod správu 6 katastrálních území. Charakteristickým rysem pro oblast Černovic jsou zvýšené plochy vrchovin, na nichž převládá komplex rul a pararul. Pro tuto krajinu jsou typické rašelinné louky, rybníky a fragmenty podhorských bučin, kde převažují kulturní smrčiny a orné půdy (Culek a kol., 2013). Okolí obce tvoří zelená údolí a malé zalesnění plochy. Jedná se o klidnou oblast zaměřenou na zemědělství. Jak se uvádí přímo na webových stránkách Zemědělského družstva Černovice (zdcernovice.cz, 2023), zemědělství je tu zaměřeno převážně na obiloviny, řepku, brambory a krmné plodiny. V Černovicích krom obecních rybníků a potoku nevyskytuje žádný vodní tok. Jak uvádí Culek (2013) ve své publikaci typy vodních toků na území Pelhřimovska jsou bystriny a potoky spadající do pstruhového pásma. Místní flóra je chudá, převažují zejména hercynské druhy a doznívají druhy alpské (Čábera, 1969). přirozená vegetace je z velké části složena z kyselých

bukových bučin (též acidofilních bučin), na hřbetních vrcholcích se vyskytují květnaté bučiny a malé zastoupení mají acidofilní doubravy. V severovýchodní části území je možné narazit na dubohabrové háje, na skalnatých vrcholech ojediněle se suťovými lesy a v depresích s podmáčenými smrčínami a rašeliništi (Culek a kol., 2013).

3 DÁLKOVÝ PRŮZKUM ZEMĚ

Dálkový průzkum Země (*angl. Remote Sensing*) se považuje za jednu z moderních geoinformačních technologií. Obecně lze říct, že se jedná o získávání informací o objektech a jevech na dálku čili bez přímého kontaktu. Jde o systém skládající se ze 2 subsystémů – subsystém sběru a přenosu dat a subsystém analýzy a interpretace (Dobrovolný, 1998). DPZ funguje na principu přenosu informací pomocí elektromagnetického záření (Halounová, 2005).

Definice dálkového průzkumu Země (DPZ) existuje hned několik:

- „Dálkový průzkum je věda i umění získávat užitečné informace o objektech, plochách či jevech prostřednictvím dat měřených na zařízení, která s těmito zkoumanými objekty, plochami či jevy nejsou v přímém kontaktu.“ (Lillesand, Kiefer, 1994).
- „Dálkový průzkum je způsob získávání informací o zemském povrchu i vodních plochách s využitím snímků pořízených z ptáčí perspektivy, využívá elektromagnetického záření v jednom nebo více intervalech spektra, toto záření je odráženo nebo emitováno ze zemského povrchu.“ (Campbell, 2002).

3.1 Zpracování obrazu

Zpracování dat může probíhat dvojím způsobem, buď analogově nebo digitálně. V dnešní době se více využívá druhá uvedená metoda, pro svou rychlost, objektivnost, ekonomičnost, snazší úprava a snadný přenos.

Digitální snímek je charakterizován čtyřmi základními vlastnostmi – radiometrické rozlišení, spektrální rozlišení, prostorové rozlišení a časové rozlišení. Každý snímek se skládá z pixelů (obrazových prvků) a každý jeden pixel nese jedno číslo (tzv. DN hodnotu), které je prezentováno jako odstín šedi (Dobrovolný, 1998).

3.1.1 Fáze digitálního zpracování snímku

1. Rektifikaci dat tzv. předzpracování obrazových záznamů, se provádí za účelem zpracování surových dat,
2. Zvýraznění obrazu – v této fázi dochází ke zlepšení obrazu pro další interpretaci,
3. Klasifikace obrazu – více popsáno v kapitole 4,
4. Postklasifikační úpravy,
5. Analýza obrazových dat (jako např. modelování s obrazovými daty),
6. Spojení dat s jinými obrazovými daty a vstup do prostřední GIS.

4 KLASIFIKACE OBRAZU

Za klasifikaci obrazu se považuje proces, kdy je jednotlivým pixelům obrazu přiřazen informační význam. Klade si za cíl nahrazení hodnot radiometrických charakteristik, jež představují spektrální vlastnosti objektů a jevů, znázorněných v původním snímku. Tyto hodnoty jsou vyjádřeny tzv. informačními třídami. Informační třídy jsou formulovány hned na začátku celého procesu klasifikace v podobě tzv. klasifikačního schématu neboli legendy mapy (Dobrovolný, 1998).

Jak uvádí Dobrovolný ve své studii, klasifikace se uplatňuje za použití rozhodovacích pravidel tzv. klasifikátorů, které zařadí veškeré obrazové prvky do informační třídy. Tyto klasifikátory lze rozdělit do několika skupin, např. klasifikátory prostorového chování, časového chování anebo spektrálního chování. Nejvíce propracované a využívané jsou právě poslední zmíněné klasifikátory. To jsou například klasifikátory bodové, tzv. „per-pixel“, za předpokladu, že každý pixel patří pouze do jedné třídy. (Dobrovolný, 1998).

Lillesand a Kiefer ve své publikaci zmiňují, že obecným postupem při klasifikaci obrazu je automatická kategorizace všech pixelů na snímku do tříd. Klasifikace je prováděna prostřednictvím spektrálního rozpoznávání vzorů čili pixely jejichž kombinace odrazivosti je podobná jsou seskupeny do jednotlivých tříd.

Dalším způsobem klasifikace může být prostorové rozpoznání vzorů. Jedná se o naprosto odlišný přístup od spektrálního rozpoznání vzorů.

Prostorové klasifikátor zohledňují aspekty jako je textura obrazu, velikost a tvar prvků či vzdálenost pixelů. Obrazové pixely jsou kategorizovány na základě prostorového vztahu k pixelu, jimiž je obklopen. Tento způsob klasifikace je daleko složitější a výpočetně náročnější než postup spektrálního rozpoznání vzorů (Lillesand, Kiefer, 2015).

Klasifikace se dělí na řízenou a neřízenou. A právě řízenou klasifikací se zabývám v následující podkapitole.

4.1 Řízená klasifikace

Řízená klasifikace (*angl. Supervised Classification*) neboli klasifikace s učitelem, je nejčastěji používanou technikou pro kvantitativní analýzu obrazových dat DPZ (Richards, 2013). Jde o proces aplikace vzorků o známé identitě. Operátor předem zpřesňuje výpočetnímu algoritmu numerický popis hledaných povrchů v podobě tzv. trénovacích ploch. Trénovací plochy jsou části obrazů, které reprezentují známý povrch (Dobrovolný, 1998).

Jak popisuje Richards (2013) ve své publikaci, podstatou klasifikace s učitelem je segmentace spektrální oblasti na oblasti, které lze přiřadit k třídám půdního pokryvu, které se mohou překrývat (Richards, 2013). Zpracovatel musí na začátku definovat kategorie, jež budou klasifikovány, legendu či klasifikační schéma. Klasifikační schéma mnohdy vzniká v hierarchické struktuře, jehož každý úsek odpovídá jistému měřítku tematické mapy (Dobrovolný, 1998). Každý pixel v datovém souboru je pak číselně porovnán s každou kategorií v interpretačním klíči a označen názvem kategorie, které se "nejvíce podobá" (Lillesand, Kiefer, 2015).

Řízená klasifikace má k dispozici několik různých algoritmů, od algoritmů založených na principu pravděpodobnostního rozdělení až po algoritmy spektrálního rozdělení vzorků. Každý algoritmus se liší v identifikaci a popisu oblasti ve spektrálním prostoru. Existují algoritmy, které se snaží o jednoduchou geometrickou segmentaci a na druhou stranu jsou

algoritmy, které používají statistické modely, pomocí nichž spojují spektrální měření a zájmové třídy. Dále pak jsou klasifikátory, které si poradí s třídami, jež nadefinoval uživatel a mohou se překrývat, tzv. měkké klasifikační metody. Opačným typem jsou algoritmy, které vytvářejí pevné hranice mezi třídami (Richards, 2013).

Richards (2013) popisuje následujících 6 kroků při použití klasifikátoru, bez ohledu na použitou metodu:

1. Definování informačních třídy pro segmentaci obrazu
2. Výběr reprezentativních pixelů ke každé třídě, k vytvoření trénovacích množin. Trénovací množiny jsou pro každou třídu stanoveny na základě map či leteckých snímků. Trénovací pixely jednotlivých tříd se mnohdy nachází ve stejném tréninkovém poli.
3. Použití trénovacích dat a definování jejich parametrů algoritmů, které budou použity.
4. Použití natrénovaného algoritmu k zařazení do jedné z kategorií.
5. Vyhodnocení tabulek a map zobrazující výsledky klasifikace
6. Vyhodnocení přesnosti výstupů pomocí testovacích sad

4.1.1 Trénovací plochy

Trénovací plochy znázorňují jednotlivé kategorie vyobrazené na snímku. Uvádí se jako nejdůležitější krok při tvorbě řízené klasifikace. Dochází ke sběru informací o zpracované lokalitě z terénního průzkumu nebo jiných zdrojů, tzv. podpurných dat. Trénovací data musí být reprezentativní a kompletní. Ke klasifikaci je nutné, aby byly charakterizovány veškeré kategorie s jejichž typickými částmi obrazů (natur.cuni.cz, 2022). Zařazení několika spektrálních tříd do jedné není dobrou volbou. Například jeli na snímku pouze jedna vodní plocha, jejíž uniformní chování je spektrální, postačí k charakteristice této třídy jedna trénovací množina. Ale pokud je na obraze jedna či více vodních ploch s odlišným spektrálním chováním, je potřeba popsat veškeré spektrální třídy trénovacími plošinami (Dobrovolný, 1998).

4.1.2 Vymezení trénovacích množin

V první řadě při řízené klasifikaci dochází k definování tzv. trénovacích ploch ke každé kategorii či třídě, jež je na snímku identifikována. Tyhle „automatické“ trénovací plochy vybírá zpracovatel. V této etapě jde především o shromáždění informací o zpracovávaném území z tzv. podpurných dat (jedná se o terénní průzkum nebo jiných zdrojů). Je velmi důležité, aby tahle první část vymezení byla provedena kvalitně, protože na ní závisí úspěch či neúspěch celé klasifikace. Zkoumaná data musí být komplexní a reprezentativní (Dobrovolný, 1998).

Obrys trénovacích ploch můžeme definovat i „manuálně“ pomocí tzv. úvodního (zárodečného) pixelu (angl. seed pixel). Tento pixel je vybrán na ploše příznačné pro danou kategorii jako reprezentativní pro své okolí. Posléze jsou k tomuto pixelu, na základě předem daných pravidel, vybírány další pixely, které mají podobné spektrální chování. Ty se pak stávají trénovací množinou pro danou třídu.

Pro jakýkoliv klasifikátor, bez ohledu na způsob vymezení, je nutné, aby minimální počet pixelů, které tvoří trénovací množinu byl $N + 1$, kde N je počet klasifikovaných spektrálních písem. Pokud je menší počet pixelů, dochází k nesprávnému generování statistických spektrálních příznaků. Rozdělení trénovacích ploch by mělo být rovnoměrné na ploše

obrazu, neboť odrazivé a vyzařovací vlastnosti stejných jevů mohou být v různých částech obrazu různé (Dobrovolný, 1998).

Definice vhodných trénovacích ploch závisí na níže uvedených faktorech:

- dostatečný počet pixelů v každé trénovací ploše,
- vhodná velikost trénovacích ploch,
- vhodná poloha trénovacích ploch,
- umístění trénovacích ploch,
- rozmístění trénovacích ploch pro danou třídu,
- míra homogenity trénovacích ploch z hlediska jejich spektrálního chování.

4.2 Klasifikační algoritmy

Jak uvádí Dobrovolný (1998), klasifikátory jsou rozhodovací pravidla, díky nimž jsou jednotlivé prvky obrazu zařazeny do kategorií. Předpokládá se, že se rozhodovací pravidla (klasifikační algoritmy) obrazových prvků tříd budou shlukovat do vícerozměrného příznakového prostoru. Je potřeba najít pravidlo, jaké určí, ke kterému shluku jednotlivé pixely patří, může nastat, že nepatří do žádného, v tomto případě se jedná o nezařazené pixely.

V následujících podkapitolách jsou shrnuty použití klasifikační algoritmy:

- Naïve Bayes
- Random Forest (RF)
- Classification and Regression Trees (CART)
- Minimum Distance

4.2.1 Naïve Bayes

Naivní bayesovský klasifikátor je známý jako nejjednodušší bayesovský klasifikátor (Aggarwal, 2015). Jedná se o klasifikační techniku založenou na Bayesově teorému s předpokladem nezávislosti prediktorů. Zjednodušeně lze říct, že Naivní Bayesův klasifikátor předpokládá, že přítomnost určitého znaku ve třídě nesouvisí s přítomností žádného jiného znaku (Webb, 2017). Bayesovy klasifikátory vytváření velmi dobře fungující a jednoduché modely, především v oblasti předpovídání nemocí či klasifikací dokumentů (Raschka, 2014).

Spolu s jednoduchostí je známo, že Naive Bayes je robustní, rychlý, přesný a lehce implementovaný klasifikátor v mnoha odvětvích. Především u malé velikosti vzorku se schopen překonat i velmi sofistikované a výkonné klasifikační metody (Raschka, 2014).

Typickou ukázkou, proč se klasifikátor nazývá „naivní“ může být příklad na ovoci. Ovoce může být považováno za jablko, pokud je červené a kulaté. Přestože tyto dvě vlastnosti jsou na sobě závislé (či jsou závislé na existenci dalších vlastností), tak všechny vlastnosti zároveň nezávisle přispívají k pravděpodobnosti, že se jedná o jablko (analyticsvidhya.com, 2023).

Tento algoritmus byl použit např. ve třech uvedených studiích:

- *Image classification of artworks based on multiple naive Bayes algorithm* (Liang, 2021),
- *Halftone Image Classification Using LMS Algorithm and Naive Bayes* (Liu, 2011),
- *Local Naive Bayes Nearest Neighbor for Image Classification* (McCann, 2012).

4.2.2 Random Forest (RF)

Random Forest je populární algoritmus strojového učení, který patří mezi techniky učení s učitelem. Lze jej použít pro klasifikační i regresní úlohy. Jedná se o klasifikátor, který se skládá ze souboru, jehož struktura je stromovitá (Breiman, 1999). Algoritmus Random Forest který tvoří několik rozhodovacích stromů pomocí náhodně vybrané podmnožiny trénovacích dat (Belgiu, 2016).

Patří mezi nové metody a přístupy strojového učení a rozpoznávání vzorů. RF klasifikátor je velmi robustní s ohledem na rozložení vstupních dat, má obecně velmi dobrý výkon a nevyžaduje rozsáhlé hyperladění parametrů (Wenzhong Shi, Michael F. Goodchild, 2021).

Díky algoritmu Random Forest, bylo dosaženo zlepšení přesnosti klasifikace. Příkladem může být metoda bagging, kdy se pro růst každého stromu provádí náhodný výběr (bez náhrady) z příkladů v trénovací množině (Breiman, 1999).

Dle studie Cutler a Stevens (2011) je algoritmus Random Forest z výpočetního hlediska používán především proto, že je relativně rychlý na trénování a predikci, lze jej použít pro problémy s velkým rozměrem a zvládá jak regresi, tak klasifikaci více tříd. Ze statistického hlediska je oblíbený díky funkcím jako imputace chybějících hodnot, detekce odlehklých hodnot.

Tento algoritmus pro klasifikaci obrazu byl použit například v následujících studiích:

- *SPECT image classification using random forests (Ramirez, 2009).*
- *Performance of Random Forest Classifier for Flood Mapping Using Sentinel-1 SAR Images (Chu, 2022).*
- *Remote sensing image gap filling based on spatial-spectral random forests (Wang, 2022).*

4.2.3 Classification and Regression Tree (CART)

CART je prediktivní model, vysvětlující, jak lze hodnoty výsledné proměnné předpovědět na základě jiných hodnot. Tento algoritmus nevyžaduje předchozí výběr proměnných, ale sám definuje významné proměnné a odstraní ty méně významné (náhodné proměnné).

Principem algoritmu CART je konstrukce tzv. rozhodovacích stromů pomocí historických dat. Tyhle rozhodovací stromy se využívají ke klasifikaci nových dat. K jejich konstrukci je zapotřebí tzv. learning sample, což je soubor dat s předem přiřazenými kategoriemi pro všechna pozorování (Duda, 2001). Cílem algoritmu CART je z kořenového uzlu vytvořit podskupiny, které budou třídně čistší než v předchozím uzlu (Richards, 2013).

Výstupem modelu CART je rozhodovací strom, kde každé rozvětvení představuje rozdělení predikční proměnné a každý koncový uzel obsahuje předpověď výsledné proměnné (Dutta, 2021). CART poskytuje obecný rámec, který lze různými způsoby konkretizovat a vytvářet různé rozhodovací stromy. Rozhodovací stromy představují sadu otázek, na které lze odpovědět pouze ano/ne. Příkladem může být trénovací množina, která by obsahovala 5 tříd. Očekáváním by bylo. Že podskupiny budou obsahovat pixely z méně než 5 tříd a jedna podskupina pouze z jedné třídy. Při postupování dolů se třídy dále dělí, a nakonec jsou vytvořeny skupiny, které obsahují pixely pouze z jedné třídy, tedy ty čisté skupiny (Richards, 2013).

V přístupu CART existuje šest obecných typů otázek (Duda, 2001):

1. Vlastnosti by měly být omezeny na binární hodnotu nebo by měly být povoleny s více hodnotami? tzn. kolik výsledků rozhodnutí nebo dělení je v uzlu,
2. Která vlastnost by měla být v uzlu testována?
3. Kdy má být uzel deklarován jako list?
4. Pokud je strom „příliš velký“, jak jej lze zmenšit a zjednodušit?
5. Pokud je uzel znečištěný, jak by měla být přiřazena kategorie?
6. Jak by se mělo zacházet s chybějícími údaji?

Jak uvádí Goetz et al. aplikace klasifikačních a regresních stromů (metod) je ve výzkumu dálkového průzkumu Země stále více populární (Liang, 2012).

Případové studie použití algoritmu CART:

- *Classification and regression trees: A powerful yet simple technique for ecological data analysis (De'ath, 2000),*
- *Classification and regression trees – Breiman, L, Friedman, Jh, Olshen, Ra, Stone, Cj (Praagman, 1985),*
- *GIS-based groundwater potential mapping using boosted regression tree, classification and regression tree, and random forest machine learning models in Iran (Naghbi, 2016).*

4.2.4 Minimum Distance

Algoritmus Minimum Distance klasifikuje vektory podle nejkratší vzdálenosti vstupního vektoru vzhledem ke všem středům tříd. Vektor přiřadí ke středu třídy, která má nejkratší vzdálenost. Je to snadný a decentrální způsob, jak vyřešit klasifikační problém. Vzdálenost mezi vektory se často vyhodnocuje podle Manhattanovy a Euklidovské vzdálenosti (Zhao, 2012).

Klasifikátor minimální vzdálenosti nevyužívá informace o kovarianci, ale je závislý pouze na středních polohách spektrálních tříd. Je důležité podotknout, že pro daný počet vzorků je lze odhadnout přesněji než kovariance. Tento klasifikátor používá trénovací data k určení třídních průměrů a klasifikace se pak realizuje zařazením pixelů do třídy nejbližšího průměru. Jedná se o rychlejší klasifikátor, než je algoritmus maximální pravděpodobnosti, ale kvůli nepoužívání kovariantních dat není tak flexibilní. Protože se v metodě algoritmu minimální vzdálenosti nepoužívají kovariantní data, jsou modely tříd ve spektrální oblasti symetrické. Podlouhlé třídy proto nebudou dobře modelovány (Richards, 2013).

Případové studie používající algoritmus Minimum Distance:

- *Face Recognition Using PCA and Minimum Distance Classifier (Mondal, 2017),*
- *Quantum Minimum Distance Classifier (Santucci, 2017),*
- *Learning the kernel parameters in kernel minimum distance classifier (Zhang, 2006).*

4.3 Hodnocení přesnosti klasifikace

Je důležité výsledky klasifikace hodnotit s ohledem na polohu (Dobrovolný, 1998).

Mezi nejvíce používané metody pro hodnocení přesnosti klasifikace se řadí klasifikační chybová matice a kappa koeficient. Než dojde k ukončení klasifikace je nutné zhodnotit její přesnost (Lillesand, Kiefer, 1994).

4.3.1 Klasifikační chybová matice

Klasifikační chybová matice je nejpoužívanější metoda k vyhodnocení úspěšnosti klasifikace. Srovnává vztah mezi referenčními daty a výsledky klasifikace u všech informačních tříd. Chybová matice je čtvercová čili počet sloupců a řádků je shodný s počtem hodnocených kategorií (Dobrovolný, 1998). Sloupce jsou tvořeny skutečnými daty a řádky odpovídají klasifikovaným datům (natur.cuni.cz, 2022). Trénovací plochy obrazu jsou potřebné k přesnosti testování klasifikace (Dobrovolný, 1998).

4.3.2 Kappa koeficient

Kappa koeficient je kvantitativní metoda k určení výsledků hodnot automatické klasifikace. Jde o hodnotu porovnávací klasifikaci dle rozhodovacího pravidla s klasifikací, která vznikla náhodně při zařazování pixelů do tříd. Výpočet kappa koeficientu je předpoklad, že dojde ke správnému zařazení určitého procenta pixelů (Dobrovolný, 1998).

Kappa koeficient se dá vyjádřit následujícím vzorečkem:

$$\kappa = \frac{PP - PO}{1 - PO} \quad (1)$$

kde PP je přesnost pozorovaná (určená z chybové matice) a PO je přesnost dosažitelná čistě náhodným zařazením pixelů do jednotlivých tříd (Dobrovolný, 1998).

5 GOOGLE EARTH ENGINE

Google Earth Engine je bezplatná cloudová platforma pro geoprostorovou analýzu. GEE umožňuje přístup k vědeckým analýzám a vizualizacím satelitních snímků planety Země a geoprostorových dat. Google Earth Engine obsahuje datový katalog s možností vyhledávání mezi několika desítkami datových sad, jako je Landsat, Sentinel, MODIS, klimatická data či data o počasí a o půdním pokryvu.

Asi největší výhodou GEE je, že není potřeba stahování žádného softwaru, tím pádem není nutné mít výkonné zařízení, ani mnohabitová data, protože tohle vše již obsahuje. Další významnou výhodou je dostupnost odkudkoliv a z jakéhokoliv zařízení s internetovým připojením.

Google Earth Engine je ovladatelný skrze programovací rozhraní API (*angl. application programming interface*). Veškeré funkce jsou uživatelům dostupné pomocí knihoven v programovacích jazycích JavaScript a Python.

Poslední dobou se platforma Google Earth Engine hojně využívá při vědeckých výzkumech a analýzách dálkového průzkumu Země. Takovým výzkumem může být např. předpověď výskytu nemoci nebo správa přírodních zdrojů.

5.1 Základní princip práce s online platformou GEE

Veškerá práce v prostředí Google Earth Engine probíhá přímo na webovém prohlížeči v editoru kódu, který je dostupný na adrese <http://code.earthengine.google.com>, prostřednictvím rozhraní API a vývojového prostředí IDE. Při práci v Google Earth Engine je možné používat programovací jazyk JavaScript nebo Python, který se ovšem nedoporučuje pro začátečníky.

Google Earth Engine obsahuje katalog, ve kterém je obsažena celá řada datových sad (družicové a letecké snímky – Sentinel, Landsat a MODIS, klimatická data, topografická a socioekonomická data a mnoho dalších). Tyhle datové sady je možné dvěma kliky nahrát do editoru kódu a dále s nimi pracovat. Dále pak obsahuje data multispektrální a hyperspektrální. Datasets lze vyhledávat pomocí tagů.

Rozhraní editoru kódu je rozděleno do tří panelů. Okno *Code editor* je určen k psaní příkazu v programovacím jazyce JavaScript. Napsaný skript se odesílá na server Googlu, kde dochází k jeho zpracování a výsledky se uživateli zobrazují v mapovém okně. Funkce editoru jsou vytvořené tak, aby umožnily rychlý a snadný vývoj geoprostorových postupů.

Jednotlivé skripty lze vkládat, upravovat a ukládat. Editor kódu je interaktivní prostředí pro vývoj aplikací Earth Engine. Je-li kód napsán chybně, dojde k jeho zvýraznění a rady ke správné syntaxi.

Nad oknem Code editor je umístěno několik tlačítek. Tlačítko *Get Link*, který vygeneruje v adresním řádku jedinečnou URL adresu skriptu. Dále se tu nachází tlačítko *Save* – slouží k uložení příkazu, *Run* – k jeho spuštění a *Reset* – slouží k vymazání výstupní mapy a konzole. A poslední tlačítko *Apps*, které umožňuje vytvořit aplikaci z editoru kódu.

V horní části editoru kódu se nachází pole pro vyhledávání datových sad a míst. A v levé části je panel, který obsahuje 3 karty – *Scripts*, *Docs* a *Assets*.

V kartě *Scripts* se ukazují ukázkové kódy a již uložené kódy pomocí tlačítka *Save* v editoru kódu. Umožňuje ukládání soukromé, sdílené a ukázkové skripty do Git repositářů. Soukromé skripty jsou uloženy v úložišti, do kterého má přístup pouze vlastník (složka *Owner*): `user/username/default`. Ve složce *Writer* jsou repositáře, kterým udělil vlastník uživateli přístup pro zápis. Uživatel je oprávněn upravovat nebo přidávat nové skripty nebo měnit přístup, ale není možné odebrat vlastníka. V adresáři *Reader* jsou uloženy repositáře,

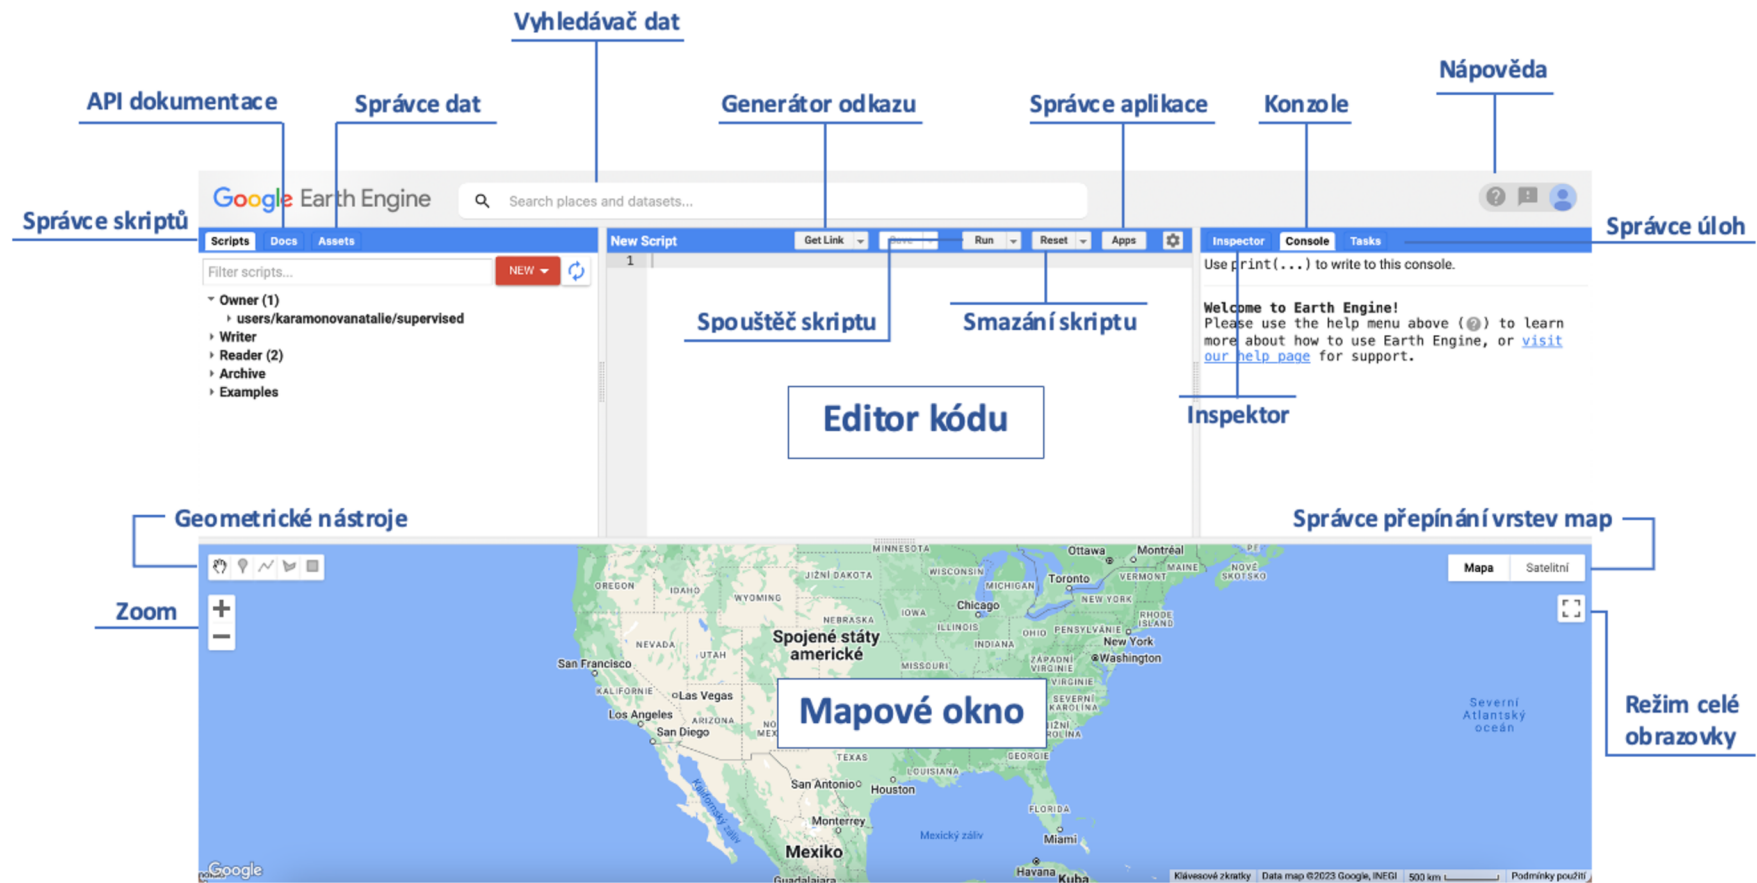
ke kterým je udělený přístup pouze pro čtení. Adresář *Archive* obsahuje starší úložiště, ke kterým má uživatel přidělen přístup, ale jejich vlastník je ještě nepřevedl ze starší verze správce skriptů. A poslední složka *Examples* je speciální úložiště, které obsahuje ukázky kódu, spravované přímo společností Google.

Záložka *Docs*, která se nachází v levém panelu editoru kódu, obsahuje odkazy k funkcím rozhraní Earth Engine API/kompletní dokumentaci API JavaScript. Záložka *Assets* umožňuje nahrávat a spravovat vlastní geodata.

V pravém panelu jsou umístěna tlačítka *Inspector*, *Console* a *Tasks*. Karta *Inspector* zprostředkovává interaktivní dotazování na mapu. Po kliknutí na panel mapy umožní zjistit hodnotu vrstev. Karta *Console* vrací zprávy při běhu skriptů a tisku informací o datech a výsledcích. Zaznamenává i informace o chybách. Záložka *Tasks* umožňuje spuštění specifických metod, které jsou nebo mohou být časově náročné, například import a export dat.

Tlačítko *Nápověda* zobrazuje odkazy na uživatelskou příručku, fórum s nápovědou, prohlídku editoru kódu, seznam klávesových zkratk pro editor kódu a feedback (Earth Engine Code Editor, 2023).

Obr. 7 Vývojové rozhraní Google Earth Engine.



5.2 Algoritmy použití při řízené klasifikaci v GEE

Hlavními algoritmy používanými v prostředí Google Earth Engine pro řízenou klasifikaci jsou Random Forest, CART, SVM, Minimum Distance a Naïve Bayes. Ke každému algoritmu jsou popsány parametry, které jsou dostupné v online dokumentaci GEE (API Reference, 2023).

5.2.1 Random Forest

Algoritmus Random Forest je model strojového učení. Jeho nastavené parametry ovlivňují chování modelu a určují, jakým způsobem se vstupní data budou používat k tvorbě výstupů. Základní charakteristika algoritmu je v kap. 4.2.2.

Parametry, které je možné nastavit:

- *numberOfTrees* – určuje kolik stromů bude použito k tvorbě modelu. Čím větší počet stromů, tím větší pravděpodobnost robustnosti a přesnosti. Výpočet trvá delší dobu.
- *variablesPerSplit* – zobrazuje celé číslo počtu predikčních proměnných, které mají být vzorkovány pro každé rozdělení stromů.
- *minLeafPopulation* – jedná se o minimální počet uzlů v listu. Tento parametr kontroluje a zabraňuje přílišnému růstu stromů.
- *bagFraction* – podíl trénovacích vzorků použitých pro každý strom. Jde o číslo v rozsahu [0,1]. Menší hodnota čísla může zabránit nadměrnému přizpůsobení, ale také může vést k méně přesným modelům.
- *maxNodes* – udává maximální počet uzlů listu v každém stromu. Pokud není zadáno, výchozí hodnota je bez omezení
- *seed* – randomizační pole. Jedná se o náhodné „semínko“, které se používá k inicializaci generátoru náhodných čísel. Lze jej použít k zajištění reprodukovatelných výsledků.

```
//vytvoření klasifikátoru + definování parametrů
var classifier = ee.Classifier.smileRandomForest(200).train({
  features: training,
  classProperty: 'landcover',
  inputProperties: bands
});
```

Obr. 8 Část skriptu pro GEE zachycující klasifikátor RF.

5.2.2 CART

Classification and Regression Tree (CART), který se v GEE používá k řešení klasifikace pod dohledem. Princip práce klasifikátoru je založený na rozdělení vstupních dat na menší podmnožiny na základě predikčních proměnných. Výsledkem je model, k předpovídání tříd či spojitých hodnot pro nová data. Základní charakteristika klasifikátoru je v kap. 4.2.3.

Parametry nastavitelné pro algoritmus CART:

- *maxNodes* – maximální počet uzlů v každém stromu. Když není zadáno jinak, výchozí hodnota je bez omezení. Není podporován.
- *minLeafPopulation* – vytvoří pouze uzly. Jde o celé číslo, které určí minimální počet pixelů přítomných v listovém uzlu. Listový uzel je koncovým uzlem stromu, bez

dalšího rozdělení. Čím menší hodnota, tím složitější strom s větším počtem rozdělení a menšímu listovými uzly. Příliš vysoké nastavení může vést k nedostatečnému přizpůsobení. Optimální hodnota může být určena metodou pokus-omyl.

```
//vytvoření klasifikátoru + definování parametrů
var classifier = ee.Classifier.smileCart().train({
  features: training,
  classProperty: 'landcover',
  inputProperties: bands
});
```

Obr. 9 Část skriptu pro GEE zachycující klasifikátor CART.

5.2.3 Minimum Distance

Jednoduchá metoda klasifikace s učitelem. Princip klasifikátoru – každý pixel na obrázku, je přiřazen ke třídě, kterou představuje nejbližší trénovací vzorek. Základní principy algoritmu jsou popsány v kapitole 4.2.4.

Co lze nastavit u klasifikátoru Minimum Distance:

- *metric* – metrika minimální vzdálenosti se při klasifikaci používá k porovnání vlastností vstupních dat a trénovacích vzorků. Euklidovská vzdálenost znázorňuje přímkovou vzdálenost mezi 2 body v prostoru prvků.
- *kNearest* – určuje počet nejbližších trénovacích vzorků/počet nejbližších sousedů, které se použijí pro každý trénovací pixel. Čím větší počet, tím delší výpočetní čas a vyšší přesnost a robustnost klasifikace.

```
//vytvoření klasifikátoru + definování parametrů
var classifier = ee.Classifier.minimumDistance().train({
  features: training,
  classProperty: 'landcover',
  inputProperties: bands
});
```

Obr. 10 Část skriptu pro GEE zachycující klasifikátor Minimum Distance.

5.2.4 Support Vector Machine (SVM)

Principem SVM je nalezení rozhodovací hranice, která odděluje třídy. Přesnost algoritmu je závislá na kvalitě trénovacích dat a na výběru funkcí.

Možnosti nastavitelných parametrů:

- *decisionProcedure* – rozhodovací postup pro použití klasifikace. Volba parametru závisí na počtu tříd a velikosti trénovacích množin.
- *svmType* – volba je závislá na přesnosti a odolnosti vůči odlehlým hodnotám a šumu. C_SVC – metoda, jež najde rozhodovací hranice maximalizující rozpětí mezi třídami. Je robustnější proti odlahlým hodnotám a šumu. NU_SVC – metoda nalezení rozhodovací hranice minimalizující horní omezení chybně klasifikovaných vzorků. A metoda ONE_CLASS – jejím cílem je identifikace vzorků lišících se od trénovacích množin.
- *kernelType* – jedná se o typ jádra, k mapování vstupních dat, ve kterých lze nalézt lineární rozhodovací hranici. Metody LINEAR, POLY, RBF a SIGMOID. Jádro linear je vhodné pro lineárně separovatelná data. jádro poly je mapováno pomocí

polynomické transformace. Vhodné pro lineárně neseparovatelná data. stejně tak i jádro RBF a sigmoid.

- *shrinking*
- *degree* – jde o stupeň polynomu. Platí pouze pro POLY jádra.
- *gamma* – hodnota gamma ve funkci jádra. Výchozí hodnota je převrácená hodnota počtu funkcí. Platí pro jádra POLY, RBF a SIGMOID.
- *coef0* – hodnota coef0 ve funkci jádra. Výchozí hodnota je 0.
- *cost* – parametr cost. Výchozí hodnota je 1.
- *nu* – paramter nu. Výchozí hodnota činí 0,5.
- *terminationEpsilon* – tolerance ukončovacího kritéria. Výchozí hodnotou je 0,001.
- *lossEpsilon* – epsilon ve ztrátové funkci.
- *oneClass* – platí pouze pro jednotřídní SVM. Možné hodnoty jsou 0 a 1.

```
//vytvoření klasifikátoru + definování parametrů
var classifier = ee.Classifier.libsvm({
  kernelType: 'poly',
  degree: 3,
  cost: 1
});
```

Obr. 11 Část skriptu pro GEE zachycující klasifikátor SVM.

5.2.5 Naïve Bayes

Jedná se o algoritmus, který předpokládá, že se vektor skládá pouze z kladných celých čísel, záporné hodnoty jsou vyřazeny. Je založen na Bayesově teorému, který říká, že: pravděpodobnost třídy vzhledem k sadě predikčních proměnných lze vypočítat z předchozí pravděpodobnosti třídy a pravděpodobnosti predikčních proměnných vzhledem k dané třídě. Základní charakteristika algoritmu je blíže popsána v kap. 4.2.1.

Dostupné parametry, které lze nastavit v Google Earth Engine:

- *Lambda* – v některých implementacích algoritmu se používá k zamezení přiřazení nulové pravděpodobnosti třídám. Metoda `tranClassifier()` ji nepodporuje.

```
//vytvoření klasifikátoru + definování parametrů
var classifier = ee.Classifier.smileNaiveBayes().train({
  features: training,
  classProperty: 'landcover',
  inputProperties: bands
});
```

Obr. 12 Část skriptu pro GEE zachycující klasifikátor Naïve Bayes.

6 VÝSLEDKY

Kapitola výsledky je rozdělena na několik na sebe logicky navazujících podkapitol – základní práce s GEE, výsledky klasifikací provedených na území Olomouce (pro všechny zkoumané úrovně), výsledky klasifikací provedených na území Černovic (pro všechny zkoumané úrovně) a vyhodnocení výsledku procentuálních shod pro obě zájmová území. Výsledné procentuální hodnoty jsou pro každý snímek a algoritmus uvedeny v tabulkách.

6.1 Základní práce s GEE

Vymezení zájmového území

Jako první je nutné si vymežit zájmové území (ROI). Přes záložku *Assets* v GEE lze nahrát vrstva shapefile, CSV nebo data ve formátu GeoTIFF či TFRDcord.

```
Map.addLayer(roi)
Map.centerObject(roi,10)
```

Obr. 13 Vymezení území v GEE.

Výběr vhodného datasetu

Dalším nezbytným krokem je přidání datasetu a zadání parametrů – vymezení dat, ořezání na zájmové území, míra oblačnosti.

```
var image = ee.ImageCollection("COPERNICUS/S2")
    .filterDate("2022-07-30","2022-08-30")
    .filterBounds(roi)
    .filterMetadata('CLOUD_COVERAGE_ASSESSMENT','less_than',45)
    .median()
    .clip(roi)
print(image);
```

Obr. 14 Definice snímku a jeho parametrů v GEE.

Vizualizace

Nastavení barev, aby působily co nejvěrohodnějším dojmem, tak jak je vidí lidské oko. Parametry min a max udávají hodnotu rozsahu intenzity. Parametr bands uvádí spektrální pásma.

```
var trueColour = {
  min:0,
  max:3000,
  bands:("B4", "B3", "B2")
}
Map.addLayer(image, trueColour, "True-colour image");

var falseColour = {
  min:0,
  max:3000,
  bands:("B8A", "B4", "B3")
}
Map.addLayer(image, falseColour, "False-colour image");
```

Obr. 15 Nastavení barev v GEE.

Definování klasifikačních tříd a pásem

Následuje krok definování klasifikačních tříd a spektrálních pásem.

```
var classNames =  
forest.merge(water).merge(urban).merge(grass).merge(bare);  
print(classNames);  
  
var bands = ['B8', 'B5', 'B4', 'B3', 'B2'];
```

Obr. 16 Definování klasifikačních tříd a spektrálních pásem v GEE.

Trénovací množiny

Trénovací data musí mít zadaný parametry – názvy klasifikačních tříd, krajinnou jednotku a pixelové rozlišení.

```
var training = image.select(bands).sampleRegions({  
  collection: classNames,  
  properties: ['landcover'],  
  scale: 10  
});  
print(training, 'Training Data');
```

Obr. 17 Zadání parametrů k trénovacím množinám v GEE.

Nastavení algoritmu

Pro každý použitý algoritmus se v parametrech zadávají trénovací množiny, vlastnosti a spektrální pásma.

```
var classifier = ee.Classifier.smileCart().train({  
  features: training,  
  classProperty: 'landcover',  
  inputProperties: bands  
});
```

Obr. 18 Definování klasifikačního algoritmu v GEE.

Klasifikace obrazu

Poslední částí před spuštěním skriptu je klasifikace obrazu. Definovány jsou vizualizační parametry a minimální a maximální hodnoty zobrazené na mapě.

```
var classified = image.select(bands).classify(classifier);  
Map.addLayer(classified,  
{min: 0, max: 5, palette: ['blue', 'green', 'red', 'yellow', 'orange']},  
'classification');
```

Obr. 19 Klasifikace obrazu v GEE.

Export dat

Google Earth Engine umožňuje export obrázků, mapových dlaždic, tabulek a videí. Ukládání je možné na Google Disk, do cloudového úložiště nebo do záložky *Assets*. Nejsnadnější způsob exportu výstupů z GEE, pro další zpracování v ArcGIS Pro, je uložení na Google Disk přes funkci *Export.image.toDrive* ve formátu GeoTIFF. Je nutné zadat, který snímek má být exportován, pojmenování, formát, rozlišení, zájmovou oblast a souřadnicový systém.

```

Export.image.toDrive({
  image: classified,
  description: 'cernovice_sentinel_level1_cart',
  fileFormat: 'GeoTIFF',
  scale:10,
  maxPixels:1e10,
  region: roi,
  crs: 'EPSG:32633',
  formatOptions: {
    cloudOptimized: true
  }
});

```

Obr. 20 Export snímku na Drive v GEE.

6.2 Výsledky klasifikací provedených na území Olomouce


Výsledky klasifikací, počty pixelů pro jednotlivé kategorie, shody s referenční vrstvou, jak celkovou, tak pouze v daných kategoriích jsou vyobrazeny v tabulkových a grafických výstupech.

6.2.1 Klasifikace na úrovni 1 (land cover)

Tabulka 6 Počet pixelů úrovně 1 snímku Sentinel-2 v Olomouci

ÚROVEŇ 1 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
les	159633	185935	288586	312080	153299
voda	17321	16141	24050	9860	16766
zástavba	267415	309267	277441	319969	152682
TTP	360589	275014	273758	334997	260344
holá půda	228147	246748	169270	56199	450014

Tabulka 6 a graf 1 ukazují počet pixelů na úrovni 1 na snímku Sentinel-2 pro Olomouc. Na základě vyklasifikovaných pixelů pro každou třídu lze konstatovat, že nejvíce shodný s referenční vrstvou je algoritmus CART a Random Forest. **Random Forest se nejvíce přibližuje** počtu pixelů ve třídách **TTP** a **voda**. Kdežto algoritmus **CART** ve třídě **les**. Algoritmus Naïve Bayes vyklasifikoval třídy les a zástavba dvojnásobně a třídy voda a holá půda několikanásobně menší.

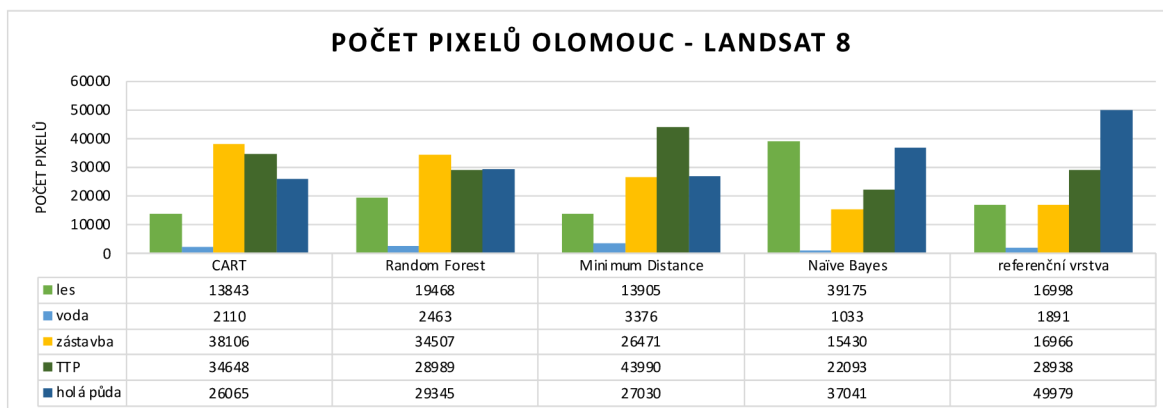


Graf 1 Počet pixelů na území Olomouce pro úroveň 1 – snímek Sentinel-2.

Tabulka 7 Počet pixelů úrovně 1 snímku Landsat 8 v Olomouci

ÚROVEŇ 1 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
les	13843	19468	13905	39175	16998
voda	2110	2463	3376	1033	1891
zástavba	38106	34507	26471	15430	16966
TTP	34648	28989	43990	22093	28938
holá půda	26065	29345	27030	37041	49979

Tabulka 7 a graf 2 znázorňují počet pixelů na úrovni 1 pro snímek Landsat 8 na území Olomouce. Lze konstatovat, že třídu **voda nejlépe** vyklasifikoval algoritmus **CART**, třídu **TTP** algoritmus **Random Forest**. Třídu **les** algoritmus **CART** s algoritmem **Minimum Distance**. Třída **zástavba** a **holá půda** je nejlépe vyhodnocena algoritmem **Naïve Bayes**.

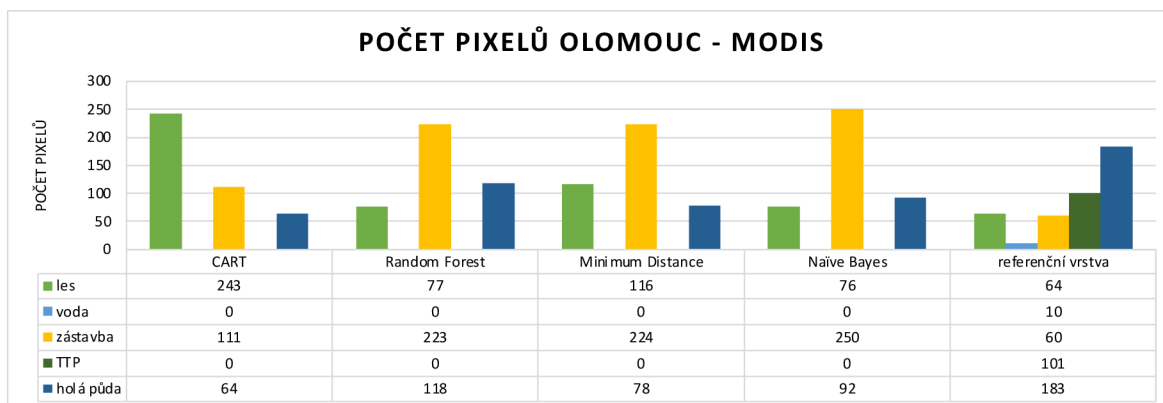


Graf 2 Počet pixelů na území Olomouce pro úroveň 1 – snímek Landsat 8.

Tabulka 8 Počet pixelů úrovně 1 snímku MODIS v Olomouci

ÚROVEŇ 1 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
les	243	77	116	76	64
voda	0	0	0	0	10
zástavba	111	223	224	250	60
TTP	0	0	0	0	101
holá půda	64	118	78	92	183

Tabulka 8 a graf 3 ukazují počet pixelů vyklasifikovaných na úrovni 1 pro snímek MODIS na území Olomouce. Na základě vyklasifikovaných pixelů, lze říct, že snímek MODIS není ve svém vysokém rozlišení 500 m příliš vhodný, pro klasifikaci takto malých tříd. Kategorii **voda** a **TTP** nedokázal vůbec vyhodnotit. V porovnání s referenční vrstvou, je **nejvíce shodná** třída **les** u algoritmu **Naïve Bayes**. Ostatní třídy jsou nadhodnoceny.




Graf 3 Počet pixelů na území Olomouce pro úroveň 1 – snímek MODIS.

6.2.2 Klasifikace na úrovni 2 (land use)

Tabulka 9 Počet pixelů úrovně 2 snímku Sentinel-2 v Olomouci

ÚROVEŇ 2 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
nezařazeno	4	4	4	168	0
voda	12444	12960	11686	7240	15840
zpevněná cesta	18289	9139	45850	36296	29485
nezpevněná cesta	19082	6638	55573	67008	4476
zelené plochy	45517	39157	150376	49246	10548
průmysl	127200	136879	29762	25396	51692
staveniště	73264	57217	34692	55342	861
úhor	71874	67890	142488	187896	2907
souvislá zástavba	55906	56503	19244	17292	94184
obhospodařovaná půda	249147	312717	49981	39463	228786
TTP	34943	37950	136294	130067	242063
roztroušená zástavba	61907	62839	138085	87705	4571
mix	45186	45497	66437	84477	208511
jehličnaté lesy	133563	131966	56166	81266	51797
smíšené lesy	41135	33325	66202	159846	15896
listnaté lesy	42591	21371	29212	3344	70435

Z tabulky 9 a grafu 4, ukazující počet pixelů pro úroveň 2 snímku Sentinel-2 na území Olomouce, je možné konstatovat, že s referenční vrstvou se **nejvíce shoduje** algoritmus **Minimum Distance** ve třídě **jehličnaté lesy** a algoritmus **CART** ve třídě **obhospodařovaná půda**. Algoritmy **CART**, **Random Forest** a **Minimum Distance** **nedokázaly** 4 pixely **zařadit** do žádné z patnácti kategorií. Algoritmus **Naïve Bayes** nedokázal zařadit dokonce 168 pixelů. Proto byla pro tyto pixely vytvořena zvláštní kategorie s názvem **nezařazeno**. Algoritmus CART a Random Forest u třídy průmysl, vyklasifikovaly více jak dvojnásobný počet pixelů než ukazuje referenční vrstva.




Graf 4 Počet pixelů na území Olomouce pro úroveň 2 – snímek Sentinel-2.

Tabulka 10 Počet pixelů úrovně 2 snímku Landsat 8 v Olomouci

ÚROVEŇ 2 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
nezařazeno	0	0	0	188	0
voda	2286	2123	1686	648	1734
zpevněná cesta	4162	1179	11128	6480	2665
nezpevněná cesta	578	294	5858	6354	227
zelené plochy	6398	4009	21323	11047	1175
průmysl	7969	9640	1346	4239	5818
staveniště	7757	6926	5633	9177	95
úhor	7478	7331	12317	13605	318
souvislá zástavba	7353	4961	10398	5983	10644
obhospodařovaná půda	41510	56762	3390	7958	25616
TTP	3926	2785	21575	2552	27228
roztroušená zástavba	4712	2273	5081	4087	263
mix	5544	4467	1963	5963	23589
jehličnaté lesy	7860	7509	2906	10525	5741
smíšené lesy	4987	2831	1394	6045	1768
listnaté lesy	2091	1521	8613	19760	7730

Tabulka 10 a graf 5 ukazují počet pixelů na úrovni 2 u snímku Landsat 8 a na území města Olomouce. Algoritmus Naïve Bayes nedokázal zařadit do žádné z kategorií 188 pixelů. Na základě vyklasifikovaného počtu pixelů lze konstatovat, že **nejvíce podobný s referenční vrstvou** je v kategorii **voda** a **souvislá zástavba** algoritmus **Minimum Distance**. Kategorie staveniště, úhor a roztroušená zástavba veškeré algoritmy několikanásobně nadhodnotily. Naopak kategorii TTP algoritmy CART, Random Forest a Naïve Bayes několikanásobně podhodnotily.




Graf 5 Počet pixelů na území Olomouce pro úroveň 2 – snímek Landsat 8.

Tabulka 11 Počet pixelů úrovně 2 snímku MODIS v Olomouci

ÚROVEŇ 2 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
nezařazeno	0	0	0	0	0
voda	7	9	11	81	4
zpevněná cesta	0	0	0	0	1
nezpevněná cesta	0	0	0	0	0
zelené plochy	0	0	0	0	1
průmysl	112	127	144	5	21
staveniště	0	0	0	0	0
úhor	82	66	46	60	0
souvislá zástavba	0	0	0	0	29
obhospodařovaná půda	115	96	56	76	99
TTP	0	0	0	0	106
roztroušená zástavba	7	29	47	115	0
mix	0	0	0	0	95
jehličnaté lesy	67	46	59	30	26
smíšené lesy	0	0	0	0	5
listnaté lesy	11	28	38	34	14

Tabulka 11 a graf 6 ukazují počet pixelů na úrovni 2 snímku MODIS a na území Olomouce. U snímku MODIS, při svém rozlišení, **algoritmy nedokázaly zařadit žádný pixel do 8 kategorií**. U zbylých 7 vyklasifikovaných kategorií lze tvrdit, že **nejvíce shodná** s referenční vrstvou je třída **obhospodařovaná půda** u algoritmu **Random Forest**, třída **jehlíčnaté lesy** u algoritmu **Naïve Bayes** a poslední třída **listnaté lesy** vyklasifikovaná algoritmem **CART**.




Graf 6 Počet pixelů na území Olomouce pro úroveň 2 – snímek MODIS.

6.2.3 Klasifikace na úrovni 3 (biotopy)

Tabulka 12 Počet pixelů úrovně 3 snímku Sentinel-2 v Olomouci

ÚROVEŇ 3 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
<i>nezařazeno</i>	0	0	0	0	13
K1 + K3	750	769	209	2411	264
L1 + L2.2	1772	1447	466	1271	1409
L2.4	1430	1799	391	548	2053
L2.3 + L2.3B	2283	2456	1940	2654	712
L3.1	2657	3432	1553	3678	4862
L5.1 + L5.4	1395	1494	508	1125	414
L7.1 + L7.2	2530	2157	920	1421	2762
M1.1 + M1.3	161	77	534	268	7
M1.4 + M1.7	365	177	438	472	98
S1.2	82	48	3676	2	0
T1.1	1016	1049	305	391	1636
T1.4	1048	1147	718	1036	1463
T1.5 + T1.6 + T1.9	430	95	2835	11	274
T3.4D	108	50	413	988	4
T4.2	97	14	1372	93	1
V1F + V1G + V4B	893	806	739	648	1045

Tabulka 12 a graf 7 ukazují počet pixelů pro jednotlivé kategorie, úrovně 3 na snímku Sentinel-2 a na území Olomouce, a referenční vrstvu. Dle porovnání vyklasifikovaných pixelů pro každou třídu lze konstatovat, že s referenční vrstvou se **nejvíce shoduje** algoritmus **Random Forest** ve třídě **L1+L2.2** (Mokřadní olšiny + Údolní jasanovo-olšové luhy). Dále pak třída **L7.1+L7.2** (Suché acidofilní doubravy + Vlhké acidofilní doubravy) algoritmu **CART**.




Graf 7 Počet pixelů na území Olomouc pro úroveň 3 – snímek Sentinel-2.

Tabulka 13 Počet pixelů úrovně 3 snímku Landsat 8 v Olomouci

ÚROVEŇ 3 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
<i>nezařazeno</i>	0	0	0	4	2
K1 + K3	57	49	93	148	27
L1 + L2.2	129	141	144	135	113
L2.4	152	182	260	123	220
L2.3 + L2.3B	276	320	96	121	77
L3.1	166	165	254	384	528
L5.1 + L5.4	81	88	24	58	44
L7.1 + L7.2	325	350	176	75	290
M1.1 + M1.3	90	9	66	49	0
M1.4 + M1.7	15	9	252	292	6
S1.2	12	15	87	169	0
T1.1	110	77	55	84	176
T1.4	128	165	51	28	168
T1.5 + T1.6 + T1.9	30	7	109	37	28
T3.4D	4	10	50	22	0
T4.2	0	0	0	0	0
V1F + V1G + V4B	220	208	78	66	116

Tabulka 13 a graf 8 představuje počty pixelů na úrovni 3 snímku Landsat 8 na území Olomouce. Algoritmus Naïve Bayes nedokázal přiřadit k žádné definované třídě 4 pixely. S referenční vrstvou v kategorii **M1.4+M1.7** (Řiční rákosiny + Vegetace vysokých ostřic) a kategorii **T1.4** (Aluviální psárkové louky) se **nejvíce shoduje** algoritmus **Random Forest**. Malé území kategorie **T4.2** (Mezofilní bylinné lemy) **nedokázal vyklasifikovat žádný algoritmus**.




Graf 8 Počet pixelů na území Olomouc pro úroveň 3 – snímek Landsat 8.

Tabulka 14 Počet pixelů úrovně 3 snímku MODIS v Olomouci

ÚROVEŇ 3 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
nezařazeno	0	0	0	0	0
K1 + K3	0	0	0	0	0
L1 + L2.2	0	0	0	0	0
L2.4	0	0	0	3	2
L2.3 + L2.3B	5	3	5	1	0
L3.1	1	3	0	1	4
L5.1 + L5.4	0	0	0	0	0
L7.1 + L7.2	0	0	0	0	0
M1.1 + M1.3	0	0	0	0	0
M1.4 + M1.7	0	0	0	0	0
S1.2	0	0	0	0	0
T1.1	1	2	3	2	1
T1.4	1	0	0	1	1
T1.5 + T1.6 + T1.9	0	0	0	0	0
T3.4D	0	0	0	0	0
T4.2	0	0	0	0	0
V1F + V1G + V4B	0	0	0	0	0

Tabulka 14 a graf 9 představuje počet vyklasifikovaných pixelů úrovně 3 snímku MODIS na území Olomouce. Pro tento typ úrovně **nebylo vyklasifikováno téměř žádné množství pixelů**. Algoritmus **CART** a **Naïve Bayes** se **shoduje** u kategorie **T1.4** (Aluviální psárkové louky) s vyklasifikovaným jedním pixelem s referenční vrstvou.



Graf 9 Počet pixelů na území Olomouc pro úroveň 3 – snímek MODIS.

6.3 Výsledky klasifikací provedených na území Černovic


6.3.1 Klasifikace na úrovni 1 (land cover)

Tabulka 15 Počet pixelů úrovně 1 snímku Sentinel-2 v Černovicích

ÚROVEŇ 1 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
les	197677	196795	149179	111656	152229
voda	2879	1043	1920	760	1355
zástavba	9764	6673	24313	8284	11011
TTP	79317	78155	61278	92316	81392
holá půda	102942	109913	155889	179563	146592

Tabulka 15 a graf 10 znázorňují počet pixelů vyklasifikovaný na úrovni 1 pro snímek Sentinel-2 na území Černovic u Tábora. Na základě porovnání vyklasifikovaných tříd, lze tvrdit, že s referenční vrstvou je **nejvíce shodná** kategorie **les** a **holá půda** u algoritmu

Minimum Distance. Třída **TTP** je dle vyhodnoceného počtu pixelů **nejvíce shodná** s referenční vrstvou v kategorii **CART**.




Graf 10 Počet pixelů na území Černovic pro úroveň 1 – snímek Sentinel-2.

Tabulka 16 Počet pixelů úrovně 1 snímku Landsat 8 v Černovicích

ÚROVEŇ 1 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naive Bayes	referenční vrstva
les	23351	23686	19304	13299	16923
voda	470	133	136	79	149
zástavba	1107	616	3025	2029	1228
TTP	5482	5047	4920	7949	9026
holá půda	13196	14124	16221	20250	16280

Tabulka 16 a graf 11 ukazují počet pixelů vyklasifikovaných na úrovni 1, snímku Landsat 8 a na území obce Černovice. Na základě hodnocení počtu pixelů je z tabulek možné říct, že **nejvíce shodný** s referenční vrstvou v kategorii **voda** je algoritmus **Minimum Distance**. Co se kategorie **zástavba** týče, je možné říct, že s referenční vrstvou je **nejvíce podobný** algoritmus **CART**.




Graf 11 Počet pixelů na území Černovic pro úroveň 1 – snímek Landsat 8.

Tabulka 17 Počet pixelů úrovně 1 snímku MODIS v Černovicích

ÚROVEŇ 1 - MODIS	CART	Random Forest	Minimum Distance	Naive Bayes	referenční vrstva
les	26	30	15	48	68
voda	33	70	76	77	0
zástavba	0	0	0	0	6
TTP	50	45	42	2	31
holá půda	54	18	30	36	58

Tabulka 17 a graf 12 znázorňují počet pixelů na území Černovic u Tábora na úrovni 1 a snímku MODIS. **Žádný algoritmus nedokázal** vyklasifikovat třídu **zástavba**. Dle porovnání vyklasifikovaných pixelů, lze konstatovat, že **nejvíce shodný** s referenční vrstvou je v kategorii **holá půda** algoritmus **CART**, liší se pouze ve 4 pixelech. Ostatní třídy nadhodnoceny nebo podhodnoceny.




Graf 12 Počet pixelů na území Černovic pro úroveň 1 – snímek MODIS.

6.3.2 Klasifikace na úrovni 2 (land use)

Tabulka 18 Počet pixelů úrovně 2 snímku Sentinel-2 v Černovicích

ÚROVEŇ 2 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naive Bayes	referenční vrstva
nezařazeno	336	336	336	364	0
voda	3015	1101	4057	847	1352
TTP	49738	50659	48139	59229	79394
průmysl	20360	19644	7369	13989	1004
zpevněná cesta	3046	715	11115	2152	2172
nezpevněná cesta	4080	1657	10066	9257	1318
jehličnaté lesy	172010	186497	100606	95496	134180
smíšené lesy	39085	43276	27878	28879	9153
listnaté lesy	7792	3465	26990	66942	20402
zástavba	2458	106	31976	22760	5653
mix	19571	13828	27808	15556	19191
obhospodařovaná půda	45732	51599	28093	36198	72090
úhor	25126	19466	67916	40680	46440

Tabulka 18 a graf 13 představují počet vyklasifikovaných pixelů na úrovni 2 snímku Sentinel-2 v Černovicích u Tábora. Algoritmy CART, Random Forest a Minimum Distance nedokázaly zařadit 336 pixelů a algoritmus Naive Bayes nedokázal zařadit 364 pixelů. Dle počtu vyklasifikovaných pixelů lze konstatovat, že je **nejvíce shodná** s referenční vrstvou třída **zpevněná cesta** vyklasifikovaná algoritmem **Naive Bayes**. Kategorii zástavba algoritmus Random Forest příliš podhodnotil a algoritmy Minimum Distance a Naive Bayes nadhodnotily. Třída **mix** je s referenční vrstvou **nejvíce shodná** v algoritmu **CART**.




Graf 13 Počet pixelů na území Černovic pro úroveň 2 – snímek Sentinel-2.

Tabulka 19 Počet pixelů úrovně 2 snímku Landsat 8 v Černovicích

ÚROVEŇ 2 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naive Bayes	referenční vrstva
nezařazeno	0	0	0	20	0
voda	350	121	383	77	150
TTP	5438	6022	2713	2891	9023
průmysl	2132	1860	1251	5047	112
zpevněná cesta	208	39	2001	1000	83
nezpevněná cesta	32	34	1465	2093	57
jehličnaté lesy	18590	21774	11325	10247	14956
smíšené lesy	3352	2458	3223	3076	1021
listnaté lesy	725	734	2989	9590	2133
zástavba	321	14	6473	3820	646
mix	2982	1567	2407	2000	2137
obhospodařovaná půda	6130	6381	836	1406	8057
úhor	3307	2563	8501	2300	5192

Tabulka 19 a graf 14 znázorňují počet pixelů na úrovni 2, na území Černovic pro snímek Landsat 8. Algoritmus Naive Bayes nedokázal vyklasifikovat 20 pixelů. **Nejvíce** se v počtu pixelů s referenční vrstvou **shoduje** algoritmus **Naive Bayes** v kategorii **mix**.




Graf 14 Počet pixelů na území Černovic pro úroveň 2 – snímek Landsat 8.

Tabulka 20 Počet pixelů úrovně 2 snímku MODIS v Černovicích

ÚROVEŇ 2 - MODIS	CART	Random Forest	Minimum Distance	Naive Bayes	referenční vrstva
nezařazeno	0	0	0	0	0
voda	17	23	14	11	0
TTP	0	0	0	0	32
průmysl	0	0	0	0	0
zpevněná cesta	0	0	0	0	0
nezpevněná cesta	0	0	0	0	0
jehličnaté lesy	57	42	20	51	61
smíšené lesy	13	7	7	15	4
listnaté lesy	18	20	36	48	1
zástavba	0	0	0	0	1
mix	29	36	56	11	3
obhospodařovaná půda	21	27	22	19	34
úhor	0	0	0	0	19

Tabulka 20 a graf 15 obsahují počty pixelů úrovně 2 na území Černovic pro snímek MODIS. **Ani jeden** algoritmus **nedokázal vyklasifikovat 6 kategorií** – TTP, průmysl, zpevněná cesta, nezpevněná cesta, zástavba a úhor. **Nejvíce odpovídá** referenční vrstva kategorie **jehličnaté lesy**, která je vyklasifikovaná algoritmem **CART**. Třídou listnaté lesy a mix všechny algoritmy nadhodnotily.




Graf 15 Počet pixelů na území Černovic pro úroveň 2 – snímek MODIS.

6.3.3 Klasifikace na úrovni 3 (biotopy)

Tabulka 21 Počet pixelů úrovně 3 snímku Sentinel-2 v Černovicích

ÚROVEŇ 3 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naive Bayes	referenční vrstva
nezařazeno	20	20	20	20	0
K1	1210	862	829	312	10
K2.1 + K3	425	308	936	1969	43
L1 + L2.2 + L2B	1705	2177	1258	1341	3919
L5.4	231	223	615	314	581
L7.1	1398	1541	348	788	147
L9.2B	281	285	1557	1612	6
M1.5 + M1.7	397	289	328	46	9
R1.4 + R2.2 + R2.3	721	658	298	290	65
T1.1	2814	3081	1897	2195	4212
T1.3	396	0	1170	907	293
T2.3 + T2.3B + T5.5	237	485	548	695	3
T1.4 + T1.5 + T1.6 + T1.9	672	629	819	162	1230
V1F + V1G	413	362	297	269	402

Tabulka 21 a graf 16 ukazují počet pixelů úrovně 3 snímku Sentinel-2 na území Černovic u Tábora. Všechny algoritmy nedokázaly zařadit do žádné klasifikované kategorie 20 pixelů. S referenční vrstvou se **nejvíce shoduje** v kategorii **L5.4** (Acidofilní bučiny) klasifikátor **Minimum Distance** a v kategorii **V1F+V1G** (Makrofytní vegetace přirozeně eutrofních a mezotrofních stojatých vod) algoritmus **CART**. Třída L7.1 (Suché acidofilní doubravy) je ve všech algoritmy nadhodnocena.




Graf 16 Počet pixelů na území Černovice pro úroveň 3 – snímek Sentinel-2.

Tabulka 22 Počet pixelů úrovně 3 snímku Landsat 8 v Černovicích

ÚROVEŇ 3 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naive Bayes	referenční vrstva
nezařazeno	0	0	0	0	0
K1	34	69	39	41	1
K2.1 + K3	44	28	68	268	3
L1 + L2.2 + L2B	228	221	118	90	385
L5.4	75	26	174	193	60
L7.1	150	186	85	71	16
L9.2B	6	11	25	19	0
M1.5 + M1.7	52	17	39	45	0
R1.4 + R2.2 + R2.3	56	61	38	46	6
T1.1	279	313	215	155	455
T1.3	85	50	86	109	33
T2.3 + T2.3B + T5.5	6	3	129	3	0
T1.4 + T1.5 + T1.6 + T1.9	55	100	79	60	131
V1F + V1G	62	47	37	32	42

Tabulka 22 a graf 17 představuje počet pixelů jednotlivých kategorií úrovně 3 snímku Landsat 8 v Černovicích. U samotné referenční vrstvy se při rozlišení 30 m nedokázaly vyklasifikovat 3 malé kategorie. Na základě porovnání vyklasifikovaných pixelů lze říct, že **nejvíce shodný** s referenční vrstvou je algoritmus **CART** u kategorie **L5.4** (Acidofilní bučiny) a algoritmy **Random Forest** a **Minimum Distance** s kategorií **V1F+V1G** (Makrofytní vegetace přirozeně eutrofních a mezotrofních stojatých vod).

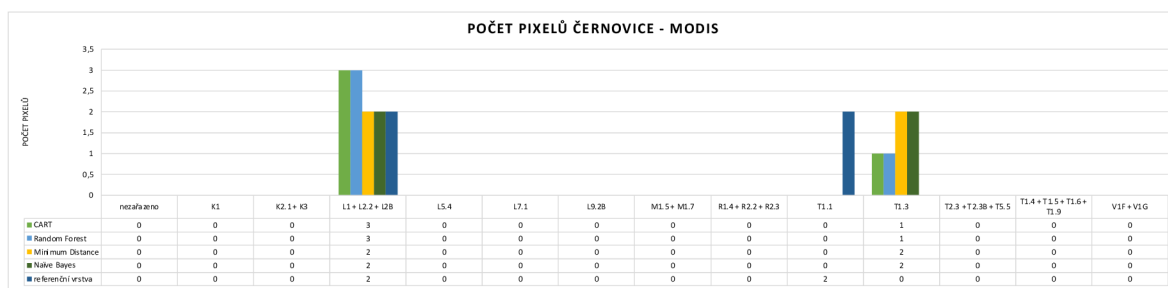


Graf 17 Počet pixelů na území Černovice pro úroveň 3 – snímek Landsat 8.

Tabulka 23 Počet pixelů úrovně 3 snímku MODIS v Černovicích

ÚROVEŇ 3 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
nezařazeno	0	0	0	0	0
K1	0	0	0	0	0
K2.1 + K3	0	0	0	0	0
L1 + L2.2 + L2B	3	3	2	2	2
L5.4	0	0	0	0	0
L7.1	0	0	0	0	0
L9.2B	0	0	0	0	0
M1.5 + M1.7	0	0	0	0	0
R1.4 + R2.2 + R2.3	0	0	0	0	0
T1.1	0	0	0	0	2
T1.3	1	1	2	2	0
T2.3 + T2.3B + T5.5	0	0	0	0	0
T1.4 + T1.5 + T1.6 + T1.9	0	0	0	0	0
V1F + V1G	0	0	0	0	0

Tabulka 23 a graf 18 ukazují počty pixelů úrovně 3 a snímku MODIS v Černovicích. Na této úrovni **není vyklasifikovaný skoro žádný počet pixelů**. S referenční vrstvou se shodují pouze algoritmy Minimum Distance a Naïve Bayes, které vyklasifikovaly stejný počet pixelů, tedy 2.



Graf 18 Počet pixelů na území Černovice pro úroveň 3 – snímek MODIS.

6.4 Vyhodnocení přesnosti klasifikace

Přesnost klasifikace je vyjádřena procentuální shodou správně vyklasifikovaných pixelů a procentuální shodou vyklasifikovaných kategorií s příslušnou referenční vrstvou.

6.4.1 Procentuální shoda na území Olomouce

Tabulka 24 Procentuální shoda pro úroveň 1

ÚROVEŇ 1	CART	Random Forest	Minimum Distance	Naïve Bayes
SENTINEL-2	56,49%	59,70%	51,49%	38,66%
LANDSAT 8	45,52%	50,53%	44,66%	31,40%
MODIS	34,69%	42,82%	40,91%	34,21%

Klasifikace na úrovni **land cover** ukazuje, že **nejvyšší výsledky** pro **shodu** v procentech na třech testovacích snímcích jsou pro algoritmus **Random Forest**, naopak **nejnižší** procentuální **výsledky** ukazuje **Naïve Bayes**. Jako jediný klasifikátor nepřekročil hranici 40 % u žádného snímku.

Tabulka 25 Procentuální shoda pro úroveň 2

ÚROVEŇ 2	CART	Random Forest	Minimum Distance	Naïve Bayes
SENTINEL-2	23,63%	27,17%	15,61%	11,89%
LANDSAT 8	22,14%	25,35%	10,82%	11,15%
MODIS	18,20%	17,71%	17,21%	8,48%

Klasifikace na úrovni **land use** znázorňuje, že **nejvyšší výsledky** pro **shodu** v procentech na testovacích snímcích **Sentinel-2** a **Landsat 8** jsou pro algoritmus **Random Forest** a na testovacím snímku **MODIS** pro algoritmus **CART**. Naopak **nejnižší** procentuální **výsledky** shod v procentech ukazuje pro snímky **Sentinel-2** a **MODIS** algoritmus **Naïve Bayes** a pro snímek **Landsat 8** algoritmus **Minimum Distance**.

Tabulka 26 Procentuální shoda pro úroveň 3

ÚROVEŇ 3	CART	Random Forest	Minimum Distance	Naïve Bayes
SENTINEL-2	32,46%	35,88%	15,64%	20,74%
LANDSAT 8	24,23%	28,47%	21,00%	22,01%
MODIS	0,025%	0,025%	0,00%	0,025%

Klasifikace na úrovni **biotopů** představuje, že **nejvyšší výsledek** v procentuální **shodě** testovacích snímcích jsou pro algoritmus **Random Forest** a **nejnižší** pro algoritmus **Minimum Distance**. Výsledky u testovacího snímku MODIS jsou pro algoritmus CART, Random Forest a Naïve Bayes shodné.

6.4.2 Procentuální shoda na území Černovic u Tábora

Tabulka 27 Procentuální shoda pro úroveň 1

ÚROVEŇ 1	CART	Random Forest	Minimum Distance	Naïve Bayes
SENTINEL-2	58,85%	59,47%	47,04%	40,04%
LANDSAT 8	54,36%	57,58%	48,43%	41,88%
MODIS	32,52%	15,95%	16,56%	20,25%

Klasifikace na úrovni **land cover** představuje, že výsledek **nejvyšší procentuální shody** testovacích snímků **Sentinel-2** a **Landsat 8** jsou pro algoritmus **Random Forest** a u testovacího snímku **MODIS** pro algoritmus **CART**. Na druhou stranu **nejnižší výsledky procentuální shody** testovacích snímků **Sentinel-2** a **Landsat 8** jsou u algoritmu **Naïve Bayes** a u snímku **MODIS** pro algoritmus **Random Forest**.

Tabulka 28 Procentuální shoda pro úroveň 2

ÚROVEŇ 2	CART	Random Forest	Minimum Distance	Naïve Bayes
SENTINEL-2	41,14%	42,24%	38,08%	34,10%
LANDSAT 8	41,29%	44,88%	35,94%	30,86%
MODIS	33,55%	26,45%	16,13%	16,13%

Klasifikace na úrovni **land use** ukazuje, že **nejvyšší výsledek shody** v procentech na testovacích snímcích **Sentinel-2** a **Landsat 8** je pro algoritmus **Random Forest** a u testovacího snímku **MODIS** pro algoritmus **CART**. **Nejnižší výsledek shody** v procentech na testovacích snímcích **Sentinel-2** a **Landsat 8** je pro algoritmus **Naïve Bayes**. U snímku **MODIS** je výsledek shody stejně nízký pro algoritmy **Minimum Distance** i **Naïve Bayes**.

Tabulka 29 Procentuální shoda pro úroveň 3

ÚROVEŇ 3	CART	Random Forest	Minimum Distance	Naïve Bayes
SENTINEL-2	42,09%	43,96%	28,21%	31,28%
LANDSAT 8	42,31%	42,67%	33,30%	26,77%
MODIS	0,05%	0,05%	0,05%	0,05%

Klasifikace na úrovni biotopy znázorňuje nejvyšší možný výsledek shody v procentech na třech testovacích snímcích. U snímků **Sentinel-2** a **Landsat 8** je **nejvyšší výsledek shody** v procentech pro algoritmus **Random Forest**. Naopak **nejnižší výsledek shody** vykazuje u snímku **Sentinel-2** algoritmus **Minimum Distance** a u snímku **Landsat 8** algoritmus **Naïve Bayes**. U snímku **MODIS** je výsledek u všech algoritmů stejný.

6.4.3 Procentuální shoda v kategoriích na území Olomouce

Tabulka 30 Procentuální shoda v kategoriích pro úroveň 1 a snímek Sentinel-2

ÚROVEŇ 1 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes
les	81,55%	70,01%	45,11%	41,71%
voda	46,09%	49,46%	33,19%	80,96%
zástavba	58,03%	50,18%	55,93%	48,50%
TTP	36,76%	48,19%	48,41%	39,56%
holá půda	10,17%	9,41%	13,71%	41,30%

Tabulka 30 ukazuje procentuální shodu v kategoriích na úrovni 1 snímku Sentinel-2. Výsledná klasifikace ukazuje, že kategorie les je nejvýhodnější s 81,55 % v algoritmu CART, voda s 80,96 % v algoritmu Naïve Bayes, zástavba s procentuální shodou 58,03 % v algoritmu CART, TTP s 48,41 % v algoritmu Minimum Distance a poslední kategorie holá půda v algoritmu Minimum Distance s 41,30 %. Algoritmus **CART** spolu s algoritmem **Naïve Bayes** vycházejí nejlépe v **2 třídách**. Algoritmus **Minimum Distance** je nejvýhodnější v **jedné kategorii** a algoritmus **Random Forest** nevyšel nejlépe ani v **jedné** kategorii.

Tabulka 31 Procentuální shoda v kategoriích pro úroveň 1 a snímek Landsat 8

ÚROVEŇ 1 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes
les	5,81%	4,13%	5,78%	2,05%
voda	27,35%	23,43%	17,09%	55,86%
zástavba	15,66%	17,30%	22,55%	38,68%
TTP	26,13%	31,23%	20,58%	40,98%
holá půda	34,58%	30,71%	33,34%	24,33%

Tabulka 31 ukazuje procentuální shodu v kategoriích na úrovni 1 snímku Landsat 8. Výsledná procentuální shoda ukazuje, že kategorie les je nejvýhodnější s 5,81 % v algoritmu CART, voda s 55,86 %, zástavba s procentuální shodou 38,68 % a TTP s 40,98 % v algoritmu Naïve Bayes a poslední kategorie holá půda v algoritmu CART s 34,58 %. Klasifikátor **Naïve Bayes** je vykazuje **nejlepší výsledky ve třech kategoriích** a **CART** ve **dvou kategoriích**. Naopak algoritmy **Random Forest** a **Minimum Distance** **nevykazují** nejvyšší procentuální shodu v **žádné kategorii**.

Tabulka 32 Procentuální shoda v kategoriích pro úroveň 1 a snímek MODIS

ÚROVEŇ 1 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes
les	0,354%	0,252%	0,352%	0,125%
voda	0,000%	0,000%	0,000%	0,000%
zástavba	0,223%	0,246%	0,321%	0,551%
TTP	0,000%	0,000%	0,000%	0,000%
holá půda	0,088%	0,078%	0,085%	0,062%

Tabulka 32 ukazuje procentuální shodu v kategoriích na úrovni 1 snímku MODIS. Výsledná procentuální shoda představuje, že kategorie les je nejvýhodnější s 0,35 % v algoritmu CART, kategorie voda spolu s TTP nebyly vůbec vyobrazeny, zástavba s procentuální shodou 0,55 % v algoritmu Naïve Bayes a poslední kategorie holá půda v algoritmu CART s 0,09 %. **V nejvíce** kategoriích ukazuje **nejvyšší** procentuální shody

algoritmus **CART** a v **jedné** kategorii algoritmus **Naïve Bayes**. Naopak algoritmy **Random Forest** a **Minimum Distance** **nevykazují** nejvyšší procentuální shodu v **žádné** kategorii.

Tabulka 33 Procentuální shoda v kategoriích pro úroveň 2 a snímek Sentinel-2

ÚROVEŇ 2 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes
voda	52,46%	50,37%	55,86%	90,17%
zpevněná cesta	14,80%	29,62%	5,90%	7,46%
nezpevněná cesta	2,29%	6,58%	0,79%	0,65%
zelené plochy	4,12%	4,79%	1,25%	3,81%
průmysl	6,98%	6,48%	29,82%	34,95%
staveniště	2,65%	3,39%	5,59%	3,50%
úhor	30,93%	32,74%	15,60%	11,83%
souvislá zástavba	1,15%	1,14%	3,35%	3,72%
obhospodařovaná půda	8,57%	6,83%	42,73%	54,11%
TTP	54,71%	50,37%	14,03%	14,70%
roztroušená zástavba	20,28%	19,98%	9,09%	14,31%
mix	12,05%	11,97%	8,20%	6,45%
jehličnaté lesy	13,63%	13,80%	32,41%	22,40%
smíšené lesy	14,40%	17,78%	8,95%	3,71%
listnaté lesy	0,32%	0,64%	0,47%	4,10%

Tabulka 33 ukazuje procentuální shodu v kategoriích na úrovni 2 snímku Sentinel-2. výsledné klasifikace představují, že:

- voda je nejvýhodnější v algoritmu Naïve Bayes s 90,17 %,
- zpevněná cesta je nejvýhodnější v algoritmu Random Forest s 29,62 %,
- nezpevněná cesta je nejvýhodnější v algoritmu Random Forest s 6,58 %,
- zelené plochy je nejvýhodnější v algoritmu Random Forest s 4,79 %,
- průmysl je nejvýhodnější v algoritmu Naïve Bayes s 34,95 %,
- staveniště je nejvýhodnější v algoritmu Minimum Distance s 5,59 %,
- úhor je nejvýhodnější v algoritmu Random Forest s 32,74 %,
- souvislá zástavba je nejvýhodnější v algoritmu Naïve Bayes se 3,72 %,
- obhospodařovaná půda je nejvýhodnější v algoritmu Naïve Bayes s 54,11 %,
- TTP je nejvýhodnější v algoritmu CART s 54,71 %,
- roztroušená zástavba je nejvýhodnější v algoritmu CART s 20,28 %,
- mix je nejvýhodnější v algoritmu CART s 12,05 %,
- jehličnaté lesy je nejvýhodnější v algoritmu Minimum Distance s 32,41 %,
- smíšené lesy je nejvýhodnější v algoritmu Random Forest 17,78 %,
- listnaté lesy je nejvýhodnější v algoritmu Naïve Bayes se 4,10 %.

Algoritmus **CART** vykazuje **nejvyšší** výsledky ve **třech kategoriích**, algoritmus **Random Forest** v **pěti kategoriích**, algoritmus **Minimum Distance** ve **dvou kategoriích**, a nakonec algoritmus **Naïve Bayes** také v **pěti kategoriích**.

Tabulka 34 Procentuální shoda v kategoriích pro úroveň 2 a snímek Landsat 8

ÚROVEŇ 2 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes
voda	6,65%	29,72%	37,43%	97,38%
zpevněná cesta	0,10%	12,89%	1,37%	2,35%
nezpevněná cesta	15,74%	1,36%	0,07%	0,06%
zelené plochy	7,49%	2,27%	0,43%	0,82%
průmysl	6,85%	4,97%	35,59%	11,30%
staveniště	32,37%	7,88%	9,69%	5,95%
úhor	6,67%	34,25%	20,39%	18,46%
souvislá zástavba	25,46%	10,06%	4,80%	8,34%
obhospodařovaná půda	0,56%	3,30%	55,22%	23,52%
TTP	0,38%	8,37%	1,08%	9,13%
roztroušená zástavba	0,00% *	0,66%	0,30%	0,37%
mix	0,00% *	0,00% *	0,00% *	0,00% *
jehličnaté lesy	0,00% *	0,00% *	0,00% *	0,00% *
smíšené lesy	0,00% *	0,00% *	0,00% *	0,00% *
listnaté lesy	19,13%	26,30%	4,64%	2,02%

Tabulka 34 znázorňuje vyklasifikovanou procentuální shodu v kategoriích na úrovni 2 snímku Landsat 8. Výsledky ukazují, že kategorie:

- voda je nejvýhodnější v algoritmu Naïve Bayes s 97,38 %,
- zpevněná cesta je nejvýhodnější v algoritmu Random Forest s 12,89 %,
- nezpevněná cesta je nejvýhodnější v algoritmu CART s 15,74 %,
- zelené plochy je nejvýhodnější v algoritmu CART s 7,49 %,
- průmysl je nejvýhodnější v algoritmu Minimum distance s 35,59 %,
- staveniště je nejvýhodnější v algoritmu CART s 32,37 %,
- úhor je nejvýhodnější v algoritmu Random Forest s 34,25 %,
- souvislá zástavba je nejvýhodnější v algoritmu CART s 25,64 %,
- obhospodařovaná půda je nejvýhodnější v algoritmu Minimum Distance s 55,22 %,
- TTP je nejvýhodnější v algoritmu Naïve Bayes s 9,13 %,
- roztroušená zástavba je nejvýhodnější v algoritmu Random Forest s 0,66 %,
- mix, jehličnaté lesy a smíšené lesy se v žádném bodu neshodují s referenční vrstvou,
- listnaté lesy je nejvýhodnější v algoritmu Random Forest s 26,30 %.

Ze všech testovaných algoritmů vykazuje algoritmus **CART nejvyšší** výsledky ve **čtyřech kategoriích**, algoritmus **Random Forest taktéž** ve 4 kategoriích, algoritmus **Minimum Distance** ve **dvou** kategoriích a algoritmus **Naïve Bayes** též ve **dvou** kategoriích.

Tabulka 35 Procentuální shoda v kategoriích pro úroveň 2 a snímek MODIS

ÚROVEŇ 2 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes
voda	71,43%	55,56%	45,45%	6,17%
zpevněná cesta	0,00%	0,00%	0,00%	0,00%
nezpevněná cesta	0,00%	0,00%	0,00%	0,00%
zelené plochy	0,00%	0,00%	0,00%	0,00%
průmysl	0,00% *	0,00% *	0,00% *	0,00% *
staveniště	0,00%	0,00%	0,00%	0,00%
úhor	0,00% *	0,00% *	0,00% *	0,00% *
souvislá zástavba	0,00%	0,00%	0,00%	0,00%
obhospodařovaná půda	10,43%	12,50%	21,43%	15,79%
TTP	0,00%	0,00%	0,00%	0,00%
roztroušená zástavba	71,43%	17,24%	10,64%	4,35%
mix	0,00%	0,00%	0,00%	0,00%
jehličnaté lesy	14,93%	21,74%	16,95%	33,33%
smíšené lesy	0,00%	0,00%	0,00%	0,00%
listnaté lesy	54,55%	21,43%	15,79%	17,65%

Tabulka 35 představuje vyklasifikovanou procentuální shodu v kategoriích na úrovni 2 snímku MODIS. Výsledky ukazují, že kategorie:

- voda je nejvýhodnější v algoritmu CART se 71,43 %,
- zpevněná cesta, nezpevněná cesta, zelené plochy, staveniště, souvislá zástavba, TTP, mix a smíšené lesy se v žádném bodu neshodují s referenční vrstvou
- průmysl a úhor je vyobrazeno mimo kontrolní plochy
- obhospodařovaná půda je nejvýhodnější v algoritmu Minimum Distance s 21,43 %,
- roztroušená zástavba je nejvýhodnější v algoritmu CART se 71,43 %,
- jehličnaté lesy je nejvýhodnější v algoritmu Naïve Bayes s 33,33 %,
- listnaté lesy je nejvýhodnější v algoritmu CART s 54,55 %.

Ze všech testovaných algoritmů vykazuje algoritmus **CART nejvyšší** výsledky ve **třech kategoriích**, algoritmus **Random Forest v žádné** z kategorií, algoritmus **Minimum Distance** a **Naïve Bayes** pouze v **jedné** kategorii.

Tabulka 36 Procentuální shoda v kategoriích pro úroveň 3 a snímek Sentinel-2

ÚROVEŇ 3 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes
K1 + K3	0,67%	0,65%	2,39%	0,21%
L1 + L2.2	2,09%	2,56%	7,94%	2,91%
L2.4	5,10%	4,06%	18,67%	13,32%
L2.3 + L2.3B	25,58%	23,78%	30,10%	22,00%
L3.1	18,89%	14,63%	32,32%	13,65%
L5.1 + L5.4	13,55%	12,65%	37,20%	16,80%
L7.1 + L7.2	3,52%	4,13%	9,67%	6,26%
M1.1 + M1.3	0,00% *	0,00% *	0,00% *	0,00% *
M1.4 + M1.7	0,27%	0,56%	0,23%	0,21%
S1.2	0,00% *	0,00% *	0,00% *	0,00% *
T1.1	2,85%	2,76%	9,51%	7,42%
T1.4	7,92%	7,24%	11,56%	8,01%
T1.5 + T1.6 + T1.9	0,00% *	0,00% *	0,00% *	0,00% *
T3.4D	24,07%	52,00%	6,30%	2,63%
T4.2	2,06%	14,29%	0,15%	2,15%
V1F + V1G + V4B	66,52%	73,70%	80,38%	91,67%

Tabulka 36 představuje vyklasifikovanou procentuální shodu v kategoriích na úrovni 3 snímku Sentinel-2. Výsledky ukazují, že kategorie:

- K1+K3 je nejvýhodnější v algoritmu Minimum Distance s 2,39 %,
- L1+L2.2 je nejvýhodnější v algoritmu Minimum Distance s 7,94 %,
- L2.4 je nejvýhodnější v algoritmu Minimum Distance s 18,67 %,
- L2.3+L2.3B je nejvýhodnější v algoritmu Minimum Distance s 30,10 %,
- L3.1 je nejvýhodnější v algoritmu Minimum Distance s 32,32 %,
- L5.1+L5.4 je nejvýhodnější v algoritmu Minimum Distance s 37,20 %,
- L7.1+L7.2 je nejvýhodnější v algoritmu Minimum Distance s 9,67 %,
- M1.1+M1.3 je vyobrazeno mimo kontrolní oblast,
- M1.4+M1.7 je nejvýhodnější v algoritmu Random Forest s 0,56 %,
- S1.2 je vyobrazeno mimo kontrolní oblast,
- T1.1 je nejvýhodnější v algoritmu Minimum Distance s 9,51 %,
- T1.4 je nejvýhodnější v algoritmu Minimum Distance s 11,56 %,
- T1.5+T1.6+T1.9 je vyobrazeno mimo kontrolní oblast,
- T3.4D je nejvýhodnější v algoritmu Random Forest s 52,00 %,
- T4.2 je nejvýhodnější v algoritmu Random Forest s 14,29 %,
- V1F+V1G+V4B je nejvýhodnější v algoritmu Naïve Bayes s 91,67 %.

Algoritmus **CART neukazuje nejvyšší** výsledky **ani u jedné** z testovacích kategorií, algoritmus **Random Forest** ve **třech kategoriích**, algoritmus **Minimum Distance** v **devíti** kategoriích a algoritmus **Naïve Bayes** jen v **jedné** kategorii.

Tabulka 37 Procentuální shoda v kategoriích pro úroveň 3 a snímek Landsat 8

ÚROVEŇ 3 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes
K1 + K3	17,54%	20,41%	10,75%	6,76%
L1 + L2.2	3,88%	3,55%	3,47%	3,70%
L2.4	17,11%	14,29%	10,00%	21,14%
L2.3 + L2.3B	22,46%	19,38%	64,58%	51,24%
L3.1	58,43%	58,79%	38,19%	25,26%
L5.1 + L5.4	1,23%	1,14%	4,17%	1,72%
L7.1 + L7.2	0,31%	0,29%	0,57%	1,33%
M1.1 + M1.3	5,56%	55,56%	7,58%	10,20%
M1.4 + M1.7	46,67%	77,78%	2,78%	2,40%
S1.2	16,67%	13,33%	2,30%	1,18%
T1.1	0,00% *	0,00% *	0,00% *	0,00% *
T1.4	2,34%	1,82%	5,88%	10,71%
T1.5 + T1.6 + T1.9	0,00% *	0,00% *	0,00% *	0,00% *
T3.4D	50,00%	20,00%	4,00%	9,09%
T4.2	0,00%	0,00%	0,00%	0,00%
V1F + V1G + V4B	7,27%	7,69%	20,51%	24,24%

Tabulka 37 představuje výsledky procentuálních shod za jednotlivé kategorie na úrovni 3 snímku Landsat 8.

- K1+K3 je nejvýhodnější v algoritmu Random Forest s 20,41 %,
- L1+L2.2 je nejvýhodnější v algoritmu CART s 3,88 %,
- L2.4 je nejvýhodnější v algoritmu Naïve Bayes s 21,14 %,
- L2.3+L2.3B je nejvýhodnější v algoritmu Minimum Distance s 64,58 %,
- L3.1 je nejvýhodnější v algoritmu Random Forest s 58,79 %,
- L5.1+L5.4 je nejvýhodnější v algoritmu Minimum Distance s 4,17 %,

- L7.1+L7.2 je nejvýhodnější v algoritmu Naïve Bayes s 1,33 %,
- M1.1+M1.3 je nejvýhodnější v algoritmu Random Forest s 55,56 %,
- M1.4+M1.7 je nejvýhodnější v algoritmu Random Forest s 77,78 %,
- S1.2 je nejvýhodnější v algoritmu CART s 16,67 %,
- T1.1 je vyobrazeno mimo kontrolní plochy,
- T1.4 je nejvýhodnější v algoritmu Naïve Bayes s 10,71 %,
- T1.5+T1.6+T1.9 je vyobrazeno mimo kontrolní plochy,
- T3.4D je nejvýhodnější v algoritmu CART s 50,00 %,
- T4.2 se neshoduje v žádném algoritmu,
- V1F+V1G+V4B je nejvýhodnější v algoritmu Naïve Bayes s 24,24 %.

Algoritmus **CART** ukazuje nejvyšší procentuální shodu u třech kategoriích, algoritmus **Random Forest** u čtyřech kategoriích, algoritmus **Minimum Distance** ve dvou kategoriích a algoritmus **Naïve Bayes** také ve čtyřech kategoriích.

Tabulka 38 Procentuální shoda v kategoriích pro úroveň 3 a snímek MODIS

ÚROVEŇ 3 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes
K1 + K3	0,00%	0,00%	0,00%	0,00%
L1 + L2.2	0,00%	0,00%	0,00%	0,00%
L2.4	0,00%	0,00%	0,00%	0,00% *
L2.3 + L2.3B	40,00%	66,67%	40,00%	20,00%
L3.1	0,00% *	0,00% *	0,00%	0,00% *
L5.1 + L5.4	0,00%	0,00%	0,00%	0,00%
L7.1 + L7.2	0,00%	0,00%	0,00%	0,00%
M1.1 + M1.3	0,00%	0,00%	0,00%	0,00%
M1.4 + M1.7	0,00%	0,00%	0,00%	0,00%
S1.2	0,00%	0,00%	0,00%	0,00%
T1.1	100,00%	50,00%	33,33%	50,00%
T1.4	0,00% *	0,00%	0,00%	0,00% *
T1.5 + T1.6 + T1.9	0,00%	0,00%	0,00%	0,00%
T3.4D	0,00%	0,00%	0,00%	0,00%
T4.2	0,00%	0,00%	0,00%	0,00%
V1F + V1G + V4B	0,00%	0,00%	0,00%	0,00%

Tabulka 38 představuje výsledky procentuálních shod za jednotlivé kategorie na úrovni 3 snímku MODIS. Výsledky ukazují, že kategorie:

- K1+K3 a L1+L2.2 se neshoduje v žádné kategorii,
- L2.4 je u algoritmu Naïve Bayes vyobrazeno mimo kontrolní plochu, u zbytku algoritmů se neshoduje v žádné kategorii,
- L2.3+L2.3B je nejvýhodnější v algoritmu Random Forest s 66,67 %,
- L3.1 je u algoritmu Naïve Bayes, Random Forest a CART vyobrazeno mimo kontrolní plochu, u algoritmu Minimum Distance se neshoduje v žádné kategorii,
- L5.1+L5.4 se neshoduje v žádné kategorii,
- L7.1+L7.2 se neshoduje v žádné kategorii,
- M1.1+M1.3 se neshoduje v žádné kategorii,
- M1.4+M1.7 se neshoduje v žádné kategorii,
- S1.2 se neshoduje v žádné kategorii,
- T1.1 je nejvýhodnější v algoritmu CART s 100,00 %,
- T1.4 je u algoritmu Naïve Bayes a CART vyobrazeno mimo kontrolní plochu, u zbytku algoritmů se neshoduje v žádné kategorii,

- T1.5+T1.6+T1.9 se neshoduje v žádné kategorii,
- T3.4D a T4.2 se neshoduje v žádné kategorii,
- V1F+V1G+V4B se neshoduje v žádné kategorii.

Algoritmus **CART** a **Random Forest** vykazují **nejvyšší** procentuální **shodu** v **jedné** kategorii, algoritmy **Minimum Distance** a **Naïve Bayes** **neukazují nejvyšší** procentuální **shodu** v žádné kategorii.

6.4.4 Procentuální shoda v kategoriích na území Černovic

Tabulka 39 Procentuální shoda v kategoriích pro úroveň 1 a snímek Sentinel-2

LEVEL 1 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes
les	52,94%	53,18%	70,15%	93,72%
voda	24,04%	66,35%	36,04%	91,05%
zástavba	21,51%	31,47%	8,64%	25,35%
TTP	37,84%	38,41%	48,98%	32,51%
holá půda	68,07%	63,75%	44,95%	39,02%

Tabulka 39 znázorňuje procentuální shodu v jednotlivých kategoriích na úrovni 1 snímku Sentinel-2. Výsledná procentuální shoda ukazuje, že kategorie les je nejvýhodnější s 93,72 % v algoritmu Naïve Bayes, voda s 91,05 % taktéž v algoritmu Naïve Bayes, zástavba s procentuální shodou 31,47 % v algoritmu Random Forest, TTP s 48,98 % v algoritmu Minimum Distance a poslední kategorie holá půda v algoritmu CART s 68,07 %. Algoritmus **CART**, **Random Forest** a **Minimum Distance** vychází **nejlépe** v **jedné** kategorii. Naopak algoritmus **Naïve Bayes** je **nejvýhodnější** ve **dvou** kategoriích.

Tabulka 40 Procentuální shoda v kategoriích pro úroveň 1 a snímek Landsat 8

ÚROVEŇ 1 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes
les	53,01%	52,26%	64,13%	93,08%
voda	14,47%	51,13%	50,00%	86,08%
zástavba	27,64%	49,68%	10,12%	15,08%
TTP	24,28%	26,37%	27,05%	16,74%
holá půda	76,89%	71,84%	62,55%	50,11%

Tabulka 40 znázorňuje procentuální shodu v jednotlivých kategoriích na úrovni 1 snímku Landsat 8. Výsledná shoda procent znázorňuje, že kategorie les je nejvýhodnější s 93,08 % v algoritmu Naïve Bayes, voda s 86,08 % taktéž v algoritmu Naïve Bayes, zástavba s procentuální shodou 49,68 % v algoritmu Random Forest, TTP s 27,05 % v algoritmu Minimum Distance a poslední kategorie holá půda v algoritmu CART s 76,89 %. Algoritmus **CART**, **Random Forest** a **Minimum Distance** mají **nejvyšší výsledek** v **jedné** kategorii a algoritmus **Naïve Bayes** ve **dvou** kategoriích.

Tabulka 41 Procentuální shoda v kategoriích pro úroveň 1 a snímek MODIS

ÚROVEŇ 1 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes
les	11,54%	10,00%	20,00%	6,25%
voda	45,45%	21,43%	19,74%	19,48%
zástavba	0,00%	0,00%	0,00%	0,00%
TTP	0,00% *	0,00% *	0,00% *	0,00% *
holá půda	12,96%	38,89%	23,33%	19,44%

Tabulka 41 představuje procentuální shodu v jednotlivých kategoriích na úrovni 1 snímku MODIS. Výsledná shoda procent znázorňuje, že kategorie les je nejvýhodnější s 20,00 % v algoritmu Minimum Distance, voda s 45,45 % v algoritmu CART, zástavba nebyla vyobrazena, TTP bylo vyklasifikováno mimo kontrolní území a poslední kategorie holá půda v algoritmu Random Forest s 38,89 %. Algoritmus **CART**, **Random Forest** a **Minimum Distance** vykazují **nejlepší výsledky v jedné** kategorii a algoritmus **Naïve Bayes** v **žádné** kategorii.

Tabulka 42 Procentuální shoda v kategoriích pro úroveň 2 a snímek Sentinel-2

ÚROVEŇ 2 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes
voda	24,31%	66,58%	18,07%	86,54%
TTP	42,07%	41,30%	43,46%	35,33%
průmysl	11,70%	12,13%	32,34%	17,03%
zpevněná cesta	4,30%	18,32%	1,18%	6,09%
nezpevněná cesta	1,96%	4,83%	0,79%	0,86%
jehličnaté lesy	46,47%	42,86%	79,46%	83,71%
smíšené lesy	14,83%	13,39%	20,79%	20,07%
listnaté lesy	25,14%	56,54%	7,26%	2,93%
zástavba	11,35%	100,00%	0,87%	1,23%
mix	0,69%	0,98%	0,49%	0,87%
obhospodařovaná půda	14,67%	13,00%	23,88%	18,53%
úhor	13,44%	17,34%	4,97%	8,30%

Tabulka 42 představuje procentuální shodu v jednotlivých kategoriích na úrovni 2 snímku Sentinel-2. Výsledná shoda procent znázorňuje, že kategorie:

- voda je nejvýhodnější v algoritmu Naïve Bayes v 86,54 %,
- TTP je nejvýhodnější v algoritmu Minimum Distance s 43,46 %,
- průmysl je nejvýhodnější v algoritmu Minimum Distance s 32,34 %,
- zpevněná cesta je nejvýhodnější v algoritmu Random Forest s 18,32 %,
- nezpevněná cesta je nejvýhodnější v algoritmu Random Forest s 4,83 %,
- jehličnaté lesy je nejvýhodnější v algoritmu Naïve Bayes s 83,71 %,
- smíšené lesy je nejvýhodnější v algoritmu Minimum Distance s 20,79 %,
- listnaté lesy je nejvýhodnější v algoritmu Random Forest s 56,54 %,
- zástavba je nejvýhodnější v algoritmu Random Forest se 100,00 %,
- mix je nejvýhodnější v algoritmu Random Forest s 0,98 %,
- obhospodařovaná půda je nejvýhodnější v algoritmu Minimum Distance s 23,88 %,
- úhor je nejvýhodnější v algoritmu Random Forest s 17,34 %.

Algoritmus **CART** neukazuje **nejlepší** výsledky v **žádné** kategorii, algoritmus **Random Forest** v **šesti** kategoriích, algoritmus **Minimum Distance** ve **čtyřech** kategoriích a poslední algoritmus **Naïve Bayes** ve **dvou** kategoriích.

Tabulka 43 Procentuální shoda v kategoriích pro úroveň 2 a snímek Landsat 8

ÚROVEŇ 2 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes
voda	20,00%	57,85%	18,28%	90,91%
TTP	23,83%	21,52%	47,77%	44,83%
průmysl	37,85%	43,39%	64,51%	15,99%
zpevněná cesta	3,85%	20,51%	0,40%	0,80%
nezpevněná cesta	25,00%	23,53%	0,55%	0,38%
jehličnaté lesy	48,59%	41,48%	79,75%	88,14%
smíšené lesy	18,08%	24,65%	18,80%	19,70%
listnaté lesy	52,97%	52,32%	12,85%	4,00%
zástavba	0,31%	7,14%	0,02%	0,03%
mix	9,12%	17,36%	11,30%	13,60%
obhospodařovaná půda	2,61%	2,51%	19,14%	11,38%
úhor	14,45%	18,65%	5,62%	20,78%

Tabulka 43 představuje výsledky procentuální shody v jednotlivých kategoriích na úrovni 2 snímku Landsat 8. Výsledná shoda procent znázorňuje, že kategorie:

- voda je nejvýhodnější v algoritmu Naïve Bayes s 90,91 %,
- TTP je nejvýhodnější v algoritmu Minimum Distance s 47,77 %,
- průmysl je nejvýhodnější v algoritmu Minimum Distance s 64,51 %,
- zpevněná cesta je nejvýhodnější v algoritmu Random Forest s 20,51 %,
- nezpevněná cesta je nejvýhodnější v algoritmu CART s 25,00 %,
- jehličnaté lesy je nejvýhodnější v algoritmu Naïve Bayes s 88,14 %,
- smíšené lesy je nejvýhodnější v algoritmu Random Forest s 24,65 %,
- listnaté lesy je nejvýhodnější v algoritmu CART s 52,97 %,
- zástavba je nejvýhodnější v algoritmu Random Forest s 7,14 %,
- mix je nejvýhodnější v algoritmu Random Forest s 17,36 %,
- obhospodařovaná půda je nejvýhodnější v algoritmu Minimum Distance s 19,14 %,
- úhor je nejvýhodnější v algoritmu Naïve Bayes s 20,78 %.

Algoritmus **CART** ukazuje **nejvyšší** procentuální **shody** ve **dvou** kategoriích, algoritmus **Random Forest** ve **čtyřech** kategoriích, **Minimum Distance** a **Naïve Bayes** ve **třech** kategoriích.

Tabulka 44 Procentuální shoda v kategoriích pro úroveň 2 a snímek MODIS

ÚROVEŇ 2 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes
voda	11,76%	8,70%	14,29%	18,18%
TTP	0,00% *	0,00% *	0,00% *	0,00% *
průmysl	0,00% *	0,00% *	0,00% *	0,00% *
zpevněná cesta	0,00% *	0,00% *	0,00% *	0,00% *
nezpevněná cesta	0,00% *	0,00% *	0,00% *	0,00% *
jehličnaté lesy	24,56%	33,33%	70,00%	27,45%
smíšené lesy	7,69%	14,29%	14,29%	6,67%
listnaté lesy	100,00%	90,00%	50,00%	37,50%
zástavba	0,00% *	0,00% *	0,00% *	0,00% *
mix	10,34%	8,33%	5,36%	27,27%
obhospodařovaná půda	14,29%	11,11%	13,64%	15,79%
úhor	0,00% *	0,00% *	0,00% *	0,00% *

Tabulka 44 představuje výsledky procentuální shody v jednotlivých kategoriích na úrovni 2 snímku MODIS. Výsledná procentuální shoda znázorňuje, že kategorie:

- voda je nejvýhodnější v algoritmu Naïve Bayes s 18,18 %,

- TTP je vyobrazeno mimo zájmovou oblast,
- průmysl je vyobrazeno mimo zájmovou oblast,
- zpevněná cesta je vyobrazeno mimo zájmovou oblast,
- nezpevněná cesta je vyobrazeno mimo zájmovou oblast,
- jehličnaté lesy je nejméně výhodný v algoritmu Minimum Distance se 70,00 %,
- smíšené lesy je nejméně výhodný v algoritmech Random Forest a Minimum Distance se 14,29 %,
- listnaté lesy je nejméně výhodný v algoritmu CART se 100,00 %,
- zástavba je vyobrazeno mimo zájmovou oblast,
- mix je nejméně výhodný v algoritmu Naïve Bayes s 27,27 %,
- obhospodařovaná půda je nejméně výhodný v algoritmu Naïve Bayes s 15,79 %,
- úhor je vyobrazen mimo zájmovou oblast.

Algoritmus **CART** a **Random Forest** ukazují **nejvyšší** procentuální **shodu** v **jedné** kategorii, algoritmus **Minimum Distance** ve **dvou** kategoriích a algoritmus **Naïve Bayes** ve **třech** kategoriích.

Tabulka 45 Procentuální shoda v kategoriích pro úroveň 3 a snímek Sentinel-2

ÚROVEŇ 3 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes
K1	3,72%	5,22%	5,43%	14,42%
K2.1 + K3	28,94%	39,94%	13,14%	6,25%
L1 + L2.2 + L2B	32,20%	25,22%	43,64%	40,94%
L5.4	0,43%	0,45%	0,16%	0,32%
L7.1	12,80%	11,62%	51,44%	22,72%
L9.2B	51,60%	50,88%	9,31%	9,00%
M1.5 + M1.7	0,00% *	0,00% *	0,00% *	0,00% *
R1.4 + R2.2 + R2.3	0,28%	0,30%	0,67%	0,69%
T1.1	34,72%	31,71%	51,50%	44,51%
T1.3	0,00% *	0,00%	0,00% *	0,00% *
T2.3 + T2.3B + T5.5	4,64%	2,27%	2,01%	1,58%
T1.4 + T1.5 + T1.6 + T1.9	1,49%	1,59%	1,22%	6,17%
V1F + V1G	64,41%	73,48%	89,56%	98,88%

Tabulka 45 znázorňuje procentuální shodu v kategoriích na úrovni 3 snímku Sentinel-2. Výsledná procentuální shoda ukazuje, že kategorie:

- K1 je nejméně výhodný v algoritmu Naïve Bayes s 14,42 %,
- K2.1 + K3 je nejméně výhodný v algoritmu Random Forest s 39,94 %,
- L1 + L2.2 + L2B je nejméně výhodný v algoritmu Minimum Distance s 43,64 %,
- L5.4 je nejméně výhodný v algoritmu Random Forest s 0,45 %,
- L7.1 je nejméně výhodný v algoritmu Minimum Distance s 51,44 %,
- L9.2B je nejméně výhodný v algoritmu CART s 51,60 %,
- M1.5 + M1.7 a T1.3 je vyobrazeno mimo zájmovou oblast,
- R1.4 + R2.2 + R2.3 je nejméně výhodný v algoritmu Naïve Bayes s 0,69 %,
- T1.1 je nejméně výhodný v algoritmu Minimum Distance s 51,50 %,
- T2.3 + T2.3B + T5.5 je nejméně výhodný v algoritmu CART se 4,64 %,
- T1.4 + T1.5 + T1.6 + T1.9 je nejméně výhodný v algoritmu Naïve Bayes s 6,17 %,
- V1F + V1G je nejméně výhodný v algoritmu Naïve Bayes s 98,88 %.

Algoritmus **CART** společně s algoritmem **Random Forest** **vykazují nejvyšší** procentuální **shodu** ve **dvou** kategoriích, algoritmus **Minimum Distance** ve **třech** kategoriích a pro algoritmus **Naïve Bayes** pro **čtyři** kategorie.

Tabulka 46 Procentuální shoda v kategoriích pro úroveň 3 a snímek Landsat 8

ÚROVEŇ 3 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes
K1	2,94%	1,45%	2,56%	2,44%
K2.1 + K3	9,09%	14,29%	5,88%	1,49%
L1 + L2.2 + L2B	19,30%	19,91%	37,29%	48,89%
L5.4	25,33%	73,08%	10,92%	9,84%
L7.1	6,00%	4,84%	10,59%	12,68%
L9.2B	0,00% *	0,00% *	0,00% *	0,00% *
M1.5 + M1.7	0,00% *	0,00% *	0,00% *	0,00% *
R1.4 + R2.2 + R2.3	0,00% *	0,00% *	0,00% *	0,00% *
T1.1	24,73%	22,04%	32,09%	44,52%
T1.3	27,06%	46,00%	26,74%	21,10%
T2.3 + T2.3B + T5.5	0,00% *	0,00% *	0,00% *	0,00% *
T1.4 + T1.5 + T1.6 + T1.9	3,64%	2,00%	2,53%	3,33%
V1F + V1G	46,77%	61,70%	78,38%	90,63%

Tabulka 46 znázorňuje procentuální shodu v kategoriích na úrovni 3 snímku Landsat 8. Výsledná procentuální shoda ukazuje, že kategorie:

- K1 je nejvýhodnější v algoritmu CART s 2,94 %,
- K2.1+K3 je nejvýhodnější v algoritmu Random Forest s 14,29 %,
- L1+L2.2+L2B je nejvýhodnější v algoritmu Naïve Bayes s 48,89 %,
- L5.4 je nejvýhodnější v algoritmu Random Forest s 73,08 %,
- L7.1 je nejvýhodnější v algoritmu Naïve Bayes s 12,68 %,
- L9.2B, M1.5+M1.7, R1.4+R2.2+R2.3, T2.3+T2.3B+T5.5 je vyobrazeno mimo kontrolní plochy,
- T1.1 je nejvýhodnější v algoritmu Naïve Bayes s 44,52 %,
- T1.3 je nejvýhodnější v algoritmu Random Forest s 46,00 %,
- T1.4+T1.5+T1.6+T1.9 je nejvýhodnější v algoritmu CART s 3,64 %,
- V1F+V1G je nejvýhodnější v algoritmu Naïve Bayes s 90,63 %.

Algoritmus **CART** vykazuje **dvě** kategorie s **nejvyšší** procentuální **shodou**, algoritmus **Random Forest** vykazuje nejvyšší procentuální shodu ve **třech** kategoriích, algoritmus **Minimum Distance** v **žádné** kategorii a algoritmus **Naïve Bayes** ve **čtyřech** kategoriích.

Tabulka 47 Procentuální shoda v kategoriích pro úroveň 3 a snímek MODIS

ÚROVEŇ 3 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes
K1	0,00%	0,00%	0,00%	0,00%
K2.1 + K3	0,00%	0,00%	0,00%	0,00%
L1 + L2.2 + L2B	66,67%	66,67%	100,00%	100,00%
L5.4	0,00%	0,00%	0,00%	0,00%
L7.1	0,00%	0,00%	0,00%	0,00%
L9.2B	0,00%	0,00%	0,00%	0,00%
M1.5 + M1.7	0,00%	0,00%	0,00%	0,00%
R1.4 + R2.2 + R2.3	0,00%	0,00%	0,00%	0,00%
T1.1	0,00%	0,00%	0,00%	0,00%
T1.3	100,00%	100,00%	50,00%	50,00%
T2.3 + T2.3B + T5.5	0,00%	0,00%	0,00%	0,00%
T1.4 + T1.5 + T1.6 + T1.9	0,00%	0,00%	0,00%	0,00%
V1F + V1G	0,00%	0,00%	0,00%	0,00%

Tabulka 47 ukazuje procentuální shodu v jednotlivých kategoriích úrovně 3 snímku MODIS. Výsledky procentuálních shod ukazují, že kategorie K1, K2.1+K3, L5.4, L7.1, L9.2B, M1.5+M1.7, R1.4+R2.2+R2.3, T1.1, T2.3+T2.3B+T5.5, T1.4+T1.5+T1.6+T1.9,

V1F+V1G se neshodují v žádném bodě. Kategorie L1+L2.2+L2B nejvýhodnější v algoritmu Minimum Distance a Naïve Bayes se 100,00 % a kategorie T1.3 nejvýhodnější v algoritmu CART a Random Forest se 100,00 %. **Všechny algoritmy** vykazují **nejvyšší** procentuální **shodu** v **jedné** kategorii.

Procentuální shoda klasifikace **všech úrovní** na území **Olomouce** představuje **nejvyšší** výsledky pro algoritmus **Random Forest** a **nejnižší** pro algoritmus **Naïve Bayes** a **Minimum Distance**. Algoritmus **Random Forest**, na **všech úrovních**, vykazuje **nejlepší výsledky** i na území **Černovic u Tábora**. Algoritmus **Naïve Bayes** opět vykazuje **nejnižší** procentuální **shody**.

Opačný výsledek ukazují **procentuální shody** v jednotlivých kategoriích. Na **úrovni 1** v **Olomouci** vychází algoritmus **Naïve Bayes** s algoritmem **CART** **nejlépe**. Pro **úroveň 2** **nejvyšší** výsledky ukazují algoritmy **CART** a **Random Forest**. Na **úrovni 3** nejvyšší úrovně jednoznačně vykazuje algoritmus **Minimum Distance**.

Území **Černovic** je na **úrovni 1** **nejlépe** vyklasifikováno algoritmem **Naïve Bayes**. Klasifikace na **úrovni 2** s nejvyššími výsledky vyklasifikoval algoritmus **Random Forest**. A poslední **úroveň 3** vykazuje **nejvyšší procento** shod v kategoriích algoritmus **Naïve Bayes**.

Obecně lze tedy říct, že algoritmus Naïve Bayes je vhodný pouze k porovnání kategorií, nikoliv ke srovnání výsledné klasifikace testovaných snímků. **Celkově nejlepší výsledky** vyklasifikoval algoritmus **Random Forest**.

6.5 Shrnutí poznatků z provedených klasifikací

Série klasifikací byla provedena na 3 typech snímků – Sentinel-2, Landsat 8 a MODIS. Snímky ze Sentinel-2 a MODIS byly datovány ke stejnému dni, tj. 30.7.2022-30.8.2022. U Lansatu byl z důvodu překryvu dvou snímků vybrán nejbližší možný datum a to je 1.8.2022-1.9.2022. Snímek Sentinel-2 byl v rozlišení 10 m, snímek Landsat 8 30 m a rozlišení snímku MODIS činilo 500 m (na úrovni biotopy 250 m).

Klasifikace byla provedena na dvou územích. Prvním územím byla obec Černovice u Tábora, která je zástupce venkovské krajiny a druhým územím bylo statutární město Olomouc jako zástupce městské krajiny. Testovány byly 3 úrovně krajinných jednotek. První úroveň byl land cover, který měl pro obě testovací území stejných **5 kategorií** – les, voda, zástavba, TTP a holá půda. Další úroveň byl land use, který už měl odlišný počet kategorií pro zájmová území. Na území Černovic byl klasifikováno **12 kategorií** – voda, TTP, průmysl, zpevněná cesta, nezpevněná cesta, jehličnaté lesy, smíšené lesy, listnaté lesy, zástavba, mix travní a keřové vegetace, obhospodařovaná půda a úhor. Kdežto na území Olomouce bylo definováno **15 kategorií** – voda, zpevněná cesta, nezpevněná cesta, zelené plochy (hřiště), průmysl, úhor, souvislá zástavba, obhospodařovaná půda, TTP, roztroušená zástavba, mix, jehličnaté lesy, smíšené lesy a listnaté lesy. Poslední úroveň byly biotopy. Stejně jako u úrovně 2 měla každá zájmová oblast jiný počet zkoumaných kategorií. Některé biotopy byly kvůli svému malému rozměru spojeny dohromady s jinými. Černovice u tábora byly testovány na **13 kategoriích biotopů** – Mokřadní vrbiny (K1), Vrbové křoviny hlinitých a písčitých náplavů + Vysoké mezofilní a xerofilní křoviny (K2.1 + K3), Mokřadní olšiny + Údolní jasanovo-olšové luhy (L1 + L2.2 + L2B), Acidofilní bučiny (L5.4), Suché acidofilní doubravy (L7.1), Rašelinné a podmáčené smrčiny (L9.2B), Pobřežní vegetace potoků + Vegetace vysokých ostríc (M1.5 + M1.7), Lesní prameniště bez tvorby pěnvců + Nevápnitá mechová slatiniště + Přechodová rašeliniště (R1.4 + R2.2 + R2.3),

Mezofilní ovsíkové louky (T1.1), Poháňkové pastviny (T1.3), Aluviální psárkové louky + Vlhké pcháčové louky + Střídavě vlhké bezkolencové louky (T2.3 + T2.3B + T5.5), Podhorské až horské smilkové trávníky + Podhorské acidofilní trávníky (T1.4 + T1.5 + T1.6 + T1.9), Makrofytní vegetace přirozeně eutrofních a mezotrofních stojatých vod (V1F + V1G). Na Olomouci bylo testováno **16 kategorií biotopů** – Mokřadní vrbiny + Vysoké mezofilní a xerofilní křoviny (K1 + K3), Mokřadní olšiny + Údolní jasanovo-olšové luhy (L1 + L2.2), Tvrdé luhy nížinných řek (L2.4), Měkké luhy nížinných řek (L2.3 + L2.3B), Hercynské dubohabřiny (L3.1), Květnaté bučiny + Acidofilní bučiny (L5.1 + L5.4), Suché acidofilní doubravy + Vlhké acidofilní doubravy (L7.1 + L7.2), Rákosiny eutrofních stojatých vod + Eutrofní vegetace bahnitých substrátů (M1.1 + M1.3), Říční rákosiny + Vegetace vysokých ostřic (M1.4 + M1.7), Štěrbínová vegetace silikátových skal a drolin (S1.2), Mezofilní ovsíkové louky (T1.1), Aluviální psárkové louky (T1.4), Vlhké pcháčové louky + Vlhká tužebníková lada + Střídavě vlhké bezkolencové louky (T1.5 + T1.6 + T1.9), Širokolisté suché trávníky (T3.4D), Mezofilní bylinné lemy (T4.2), Makrofytní vegetace přirozeně eutrofních a mezotrofních stojatých vod + Makrofytní vegetace vodních toků (V1F + V1G + V4B). Kategorie biotopů byly převzaty z Katalogu biotopů ČR od Milana Chytrého z roku 2010. Referenční vrstva pro úroveň 1 a 2 byla vytvořena spojením Dat50, dat z OSM a CLC2018.

Série klasifikací byla prováděna přes řízenou klasifikaci. První krok vedl k vytvoření trénovacích množin. Pro každou kategorii byl definován +- stejný počet trénovacích ploch. Trénovací data byla definována ručně jako polygony pomocí geometrických nástrojů v mapovém poli v prostředí Google Earth Engine. Následně byl spuštěn skript. Vyklasifikovaný obraz byl vyexportován z GEE v řádném rozlišení, v souřadnicovém systému WGS 84 / UTM zone 33N a ve formátu GeoTIFF. Tyto snímky byly dále importovány do programu ArcGIS Pro. První kroky v ArcGIS Pro vedly ke zjištění počtu pixelů. Tento krok byl uskutečněn pomocí zadaných parametrů v nástroji *INT*. Následoval výpočet procentuální shody snímků s referenční vrstvou. Výpočet procentuální shody umožnil nástroj *Raster Calculator*, do kterého byl zadán příkaz k vyhodnocení 1 a 0. 1 znázorňovaly počet shodných pixelů a 0 pixely, kde se pixely rozcházely. Výsledná procentuální shoda na třech testovacích snímcích byla vypočtena – počet shodných pixelů/celkový počet pixelů.

Klasifikace z GEE byly v programu ArcGIS Pro reklasifikovány přes nástroj *Reclassify* a pomocí nástroje *Raster Calculator* byla vyčíslena shoda v počtech pixelů v jednotlivých kategoriích. Vrstva perzistence obsahovala hodnoty – 1111, 2222, 3333, atd. ukazující v kolika bodech se všechny algoritmy v kategoriích shodují. Následně byla v programu MS Excel vypočtena procentuální shoda.

Obecně lze říct, že počty pixelů, v porovnání s referenční vrstvou, nejvíce sedí v úrovni 1. Žádný algoritmus se extrémně nevychyluje. V procentuální shodě kategorií je nutno rozlišovat 0,00 % a 0,00 %*. Označení s * znázorňuje vyklasifikování mimo kontrolní území, kdežto 0,00 % znamená, že hodnota byla dělena 0, tedy algoritmy se neshodly v žádné kategorii.

Výsledné počty pixelů, procentuální shody klasifikace testovaných snímků v porovnání s referenční vrstvou a procentuální shody za jednotlivé kategorie jsou v práci vyobrazeny formou tabulkových výstupů. Je nutné zdůraznit, že výsledky nevyšly podle původních očekávání. Žádný ze snímků nepřesahuje 60% hranici shodnosti s kontrolní referenční vrstvou. Může to být dáno nevhodně zvoleným rozmístěním trénovacích množin či malým počtem trénovacích množin. Z výsledků v oblasti města **Olomouce** lze vyčíst, že procentuální **shoda klasifikace** na všech třech krajinných jednotkách znázorňuje **nejvyšší** procentuální **výsledky** algoritmus **Random Forest** a **nejnižší** hodnoty algoritmus **Naive**

Bayes společně s algoritmem **Minimum Distance**. **Procentuální shoda** pro jednotlivé **kategorie** pro úroveň **land cover** je **nejlépe** vyklasifikována algoritmem **CART** a **Naïve Bayes**. Úroveň **land use** je s nejvíce procenty v jednotlivých kategoriích vykázána algoritmy **CART** a **Random Forest**. A procentuální shoda kategorií na poslední **úrovni biotopů** nejlépe vychází pod algoritmem **Minimum Distance**. Procentuální **shodu klasifikace** na třech úrovních na území **Černovic u Tábora** vykazuje algoritmus **Random Forest**. A algoritmus **Naïve Bayes** opět zastupuje **nejnižší** procentuální shodu klasifikace. Procentuálně **shodné kategorie** první úrovně **land cover** nejlépe vyklasifikoval algoritmus **Naïve Bayes**. Kategoriální shodu na úrovni **land use** s nejvyššími procentuálními hodnotami ukazuje algoritmus **Random Forest**. Poslední **úroveň biotopy** vykazuje nejvyšší procentuální shody u algoritmu **Naïve Bayes**.

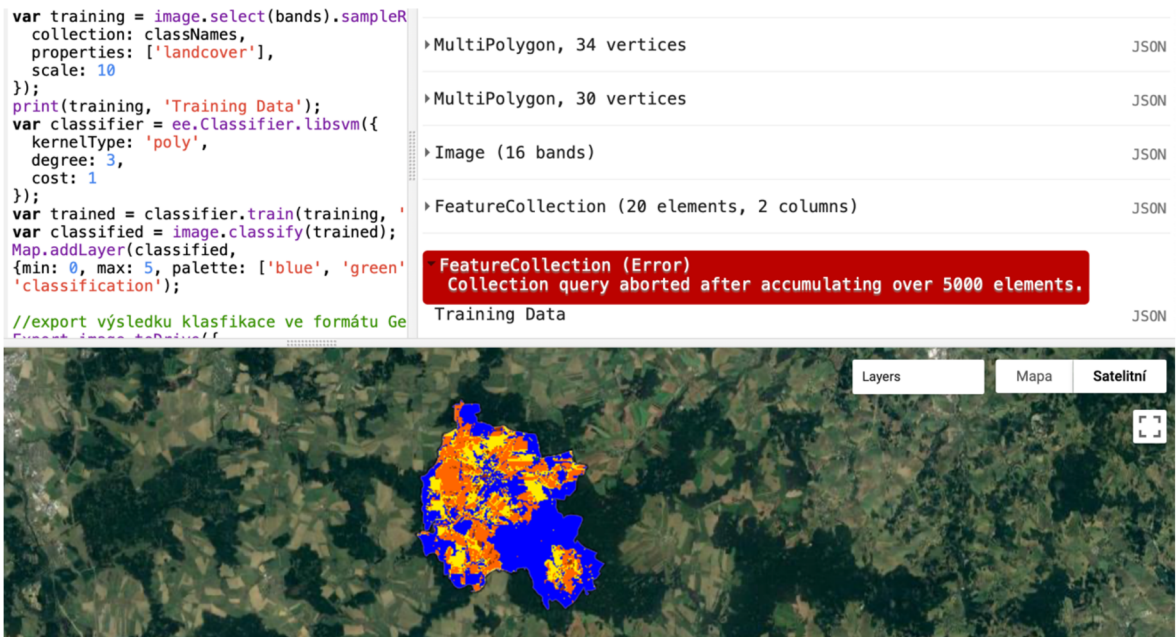
Na závěr výsledků klasifikací lze konstatovat, že algoritmus Naïve Bayes je vhodný pouze k porovnání kategorií, nikoliv ke srovnání výsledné klasifikace testovaných snímků. Algoritmus Naïve Bayes je vhodný převážně pro přírodní kategorie. Nejlépe vyhodnocuje kategorie lesů, vod a půd. Algoritmus Minimum Distance má nejlepší zaznamenané výsledky v kategoriích průmysl a půda. Algoritmus Random Forest nelze jednoznačně zařadit. Vykazuje nejlepší výsledky jak pro venkovskou, tak pro městskou krajinu. Nejlepší výsledky vykazuje především v kategoriích zelených ploch, lesů, zpevněné a nezpevněné cesty a zástavby. Algoritmus CART je stejně jako RF vhodný pro městskou i venkovskou krajinu. Nejvyšší výsledky vykazuje v kategoriích zástavba, les a holá půda.

Jak bylo očekáváno již na začátku práce, snímek MODIS se svým rozlišením nedokázal vyklasifikovat hned několik kategorií u obou zájmových území. Nejvyšší procentuální hodnotu znázorňuje snímek Sentinel-2.

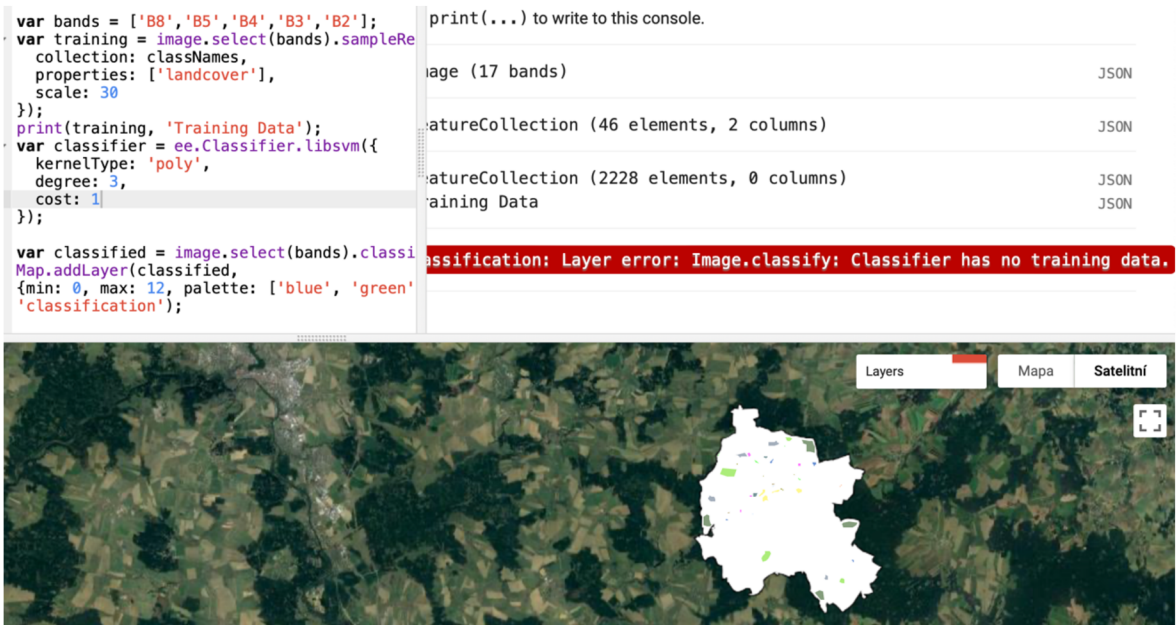
V obecném měřítku z výsledků vyplývá, že nejvhodnějším algoritmem pro klasifikaci krajinných jednotek je Random Forest a tím nejméně vhodným Naïve Bayes. Právě Naïve Bayes v několik případech nedokázal vůbec zařadit plochy do definovaných kategorií. Algoritmus Random Forest dokáže efektivně zpracovat a využít celou škálu informací pro lepší klasifikaci. Dalším jeho plusem je, že pracuje s nelineárními vztahy mezi atributy, což mu umožňuje přesněji identifikovat vegetační pokryv.

Referenční vrstva pro úroveň biotopů zabírá menší plochu než pro úroveň land cover a land use. Z tohoto důvodu je celkový počet pixelů na úrovni 3 daleko nižší.

Jak už bylo zmíněno v kap. 2.4 algoritmus SVM nepracoval tak jak se očekávalo. Na úrovni land cover nedocházelo k žádnému problému. Klasifikace v pořádku proběhla. Pro úroveň land use a biotop již nedošlo k žádné klasifikaci. Algoritmus nedokázal vyhledat žádné trénovací množiny. Vzhledem k tomu, že ani přes úpravy skriptu nedocházelo k jiným výsledkům, byl algoritmus vyřazen z celého zkoumání jednotlivých algoritmů. Např. za použití parametru *kernelType: RGB* byla vyklasifikována přes celé zájmové území pouze jedna kategorie, což nedává žádné relevantní výsledky.



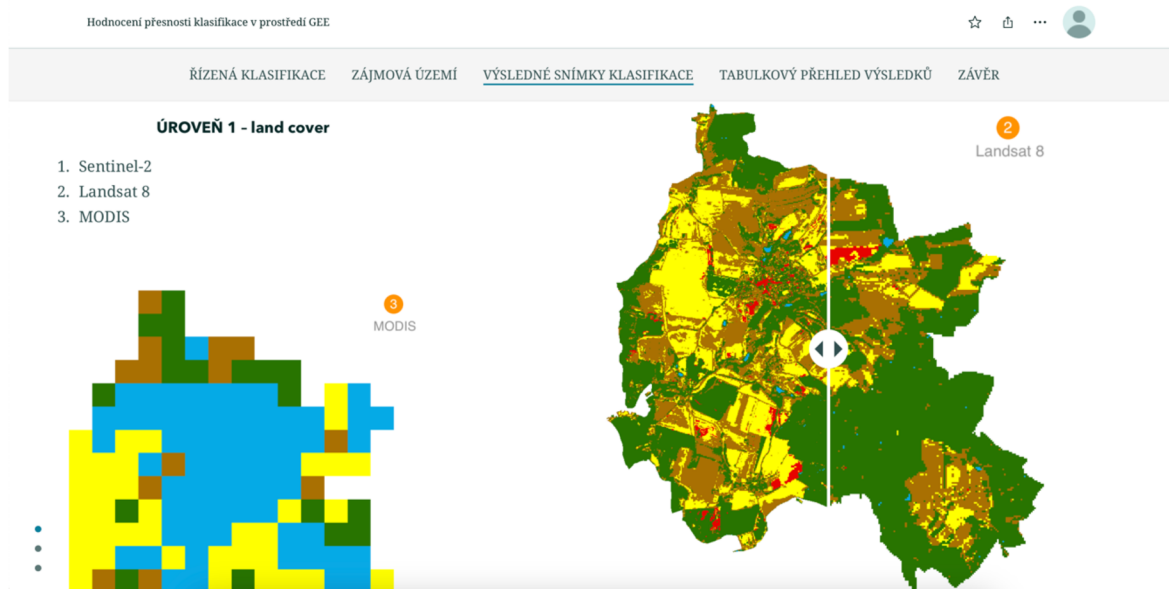
Obr. 21 Algoritmus SVM na úrovni land cover v GEE.



Obr. 22 Algoritmus SVM na úrovni land use v GEE.

6.6 StoryMap

Pro prezentaci výsledných dat zpřístupněné pro veřejnost byla vytvořena StoryMap v programu ArcGIS. StoryMap obsahuje stručnou definici pojmu řízená klasifikace a její kroky. Dále pak základní charakteristiku snímků Sentinel-2, Landsat 8 a MODIS. Je zde dostupné referenční vrstvy a výsledné klasifikace algoritmu Random Forest na území Černovic u tábora ve všech třech úrovních. Nedílnou součástí StoryMap jsou výsledky procentuálních shod ve formě tabulek. Je dostupná na přiloženém odkaze: <https://arcg.is/09jTDb>.



Obr. 23 Ukázka z prostředí StoryMap.

7 DISKUZE

Prvotním úkolem bylo vytvoření skriptu a spuštění klasifikace v Google Earth Enginu. V případě nejasností cloudová platforma nabízí několik odkazů, tutoriálů a nápověd, kde jsou jednotlivé kroky důkladně popsány. Pokud výpočet neobsahuje velké množství elementů, tak doba výpočtu trvá pouhých pár sekund. Ke zpracování klasifikace byly použity 3 typy datasetů, jež jsou dostupné přímo z katalogu obsaženém v Google Earth Engine. Těmito datasey jsou v GEE volně dostupné snímky – Sentinel-2, Landsat 8 a MODIS. Hned na začátku práce nastal problém u algoritmu Support Vector Machine, který neukazoval adekvátní výsledky, proto od něj bylo upuštěno.

Pro snadnější finální analýzu výsledků, byly snímky z GEE vyexportovány ve formátu GeoTIFF do desktopového programu ArcGIS Pro. V softwaru ArcGIS Pro bylo využito hlavně nástroje *Raster Calculator*. Při perzistenci na území Olomouce úrovně 2, na snímku Landsat 8 bylo vyhodnoceno nulové zastoupení hned několika kategorií – mix, jehličnaté lesy a smíšené lesy. Přitom se jedná o ty pixelově nejvíce zastoupené třídy ve všech snímcích.

Při importu vrstvy shapefile přes záložku *Assets* v GEE, vymezující zájmové území, bylo potřeba si pohlídat přípony souborů, jež jsou pro GEE validní.

U prvotního nastavování parametrů snímku Landsat 8, bylo definováno stejné datum jako u snímků Sentinel-2 a MODIS, tj. *.filterDate* v rozmezí od 30.7.2022 do 30.8.2022. Po spuštění klasifikace tlačítkem *Run*, byl vyklasifikován obraz, který byl zjevně vyobrazen pomocí dvou snímků. Z toho důvod byl hledán nejbližší možný datum, který by vyklasifikovaný obraz zobrazoval pouze jedním čistým snímkem. Snímek Landsat 8 je tedy brán z období 1.8.2022-1.9.2022.

Následoval problém u parametru *.first()* pro všechny typy testovacích snímků. Tohle definování při spuštění klasifikace vyobrazilo klasifikace pouze u poloviny zájmového území, tedy druhá polovina zůstala prázdná (obsahovala pouze hranici zájmového území). Tento problém byl vyřešen přenastavením parametru *.first()* na *.median()*.

Hned při psaní skriptu došlo k chybě, kdy bylo použito špatné spektrální pásmo, B8 místo B8A a tím pádem bylo použito i nesprávné rozlišení, u testovacího snímku Sentinel-2. Jelikož tahle chyba nebyla odhalena hned při začátku práce, ale až za více jak polovinou práce, tak bylo nutné pro snímek Sentinel-2 na všech úrovních a algoritmech provést celou klasifikaci snímku, export ve formátu GeoTIFF a import do programu ArcGIS Pro + následná analýza znovu. Je důležité si všechno několikrát zkontrolovat již na začátku psaní práce. I když tohle nebyla chyba, která by nešla opravit, ale právě tyhle chyby ubírají nejvíce času v celkovém psaní práce.

Další problém nastal při tvoření referenčních vrstev v programu ArcGIS Pro. Data k referenční vrstvě byla brána z Data50, CLC 2018 a OSM. Výsledná referenční vrstva pro úroveň land use obsahovala překrývající se vrstvy, což vedlo ke špatnému finálnímu výčtu rozlohy u obou území. Úprava byla provedena manuálně a následně zkontrolována před nástroj *Check Geometry* a *Repair Geometry*.

Původním záměrem bylo testovat 5 algoritmů řízené klasifikace, které obsahuje Google Earth Engine. Těmito algoritmy měly být CART, Random Forest, Minimum Distance, Naïve Bayes a Support Vector Machine. A právě u algoritmu Support Vector Machine nastávaly největší problémy. U každého algoritmu probíhalo psaní skriptu stejným způsobem. Po tom, co byl napsán první skript pro algoritmus CART, docházelo k pouhému změnění řádku odkazující na algoritmus. Se změnou algoritmu samozřejmě souvisela i úprava parametrů potřebná ke spuštění bez erroru. Po několika neúspěšných úpravách skriptu a

parametrů, zhlédnutí tutoriálů a pročtení si dokumentace v GEE, bylo rozhodnuto o vypuštění z celé série klasifikací.

Snímek MODIS na úrovni biotopy v GEE nedokázal vyklasifikovat obraz s rozlišením 500 m, proto u této poslední krajinné jednotky je použit snímek s rozlišením 250 m.

8 ZÁVĚR

Cílem diplomové práce bylo provést **sérii klasifikací** a stanovit **vhodnost** dostupných **algoritmů** pro klasifikaci krajinných jednotek v cloudovém prostředí **Google Earth Engine**. V rámci práce byla použita řízená klasifikace, která pracuje s trénovacími množinami. Trénovací množiny byly definovány manuálně přímo v mapovém okně GEE.

Jako první bylo potřeba si osvojit práci v prostředí Google Earth Engine, jak už základní nástroje, import datasetů či vektorové vrstvy shapefile, tak připravit spouštěcí skript (v programovacím jazyce JavaScript nebo Python) klasifikace. V dalším kroku proběhlo testování čtyř algoritmů řízené klasifikace (**CART**, **Random Forest**, **Minimum Distance** a **Naïve Bayes**) na třech testovacích satelitních snímcích (**Sentinel-2**, **Landsat 8** a **MODIS**) pro vybraná zájmová území (Olomouc a Černovice u Tábora). Klasifikace proběhla na třech úrovních – **land cover**, **land use** a **biotop** pro venkovskou a městskou krajinu. Každá úroveň byla klasifikována na odlišném počtu kategorií.

Veškeré výsledky byly prezentovány formou tabulkových výstupů. Výsledná **porovnání nenaplnila očekávání**. Na území města Olomouce představuje nejvyšší výsledky pro procentuální shodu ve všech úrovních algoritmus Random Forest, naopak nejnižší procentuální výsledky algoritmus Naïve Bayes společně s algoritmem Minimum Distance. Procentuální shoda u obce Černovice u Tábora, na všech úrovních vykazuje stejné výsledky. Nejvyšší výsledky jsou vykázané algoritmem Random Forest a ty nejnižší algoritmem Naïve Bayes. Procentuální shoda v kategoriích v Olomouci byla na úrovni land cover nejlépe vyhodnocena algoritmem CART a Naïve Bayes. Stejně tak je vhodné použít algoritmus CART na úrovni land use. Pro poslední úroveň biotopů je nevhodnější použít algoritmus Minimum Distance. Oblast Černovice u Tábora byl na úrovni land cover vyhodnocen s nejvyššími výsledky algoritmus Naïve Bayes. Kategorie na úrovni land use jsou nejlépe vyklasifikovány algoritmem Random Forest a kategorie na poslední úrovni biotopy algoritmem Naïve Bayes.

Nejlepší výsledky byly vyklasifikovány pomocí algoritmu **Random Forest**. Jak již je zmíněno, výsledky nedopadly dle původního předpokladu. Klasifikace pro všechny tři úrovně, na třech testovaných snímcích a čtyřech algoritmech, nebyla vyhodnocena vyšší jako 60 %. Stejně tak očekávaných výsledků nedosáhly ani procentuální shody v jednotlivých kategoriích. Na první pohled by se mohlo zdát, že se shoda bude vyskytovat ve vysokých číslech, ale výsledné analýzy ukázaly, že většina procentuálních shod se pohybuje v okolí 40 % a mnoha případech i daleko nižších.

Posledním krokem diplomové práce bylo vytvoření **StoryMaps** v programu ArcGIS Pro ke zpřístupnění dat široké veřejnosti. Ve StoryMap je obsažena stručná definice řízené klasifikace + kroky a třech testovacích snímků – Sentinel-2, Landsat 8 a MODIS. Dále jsou zde dostupné vizuální ukázky referenčních vrstev tří zkoumaných úrovní – land cover, land use a biotop. Ke každé úrovni je zde i názorná ukázka výsledných klasifikací pro algoritmus Random Forest. V neposlední řadě obsahuje výsledné klasifikace v podobě tabulek.

Veškeré dílčí cíle diplomové práce byly naplněny a v průběhu konzultovány s vedoucím práce. Jako součást diplomové práce byla vytvořena webová stránka a poster ve formátu A2.

POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE

1. AGGARWAL, Charu C. *Data Classification: Algorithms and Application*. Vydavatelství Taylor & Francis Group, LLC, 2015. 5. vydání. ISBN 978-1-4665-8674-1.
2. *API Reference* [online]. Google Earth Engine. Dostupné z: <https://developers.google.com/earth-engine/apidocs>
3. BAEZA, Santiago a PARUELO, JM. Land Use/Land Cover Change (2000-2014) in the Rio de la Plata Grasslands: An Analysis Based on MODIS NDVI Time Series [online]. *Remote Sensing*. 2020. 12(3), 381. [cit. 2023-08-09]. Dostupné z: <https://www.mdpi.com/2072-4292/12/3/381>
<https://doi.org/10.3390/rs12030381>
4. BELGIU, Mariana. Random Forest in Remote Sensing: A Review of Applications and Future Directions [online]. 2016. [cit. 2022-09-16]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0924271616000265>
5. BIČÍK, Ivan. *Vývoj využití ploch v Česku*. Praha: Česká geografická společnost, 2010. Geographica. ISBN 978-80-904521-3-8.
6. BREIMAN, Leo. RANDOM FORESTS--RANDOM FEATURES. *Statistics* [online]. Department University of California. 1999. [cit. 2022-09-16]. Dostupné z: <https://www.stat.berkeley.edu/~breiman/randomforest2001.pdf>
7. CULEK, Martin. 2013. *Biogeografické regiony České republiky*. Brno: Masarykova univerzita. ISBN 978-80-210-6693-9.
8. CAMPBELL, James B. *Introduction to Remote Sensing*. 3rd edition. New York: The Guilford Press, 2002. 625 s. ISBN 1-57230-640-8.
9. CUTLER, Adele, CUTLER, David, Richard, STEVENS, John R. Random Forest. [online] 2011. [cit. 2023-02-01]. Dostupné z: https://www.researchgate.net/publication/236952762_Random_Forests
10. ČÁBERA, A. Fytogeografická studie květeny Pelhřimovska a přilehlé části posázavského údolí při jeho severovýchodní hranici. 1969.
11. ČERVENÁ, Lucie. Hodnocení přesnosti klasifikace [online]. 2018. [cit. 2022-04-17]. Dostupné z: <https://www.natur.cuni.cz/geografie/geoinformatika-kartografie/ke-stazeni/projekty/moderni-geoinformacni-metody-ve-vyuce-gis-kartografie-a-dpz/hodnoceni-presnosti-klasifikace/>
12. ČERVENÁ, Lucie. Řízená klasifikace [online]. 2016. [cit. 2022-04-17]. Dostupné z: <https://www.natur.cuni.cz/geografie/geoinformatika-kartografie/ke->

stazeni/projekty/moderni-geoinformacni-metody-ve-vyuce-gis-kartografie-a-dpz/rizena-klasifikace/

13. DE'ATH, G., FABRICIUS, KE. Classification and Regression Trees: A Powerful Yet Simple Technique for Ecological Data Analysis [online]. WILEY 2000. 81(11), 3178-3192. ISSN 0012-9658. [cit. 2022-02-01]. Dostupné z: doi: 10.2307/177409
14. *Detailní kombinované vrstvy biotopů*. Czechglobe, 2018.
15. DOBROVOLNÝ, Petr. *Dálkový průzkum Země: digitální zpracování obrazu*. Brno: Masarykova univerzita, 1998. 210 s. ISBN 80-210-1812-7.
16. DUDA, Richard O. a HART, Peter E. a STORK, David G. *Pattern Classification*. 2nd edition. New York: Wiley, 2001. ISBN 978-0-471-05669-0.
17. DUTTA, Bhumika. A Classification and Regression Tree (CART) Algorithm [online]. 2021. [cit. 2022-02-01]. Dostupné z: <https://www.analyticssteps.com/blogs/classification-and-regression-tree-cart-algorithm>
18. *Earth Engine Code Editor* [online]. [cit. 2022-02-01]. Google Earth Engine. Dostupné z: <https://developers.google.com/earth-engine/guides/playground>
19. ESA, Sentinel Online [online]. [cit. 2023-08-05]. Dostupné z: <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2/overview>
20. HALBERSTADT, ARW, GLEASON, Colin J., MOUSSAVI, Mahsa S., POPE, Allen, TRUSEL, Luke D., DECONTO, Robert M. Antarctic Supraglacial Lake Identification Using Landsat-8 Image Classification. *Remote Sensing*. 2020. 12(8), 1327. [cit. 2023-08-04]. Dostupné z: <https://www.mdpi.com/2072-4292/12/8/1327>
<https://doi.org/10.3390/rs12081327>
21. HALOUNOVÁ, Lena. *Dálkový průzkum Země*. Praha: Vydavatelství ČVUT, 2005. ISBN 80-01-03124-1.
22. CHU, Yongjae, LEE, Hoonyol. Performance of Random Forest Classifier for Flood Mapping Using Sentinel-1 SAR Images [online]. *KOREAN SOC REMOTE SENSING*, 2022. 38(4), 375-386. ISSN 1225-6161. [cit. 2023-08-09]. Dostupné z: DOI10.7780/kjrs.2022.38.4.5
23. CHYTRÝ, Milan, ed. *Katalog biotopů České republiky*. 2. vyd. Praha: Agentura ochrany přírody a krajiny ČR, 2010. ISBN 978-80-87457-02-3. [cit. 2023-08-04]. Dostupné z: https://www.sci.muni.cz/botany/chytry/Chytry_etal2010_Katalog-biotopu-CR-2.pdf
24. KROUPÍ, Eleni, KESA, Maria, NAVARRO-SÁNCHEZ, Victor, Diego, SAEED, Salman, PELLOQUIN, Camille, ALHADDAD, Bahaa, MORENO, Laura, SORIA-FRISCH,

- Aureli, RUFFINI Giulio. Deep convolutional neural networks for land-cover classification with Sentinel-2 images [online]. *Journal of Applied Remote Sensing*. 2019. 13(2), 024525. [cit. 2023-08-04]. Dostupné z: <https://doi.org/10.1117/1.JRS.13.024525>
25. LINAG, Gang. Image classification of artworks based on multiple naive Bayes algorithm [online]. *International Journal of Arts and Technology*. 2021. 13(2), 79-90. ISSN 1754-8853. [cit. 2023-08-09]. Dostupné z: <https://doi.org/10.1504/IJART.2021.120580>
26. LIANG Shunlin, LI Xiaowen and WANG Jindi. *Advanced Remote Sensing: terrestrial information extraction and applications*. 1st edition. Academic Press, 2012. 799 s. ISBN 978-0-12-385954-9.
27. LILLESAND, Thomas M. a KIEFER, Ralph W. *Remote sensing and image interpretation*. 3th edition. New York: Wiley, 1994. 750 s. ISBN 0471577839.
28. LILLESAND, Thomas M. a KIEFER, Ralph W. *Remote sensing and image interpretation*. 7th edition. New York: Wiley, 2015. [cit. 2022-06-25]. Dostupné z: <https://www.geokniga.org/bookfiles/geokniga-remote-sensing-and-image-interpretation.pdf>
29. LIU, Yun-Fu, GUO, Jing-Ming, LEE, Jiann-Der. Halftone Image Classification Using LMS Algorithm and Naive Bayes [online]. *IEEE Transactions on Image Processing*. 2011. 20(10), 2837-2847. [cit. 2023-08-09]. Dostupné z: doi: 10.1109/TIP.2011.2136354.
30. MCCANN, Sancho, LOWE, David G. Local Naive Bayes Nearest Neighbor for Image Classification [online]. *IEEE Conference on Computer Vision and Pattern Recognition* 2012. 3650-3656. ISSN 1063-6919. [cit. 2023-08-09] Dostupní z: <https://arxiv.org/pdf/1112.0059.pdf>
31. MONDAL, Shalmoly, BAG, Soumen. Face Recognition Using PCA and Minimum Distance Classifier [online]. *SPRINGER-VERLAG SINGAPORE* 2017. 515, 397-405. ISSN 2194-5357. [cit. 2023-08-09]. Dostupné z: 10.1007/978-981-10-3153-3_39
32. NAGHIBI, Seyed Amir, POURGHASEMI, Hamid Reza, DIXON, Barnali. GIS-based groundwater potential mapping using boosted regression tree, classification and regression tree, and random forest machine learning models in Iran [online]. *SPRINGER* 2016. 188(1). ISSN 0167-6369. [cit. 2023-08-09]. Dostupné z: doi: 10.1007/s10661-015-5049-6
33. NASA, Landsat 8 [online]. [cit. 2023-08-05]. Dostupné z: <https://landsat.gsfc.nasa.gov/satellites/landsat-8/>

34. PRAAGMAN, J. Classification and Regression Trees – Breiman, L, Friedman, Jh, Olshen, Ra, Stone, Cj [online]. ELSEVIER 1985. 19(1), 144. ISSN 0377-2217. [cit. 2023-08-09]. Dostupné z: doi: 10.1016/0377-2217(85)90321-2
35. RAMIREZ, J., GORRIZ, J. M., CHAVES, R., LOPEZ, M., SALAS-GONZALEZ, D., ALVAREZ, I., SEGOVIA, F. SPECT Image Classification Using Random Forests [online]. WILEY 2009. 45(12), 604-U8. ISSN 0013-5194. [cit. 2023-08-09]. Dostupné z: doi: 10.1049/el.2009.1111
36. RASCHKA, Sebastian. Naive Bayes and Text Classification I: Introduction and Theory [online]. 2014 [cit. 2023-02-01]. Dostupné z: <https://arxiv.org/pdf/1410.5329.pdf>
37. RAY, Sunil. Naive Bayes Classifier Explained: Applications and Practice Problems of Naive Bayes Classifier [online]. 2017. [cit. 2023-02-01]. Dostupné z: <https://www.analyticsvidhya.com/blog/2017/09/naive-bayes-explained/>
38. RICHARDS, John A. *Remote Sensing Digital Image Analysis: An Introduction*. 5th ed. Springer-Verlag Berlin Heidelberg, 2013. ISBN 978-3-642-30061-5.
39. SANTUCCI, Enrica. Quantum Minimum Distance Classifier [online]. MDPI 2017. 19(12). eISSN 1099-4300. [cit. 2023-08-09]. Dostupné z: 10.3390/e19120659
40. SHI, Wenzhong, GOODCHILD, Michael F., BATTY, Michael, KWAN, Mei-Po, and ZHANG, Anshu, eds. *Urban Informatics*. Singapore: Springer Singapore Pte. Limited, 2021. Accessed June 25, 2022. ProQuest Ebook Central. [cit. 2023-02-02] Dostupné z: <https://link.springer.com/book/10.1007/978-981-15-8983-6>
41. SKLENIČKA, Petr. *Základy krajinného plánování*. Vyd. 2. Praha: Naděжда Skleničková, 2003. ISBN 80-903206-1-9.
42. USGC, MODIS Overview [online]. [cit. 2023-08-05]. Dostupné z: <https://lpdaac.usgs.gov/data/get-started-data/collection-overview/missions/modis-overview/>
43. WANG, Qunming, WANG, Lanxing, ZHU, Xiaolin, GE, Yong, TONG, Xiaohua, ATKINSON, Peter M. Remote Sensing Image Gap Filling Based on Spatial-Spectral Random Forests [online]. ELSEVIER 2022. 5. ISSN 2666-0172. [cit. 2023-08-09]. Dostupné z: doi: 10.1016/j.srs.2022.100048
44. WEBB, Geoffrey I. Naïve Bayes [online]. In: Sammut, C., Webb, G.I. (eds) *Encyclopedia of Machine Learning and Data Mining*. Springer, 2017. 895–896. ISBN 978-1-4899-7685-7. [cit. 2023-02-01]. Dostupné z: https://link.springer.com/content/pdf/10.1007/978-1-4899-7687-1_581.pdf?pdf=core
https://doi.org/10.1007/978-1-4899-7687-1_581

45. *Zemědělské družstvo Černovice u Tábora, O nás* [online]. [cit. 2023-08-09]. Zemědělské družstvo Černovice u Tábora. Dostupné z: <https://zdcernovice.cz/onas>
46. ZHANG, DQ, CHEN, SC, ZHOU, ZH. Learning the Kernel Parameters in Kernel Minimum Distance Classifier [online]. ELSEVIER SCI LTD 2006. 39(1), 133-135. ISSN 0031-3203. [cit. 2023-08-09]. Dostupné z: [10.1016/j.patcog.2005.08.001](https://doi.org/10.1016/j.patcog.2005.08.001)
47. ZHAO, Jingbo, THORNBERG, Benny, SHI, Yan, HASHEMI, Ashkan. Color Segmentation on FPGA Using Minimum Distance Classifier for Automatic Road Sign Detection [online]. IEEE 2012. [cit. 2023-08-09]. Dostupné z: <https://arxiv.org/pdf/2212.08657.pdf>

PŘÍLOHY

SEZNAM PŘÍLOH

Vázané přílohy:

- Příloha 1 Struktura kódu na úrovni 1 pro řízenou klasifikace za použití algoritmu CART
- Příloha 2 Plocha přepočítaná na m² na území Olomouce
- Příloha 3 Plocha přepočítaná na m² na území Černovic u Tábora
- Příloha 4 Ukázka grafické vizualizace na úrovni 1 snímek Sentinel-2 a pro algoritmus Random Forest na území Olomouce
- Příloha 5 Ukázka grafické vizualizace na úrovni 1 snímek Sentinel-2 a pro algoritmus Random Forest na území Černovic u Tábora

Volné přílohy

- Příloha 6 Poster

Popis struktury odevzdávaných digitálních dat na datové úložiště katedry

Povinná struktura adresářů:

Text_Prace (*DP_Karamonova.pdf*)

Data na flashdisku

Web

Poster (*Poster_Karamonova.pdf*)

Příloha 1

Struktura kódu pro úroveň 1 pro řízenou klasifikaci za použití algoritmu CART:

```
//zobrazení a zoom nahrané shp vrstvy
Map.addLayer(roi)
Map.centerObject(roi,10)

//nahrátí snímku sentinel-2, vymezení dat, území, oblačnosti a ořezání na
vrstvu shp
var image = ee.ImageCollection("COPERNICUS/S2")
  .filterDate("2022-07-30","2022-08-30")
  .filterBounds(roi)
  .filterMetadata('CLOUD_COVERAGE_ASSESSMENT','less_than',45)
  .median()
  .clip(roi);
print(image);

//vizualizace true/false a zobrazen snímku na mapě
var trueColour = {
  min:0,
  max:3000,
  bands:("B4", "B3", "B2")
}
Map.addLayer(image, trueColour, "True-colour image");

var falseColour = {
  min:0,
  max:3000,
  bands:("B8", "B4", "B3")
}
Map.addLayer(image, falseColour, "False-colour image");

//merge kategorií
var classNames =
forest.merge(water).merge(urban).merge(grass).merge(bare);
print(classNames);

//použitá pásma k predikci
var bands = ['B2', 'B3', 'B4', 'B5', 'B6', 'B7'];

//manuálně vytvořené polygony, definování polygonů lesů
var polygon1 = ee.Geometry.Polygon(
  [[[17.36744371934849, 49.61720721260987],
    [17.3666712431522, 49.6154276938894],
    [17.368387856921732, 49.61531647181187],
    [17.36993280931431, 49.61637307130023],
    [17.370361962756693, 49.61726282152286],
    [17.36821619554478, 49.616706729537384]]]);
var polygon2 = ee.Geometry.Polygon(
  [[[17.386583962878763, 49.612702679920325],
    [17.384352364978373, 49.611868461511435],
    [17.384524026355326, 49.610644915351315],
    [17.382721581897318, 49.609532574008135],
    [17.38237825914341, 49.607530295624635],
    [17.385039010486185, 49.60958819167813],
    [17.38838640733677, 49.61075614808958]]]);
```

```

var polygon3 = ee.Geometry.Polygon(
  [[[17.34744516893345, 49.64164766291443],
    [17.348560967883646, 49.64014695141827],
    [17.350105920276224, 49.64125859400482],
    [17.35199419542271, 49.64320390746414],
    [17.35199419542271, 49.64409316773103],
    [17.350105920276224, 49.64337064500136]]]);
var polygon4 = ee.Geometry.Polygon(
  [[[17.350661252591475, 49.62700322485343],
    [17.350661252591475, 49.62611365248022],
    [17.35006043777214, 49.625279663627744],
    [17.35006043777214, 49.62439005978226],
    [17.351347898099288, 49.622944418888196],
    [17.352206204984054, 49.623611643092424],
    [17.351347898099288, 49.62544646254039],
    [17.35229203567253, 49.62689202919509]]]);
var polygons = [polygon1, polygon2, polygon3, polygon4];
var polygon_forest = ee.Geometry.MultiPolygon(polygons);
print(polygon_forest);

//definování polygonů vody
var polygon5 = ee.Geometry.Polygon(
  [[[17.269981946662526, 49.544951492106314],
    [17.270947541907887, 49.54538309817244],
    [17.270958270743947, 49.54557801579124],
    [17.27036818476067, 49.545675474309014],
    [17.27009996385918, 49.54588431333533],
    [17.269928302482228, 49.54543182765004],
    [17.26941331835137, 49.54497237635859],
    [17.26888760538445, 49.54497933777403],
    [17.26914509744988, 49.544798340650225]]]);
var polygon6 = ee.Geometry.Polygon(
  [[[17.266977872565846, 49.54413699930463],
    [17.267728891090016, 49.544659111637166],
    [17.267428483680348, 49.54490276214965],
    [17.2670958897625, 49.54462430432192],
    [17.26683839769707, 49.54417876849654],
    [17.2660873791729, 49.543768036558426],
    [17.265561666205983, 49.54316933636247]]]);
var polygon7 = ee.Geometry.Polygon(
  [[[17.267685634146908, 49.56609645760572],
    [17.267524701606014, 49.56565807608365],
    [17.267331582556942, 49.565456280091716],
    [17.267245751868465, 49.56527187957667],
    [17.26736376906512, 49.565247524739604],
    [17.267530066024044, 49.565466717835875],
    [17.26766417647479, 49.565689389180044],
    [17.26789484645007, 49.56614516642074],
    [17.267750007163265, 49.56623214632672]]]);
var polygon8 = ee.Geometry.Polygon(
  [[[17.264738691454394, 49.57368513874431],
    [17.26493985713051, 49.57391994786279],
    [17.26531268418358, 49.5741930207502],
    [17.26530731976555, 49.574316511809045],
    [17.26506055653618, 49.574293900793464],
    [17.26484061539696, 49.573921687185376],
    [17.264800382261736, 49.574149537908596],
    [17.264626038675768, 49.57382080637278]]]);
var polygons = [polygon5, polygon6, polygon7, polygon8];
var polygon_water = ee.Geometry.MultiPolygon(polygons);
print(polygon_water);

```

```

//definování polygonů zastavěné plochy
var polygon9 = ee.Geometry.Polygon(
  [[[17.22445204606435, 49.5851552157788],
    [17.22447350373647, 49.58473787266525],
    [17.22466662278554, 49.58452919976971],
    [17.225074318555805, 49.58440399560399],
    [17.22494557252309, 49.585085658841116]]]);
var polygon10 = ee.Geometry.Polygon(
  [[[17.233122939164275, 49.58946930274085],
    [17.233648652131194, 49.58910068244025],
    [17.233895415360564, 49.58916327853669],
    [17.233831042344207, 49.58933715616093],
    [17.233423346573943, 49.58953885342859]]]);
var polygon11 = ee.Geometry.Polygon(
  [[[17.233242408104655, 49.590995658589755],
    [17.233274594612833, 49.590877425892685],
    [17.23333896762919, 49.59073485078858],
    [17.233794943161723, 49.5908009222301],
    [17.233773485489603, 49.591002613445376]]]);
var polygon12 = ee.Geometry.Polygon(
  [[[17.243934930315458, 49.59785673780717],
    [17.244042218676054, 49.597648121027206],
    [17.24461084698721, 49.59771766005303],
    [17.244739593019926, 49.59786021474594],
    [17.244728864183866, 49.59795061506699]]]);
var polygons = [polygon9, polygon10, polygon11, polygon12];
var polygon_urban = ee.Geometry.MultiPolygon(polygons);
print(polygon_urban);

//definování polygonů trvale zatravněné plochy
var polygon13 = ee.Geometry.Polygon(
  [[[17.247207225313627, 49.59728651649452],
    [17.24733597134634, 49.59728651649452],
    [17.24737888669058, 49.5973908257695],
    [17.24737888669058, 49.59753685837968],
    [17.246981919756376, 49.59750208875024]]]);
var polygon14 = ee.Geometry.Polygon(
  [[[17.2443091456953, 49.59425476394292],
    [17.244384247547718, 49.594115675916505],
    [17.244652468449207, 49.59401135963637],
    [17.244652468449207, 49.59408090384792],
    [17.244631010777088, 49.59421303757664]]]);
var polygon15 = ee.Geometry.Polygon(
  [[[17.249008375889392, 49.58879526115714],
    [17.24905129123363, 49.58884394732169],
    [17.2488474433485, 49.58892740920502],
    [17.248954731709095, 49.58913606328865],
    [17.248986918217273, 49.58935167157079],
    [17.2487937991682, 49.58933776138777],
    [17.24880452800426, 49.589094332543326],
    [17.24860068011913, 49.58899696066539]]]);
var polygon16 = ee.Geometry.Polygon(
  [[[17.251111967288306, 49.586431486095556],
    [17.251187069140723, 49.58625759811438],
    [17.251423103534034, 49.58615326502819],
    [17.251626951419166, 49.58620195382951],
    [17.251605493747046, 49.586320197858996],
    [17.251326544009498, 49.586320197858996]]]);
var polygons = [polygon13, polygon14, polygon15, polygon16];
var polygon_grass = ee.Geometry.MultiPolygon(polygons);
print(polygon_grass);

```

```

//definování polygonů holé půdy
var polygon17 = ee.Geometry.Polygon(
  [[[17.318734527004683, 49.58263630116312],
    [17.32027947939726, 49.58007640837871],
    [17.324227691067183, 49.579965105645954],
    [17.328862548244917, 49.58074421944388],
    [17.32851922549101, 49.58230240972044]]]);
var polygon18 = ee.Geometry.Polygon(
  [[[17.18126671304829, 49.59109412227011],
    [17.181180882359815, 49.589035445576876],
    [17.18405621042378, 49.58959185325092],
    [17.185858654881788, 49.590315173739164],
    [17.185214924718213, 49.59331962095978],
    [17.184614109898877, 49.59226252174329]]]);
var polygon19 = ee.Geometry.Polygon(
  [[[17.296050410737184, 49.61957718024369],
    [17.296050410737184, 49.618659668640746],
    [17.29866824673572, 49.61863186498914],
    [17.299826961030153, 49.618047984641265],
    [17.302487712372926, 49.61885429375768],
    [17.303303103913453, 49.61916013165667],
    [17.302487712372926, 49.619855210652084],
    [17.29961238430896, 49.618965507761224]]]);
var polygon20 = ee.Geometry.Polygon(
  [[[17.28102937975529, 49.629057149898834],
    [17.280857718378336, 49.6272085670558],
    [17.28420511522892, 49.628000825435386],
    [17.284419691950113, 49.62909884644719],
    [17.283346808344156, 49.62962699963713],
    [17.282188094049722, 49.62876527306094]]]);
var polygons = [polygon17, polygon18, polygon19, polygon20];
var polygon_bare = ee.Geometry.MultiPolygon(polygons);
print(polygon_bare);

//vytvoření featurecollection z geometrie
var poly = ee.FeatureCollection([
  ee.Feature(polygon1, {'class': 0}),
  ee.Feature(polygon2, {'class': 0}),
  ee.Feature(polygon3, {'class': 0}),
  ee.Feature(polygon4, {'class': 0}),
  ee.Feature(polygon5, {'class': 1}),
  ee.Feature(polygon6, {'class': 1}),
  ee.Feature(polygon7, {'class': 1}),
  ee.Feature(polygon8, {'class': 1}),
  ee.Feature(polygon9, {'class': 2}),
  ee.Feature(polygon10, {'class': 2}),
  ee.Feature(polygon11, {'class': 2}),
  ee.Feature(polygon12, {'class': 2}),
  ee.Feature(polygon13, {'class': 3}),
  ee.Feature(polygon14, {'class': 3}),
  ee.Feature(polygon15, {'class': 3}),
  ee.Feature(polygon16, {'class': 3}),
  ee.Feature(polygon17, {'class': 4}),
  ee.Feature(polygon18, {'class': 4}),
  ee.Feature(polygon19, {'class': 4}),
  ee.Feature(polygon20, {'class': 4}),
]);

//získání hodnot pro všechny pixely v každém polygonu + parametry
var trained = image.sampleRegions({
  collection: poly,

```



```
properties: ['class'],
  scale: 30
});

var training = image.select(bands).sampleRegions({
  collection: classNames,
  properties: ['landcover'],
  scale: 30
});
print(training, 'Training Data');

//vytvoření klasifikátoru s vlastními parametry
var classifier = ee.Classifier.smileCart().train({
  features: training,
  classProperty: 'landcover',
  inputProperties: bands
});

//trénování klasifikátoru
var classified = image.select(bands).classify(classifier);

//zobrazení výsledku klasifikace
Map.addLayer(classified,
{min: 0, max: 5, palette: ['blue', 'green', 'red','yellow', 'orange']},
'classification');

//export výsledku klasifikace ve formátu GeoTIFF
Export.image.toDrive({
  image: classified,
  description: 'sentinel_cart',
  fileFormat: 'GeoTIFF',
  scale:20,
  maxPixels:1e10,
  region: roi,
  crs: 'EPSG:32633',
  formatOptions: {
    cloudOptimized: true
  }
});
```

Příloha 2

Plocha přepočítaná na m² – Olomouc

ÚROVEŇ 1 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
les	15963300	18593500	28858600	31208000	15329900
voda	1732100	1614100	2405000	986000	1676600
zástavba	26741500	30926700	27744100	31996900	15268200
tpp	36058900	27501400	27375800	33499700	26034400
holá půda	22814700	24674800	16927000	5619900	45001400

ÚROVEŇ 1 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
les	12458700	17521200	12514500	35257500	15298200
voda	1899000	2216700	3038400	929700	1701900
zástavba	34295400	31056300	23823900	13887000	15269400
tpp	31183200	26090100	39591000	19883700	26044200
holá půda	23458500	26410500	24327000	33336900	44981100

ÚROVEŇ 1 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
les	60750000	19250000	29000000	19000000	16000000
voda	0	0	0	0	2500000
zástavba	27750000	55750000	56000000	62500000	15000000
tpp	0	0	0	0	25250000
holá půda	16000000	29500000	19500000	23000000	45750000

ÚROVEŇ 2 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
<i>nezařazeno</i>	400	400	400	16800	0
voda	1244400	1296000	1168600	724000	1584000
zpevněná cesta	1828900	913900	4585000	3629600	2948500
nezpevněná cesta	1908200	663800	5557300	6700800	447600
zelené plochy	4551700	3915700	15037600	4924600	1054800
průmysl	12720000	13687900	2976200	2539600	5169200
staveniště	7326400	5721700	3469200	5534200	86100
úhor	7187400	6789000	14248800	18789600	290700
souvislá zástavba	5590600	5650300	1924400	1729200	9418400
obhospodařovaná půda	24914700	31271700	4998100	3946300	22878600
TTP	3494300	3795000	13629400	13006700	24206300
roztroušená zástavba	6190700	6283900	13808500	8770500	457100
mix	4518600	4549700	6643700	8447700	20851100
jehličnaté lesy	13356300	13196600	5616600	8126600	5179700
smíšené lesy	4113500	3332500	6620200	15984600	1589600
listnaté lesy	4259100	2137100	2921200	334400	7043500

ÚROVEŇ 2 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
<i>nezařazeno</i>	0	0	0	169200	0
voda	2057400	1910700	1517400	583200	1560600
zpevněná cesta	3745800	1061100	10015200	5832000	2398500
nezpevněná cesta	520200	264600	5272200	5718600	204300
zelené plochy	5758200	3608100	19190700	9942300	1057500
průmysl	7172100	8676000	1211400	3815100	5236200
staveniště	6981300	6233400	5069700	8259300	85500
úhor	6730200	6597900	11085300	12244500	286200
souvislá zástavba	6617700	4464900	9358200	5384700	9579600
obhospodařovaná půda	37359000	51085800	3051000	7162200	23054400
TTP	3533400	2506500	19417500	2296800	24505200
roztroušená zástavba	4240800	2045700	4572900	3678300	236700
mix	4989600	4020300	1766700	5366700	21230100
jehličnaté lesy	7074000	6758100	2615400	9472500	5166900
smíšené lesy	4488300	2547900	1254600	5440500	1591200
listnaté lesy	1881900	1368900	7751700	17784000	6957000

ÚROVEŇ 2 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
voda	1750000	2250000	2750000	20250000	1000000
zpevněná cesta	0	0	0	0	250000
nezpevněná cesta	0	0	0	0	0
zelené plochy	0	0	0	0	250000
průmysl	28000000	31750000	36000000	1250000	5250000
staveniště	0	0	0	0	0
úhor	20500000	16500000	11500000	15000000	0
souvislá zástavba	0	0	0	0	7250000
obhospodařovaná půda	28750000	24000000	14000000	19000000	24750000
TTP	0	0	0	0	26500000
roztrošená zástavba	1750000	7250000	11750000	28750000	0
mix	0	0	0	0	23750000
jehličnaté lesy	16750000	11500000	14750000	7500000	6500000
smíšené lesy	0	0	0	0	1250000
listnaté lesy	2750000	7000000	9500000	8500000	3500000

ÚROVEŇ 3 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
<i>nezařazeno</i>	0	0	0	0	1300
K1 + K3	75000	76900	20900	241100	26400
L1 + L2.2	177200	144700	46600	127100	140900
L2.4	143000	179900	39100	54800	205300
L2.3 + L2.3B	228300	245600	194000	265400	71200
L3.1	265700	343200	155300	367800	486200
L5.1 + L5.4	139500	149400	50800	112500	41400
L7.1 + L7.2	253000	215700	92000	142100	276200
M1.1 + M1.3	16100	7700	53400	26800	700
M1.4 + M1.7	36500	17700	43800	47200	9800
S1.2	8200	4800	367600	200	0
T1.1	101600	104900	30500	39100	163600
T1.4	104800	114700	71800	103600	146300
T1.5 + T1.6 + T1.9	43000	9500	283500	1100	27400
T3.4D	10800	5000	41300	98800	400
T4.2	9700	1400	137200	9300	100
V1F + V1G + V4B	89300	80600	73900	64800	104500

ÚROVEŇ 3 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
<i>nezařazeno</i>	0	0	0	3600	1800
K1 + K3	51300	44100	83700	133200	24300
L1 + L2.2	116100	126900	129600	121500	101700
L2.4	136800	163800	234000	110700	198000
L2.3 + L2.3B	248400	288000	86400	108900	69300
L3.1	149400	148500	228600	345600	475200
L5.1 + L5.4	72900	79200	21600	52200	39600
L7.1 + L7.2	292500	315000	158400	67500	261000
M1.1 + M1.3	81000	8100	59400	44100	0
M1.4 + M1.7	13500	8100	226800	262800	5400
S1.2	10800	13500	78300	152100	0
T1.1	99000	69300	49500	75600	158400
T1.4	115200	148500	45900	25200	151200
T1.5 + T1.6 + T1.9	27000	6300	98100	33300	25200
T3.4D	3600	9000	45000	19800	0
T4.2	0	0	0	0	0
V1F + V1G + V4B	198000	187200	70200	59400	104400

ÚROVEŇ 3 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
<i>nezařazeno</i>	0	0	0	0	0
K1 + K3	0	0	0	0	0
L1 + L2.2	0	0	0	0	0
L2.4	0	0	0	187500	125000
L2.3 + L2.3B	312500	187500	312500	62500	0
L3.1	62500	187500	0	62500	250000
L5.1 + L5.4	0	0	0	0	0
L7.1 + L7.2	0	0	0	0	0
M1.1 + M1.3	0	0	0	0	0
M1.4 + M1.7	0	0	0	0	0
S1.2	0	0	0	0	0
T1.1	62500	125000	187500	125000	62500
T1.4	62500	0	0	62500	62500
T1.5 + T1.6 + T1.9	0	0	0	0	0
T3.4D	0	0	0	0	0
T4.2	0	0	0	0	0
V1F + V1G + V4B	0	0	0	0	0

Příloha 3

Plocha přepočítaná na m² – Černovice

ÚROVEŇ 1 - SENTINEL	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
les	19767700	19679500	14917900	11165600	15222900
voda	287900	104300	192000	76000	135500
zástavba	976400	667300	2431300	828400	1101100
ttp	7931700	7815500	6127800	9231600	8139200
holá půda	10294200	10991300	15588900	17956300	14659200

ÚROVEŇ 1 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
les	21015900	21317400	17373600	11969100	15230700
voda	423000	119700	122400	71100	134100
zástavba	996300	554400	2722500	1826100	1105200
ttp	4933800	4542300	4428000	7154100	8123400
holá půda	11876400	12711600	14598900	18225000	14652000

ÚROVEŇ 1 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
les	6500000	7500000	3750000	12000000	17000000
voda	8250000	17500000	19000000	19250000	0
zástavba	0	0	0	0	1500000
ttp	12500000	11250000	10500000	500000	7750000
holá půda	13500000	4500000	7500000	9000000	14500000

ÚROVEŇ 2 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
nezařazeno	33600	33600	33600	36400	0
voda	301500	110100	405700	84700	135200
TTP	4973800	5065900	4813900	5922900	7939400
průmysl	2036000	1964400	736900	1398900	100400
zpevněná cesta	304600	71500	1111500	215200	217200
nezpevněná cesta	408000	165700	1006600	925700	131800
jehličnaté lesy	17201000	18649700	10060600	9549600	13418000
smíšené lesy	3908500	4327600	2787800	2887900	915300
listnaté lesy	779200	346500	2699000	6694200	2040200
zástavba	245800	10600	3197600	2276000	565300
mix	1957100	1382800	2780800	1555600	1919100
obhospodařovaná půda	4573200	5159900	2809300	3619800	7209000
úhor	2512600	1946600	6791600	4068000	4644000

ÚROVEŇ 2 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
nezařazeno	0	0	0	18000	0
voda	315000	108900	344700	69300	135000
TTP	4894200	5419800	2441700	2601900	8120700
průmysl	1918800	1674000	1125900	4542300	100800
zpevněná cesta	187200	35100	1800900	900000	74700
nezpevněná cesta	28800	30600	1318500	1883700	51300
jehličnaté lesy	16731000	19596600	10192500	9222300	13460400
smíšené lesy	3016800	2212200	2900700	2768400	918900
listnaté lesy	652500	660600	2690100	8631000	1919700
zástavba	288900	12600	5825700	3438000	581400
mix	2683800	1410300	2166300	1800000	1923300
obhospodařovaná půda	5517000	5742900	752400	1265400	7251300
úhor	2976300	2306700	7650900	2070000	4672800

ÚROVEŇ 2 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
<i>nezařazeno</i>	0	0	0	0	0
voda	4250000	5750000	3500000	2750000	0
TTP	0	0	0	0	8000000
průmysl	0	0	0	0	0
zpevněná cesta	0	0	0	0	0
nezpevněná cesta	0	0	0	0	0
jehličnaté lesy	14250000	10500000	5000000	12750000	15250000
smíšené lesy	3250000	1750000	1750000	3750000	1000000
listnaté lesy	4500000	5000000	9000000	12000000	250000
zástavba	0	0	0	0	250000
mix	7250000	9000000	14000000	2750000	750000
obhospodařovaná půda	5250000	6750000	5500000	4750000	8500000
úhor	0	0	0	0	4750000

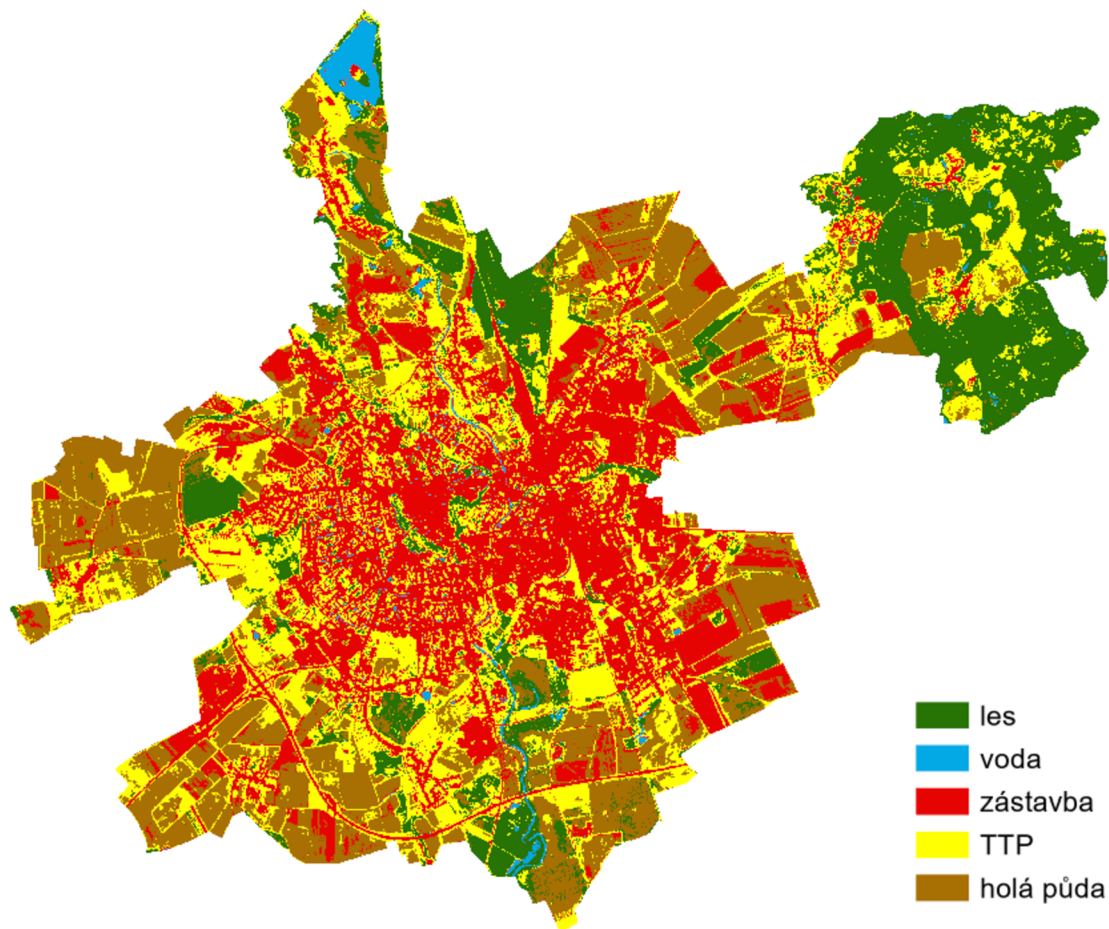
ÚROVEŇ 3 - SENTINEL-2	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
<i>nezařazeno</i>	2000	2000	2000	2000	0
K1	121000	86200	82900	31200	1000
K2.1 + K3	42500	30800	93600	196900	4300
L1 + L2.2 + L2B	170500	217700	125800	134100	391900
L5.4	23100	22300	61500	31400	58100
L7.1	139800	154100	34800	78800	14700
L9.2B	28100	28500	155700	161200	600
M1.5 + M1.7	39700	28900	32800	4600	900
R1.4 + R2.2 + R2.3	72100	65800	29800	29000	6500
T1.1	281400	308100	189700	219500	421200
T1.3	39600	0	117000	90700	29300
T2.3 + T2.3B + T5.5	23700	48500	54800	69500	300
T1.4 + T1.5 + T1.6 + T1.9	67200	62900	81900	16200	123000
V1F + V1G	41300	36200	29700	26900	40200

ÚROVEŇ 3 - LANDSAT 8	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
<i>nezařazeno</i>	0	0	0	0	900
K1	30600	62100	35100	36900	2700
K2.1 + K3	39600	25200	61200	241200	346500
L1 + L2.2 + L2B	205200	198900	106200	81000	54000
L5.4	67500	23400	156600	173700	14400
L7.1	135000	167400	76500	63900	0
L9.2B	5400	9900	22500	17100	0
M1.5 + M1.7	46800	15300	35100	40500	5400
R1.4 + R2.2 + R2.3	50400	54900	34200	41400	409500
T1.1	251100	281700	193500	139500	29700
T1.3	76500	45000	77400	98100	0
T2.3 + T2.3B + T5.5	5400	2700	116100	2700	117900
T1.4 + T1.5 + T1.6 + T1.9	49500	90000	71100	54000	37800
V1F + V1G	55800	42300	33300	28800	1018800

ÚROVEŇ 3 - MODIS	CART	Random Forest	Minimum Distance	Naïve Bayes	referenční vrstva
<i>nezařazeno</i>	0	0	0	0	0
K1	0	0	0	0	0
K2.1 + K3	0	0	0	0	0
L1 + L2.2 + L2B	187500	187500	125000	125000	125000
L5.4	0	0	0	0	0
L7.1	0	0	0	0	0
L9.2B	0	0	0	0	0
M1.5 + M1.7	0	0	0	0	0
R1.4 + R2.2 + R2.3	0	0	0	0	0
T1.1	0	0	0	0	125000
T1.3	62500	62500	125000	125000	0
T2.3 + T2.3B + T5.5	0	0	0	0	0
T1.4 + T1.5 + T1.6 + T1.9	0	0	0	0	0
V1F + V1G	0	0	0	0	0

Příloha 4

Ukázka grafické vizualizace na úrovni 1 snímek Sentinel-2 a pro algoritmus Random Forest na území Olomouce



Příloha 5

Ukázka grafické vizualizace na úrovni 1 snímek Sentinel-2 a pro algoritmus Random Forest na území Černovic u Tábora

