

**Univerzita Karlova**  
**Přírodovědecká fakulta**  
**Katedra aplikované geoinformatiky a kartografie**

Studijní program: Geografie (bakalářské studium)

Studijní obor: Geografie a kartografie



Filip ZADRAŽIL

# KLASIFIKACE LAND COVER CHANGE V ETIOPII POMOCÍ DAT LANDSAT A SENTINEL-2

CLASSIFICATION OF LAND COVER CHANGE IN ETHIOPIA USING  
LANDSAT AND SENTINEL-2 DATA

Bakalářská práce

Vedoucí práce: Mgr. Josef Laštovička, Ph.D.

Praha, 2021

## Zadání bakalářské práce

pro Filipa Zadražila  
obor Geografie a kartografie

Název tématu: Klasifikace land cover change v Etiopii pomocí dat Landsat a Sentinel-2

### Zásady pro vypracování

Práce bude zaměřena na problematiku land cover change s využitím vhodných volně dostupných dat a pokročilých klasifikačních algoritmů. Analyzován bude krajinný pokryv vybraného území Etiopie (regionu). Pro vybrané území bude stanovena detailní land cover klasifikační legenda (přibližně 7 a více kategorií). Práce se zaměří na klasifikace land cover a vyhodnocení změn (land cover change) území pomocí volně dostupných dat mise Landsat a Sentinel-2. Detailně budou testovány a porovnány pokročilé klasifikátory (např. NaiveBayes a Random Forest). Pro užití klasifikátory bude otestováno jejich nastavení a jejich vliv na výsledek/přesnost klasifikace. Pro klasifikaci území bude využito bezoblačných dat, a to buď ve formě vytvořené mozaiky či pomocí analýzy soliterních snímků. Provedeno bude detailní porovnání výstupů jednotlivých testovaných klasifikátorů pro užití datové zdroje. Porovnána budou i data z hlediska temporálního, prostorového a spektrálního rozlišení. Vyhodnoceny budou změny v čase (časové období cca 10 let). Výběr území, klasifikační legenda, volba časových horizontů a validace výsledků bude konzultována a řešena s odborníky z Geologické sekce PřF a odborníky z České geologické služby. Práce je řešena v rámci projektu "Zajištění udržitelného hospodaření v krajině ve vybraných oblastech Etiopie na základě geovědního mapování". Pro řešení práce bude využito volně dostupné výzkumné platformy Google Earth Engine (GEE) nebo desktopových softwarů QGIS, ArcGIS Pro, ArcMap, ENVI, SNAP. Práce bude prezentována pomocí vybrané on-line mapové aplikace (např. AGOL Web Map Builder). K mapovým výstupům bude použit software ArcGIS Pro nebo ArcMap.

### Cíle práce:

1. Porovnání a zhodnocení výstupů klasifikace mozaiky/scén pomocí Random Forest a NaiveBayes (případně Random Forest a jiného vhodně zvoleného klasifikátoru)
2. Otestování parametrizace vybraných klasifikačních algoritmů a vliv této parametrizace na výsledek/přesnost klasifikace
3. Srovnání výsledků klasifikace u volně dostupných dat Landsat a Sentinel-2
4. Vyhodnocení změn land cover (časové období cca 10 let)
5. Sestavení metody / klasifikačního algoritmu ve volně dostupném výzkumném prostředí GEE, případně ve vybrané alternativě
6. Porovnání temporálního, prostorového a spektrálního rozlišení dat Landsat 8 a Sentinel-2 a vlivu těchto aspektů na přesnost klasifikace

**Rozsah průvodní zprávy:** 40 až 50 stran

**Rozsah grafických prací a příloh:** dle potřeby

### Seznam odborné literatury:

Noi Phan, T.; Kuch, V.; Lehnert, L.W. Land cover classification using google earth engine and random forest classifier-the role of image composition. Remote Sens. 2020, 12.

Štych, P.; Jerabkova, B.; Lastovicka, J.; Riedl, M.; Paluba, D. A Comparison of WorldView-2 and Landsat 8 Images for the Classification of Forests Affected by Bark Beetle Outbreaks Using a Support Vector Machine and a Neural Network: A Case Study in the Sumava Mountains. *Geosciences* 2019, 9, 396.

Paluba, D.; Štych, P.; Laštovička, J. Hodnotenie metód a dát DPZ pre účely klasifikácie krajinej pokrývky na príklade bývalých vojenských obvodov Brdy a Ralsko. *Kartogr. List. / Cartogr. Lett.* 2018, 26, 76–90.

Štych, P.; Paluba, D.; Laštovička, J.; Outrata, D.; Hladký, R. Hodnocení změn krajinného pokryvu bývalého vojenského újezdu Brdy pomocí dálkového průzkumu Země. *Bohemia Cent.* 2018, 34, 51–73.

**Vedoucí bakalářské práce:** Mgr. Josef Laštovička, Ph.D.

**Konzultanti:** doc. RNDr. Přemysl Štych, Ph.D. a Mgr. Daniel Paluba

**Datum zadání bakalářské práce:** 12. ledna 2021

**Termín odevzdání bakalářské práce:** květen / červenec 2021

Platnost tohoto zadání je po dobu jednoho akademického roku.

Podpis vedoucího bakalářské práce (Mgr. Josef Laštovička, Ph.D.): .....

Podpis vedoucí katedry (doc. RNDr. Lucie Kupková, Ph.D.): .....

V Praze dne 12. ledna 2021.

## **Prohlášení**

Prohlašuji, že jsem tuto práci zpracoval samostatně s využitím informačních zdrojů a literatury, na které odkazuji. Tato práce ani její podstatná část nebyla předložena k získání stejného nebo jiného akademického titulu.

V Praze dne 29. července 2021

---

Filip Zadražil

## **Poděkování**

Mé největší poděkování patří vedoucímu práce, panu Mgr. Josefu Laštovičkovi, Ph.D., který mi byl velmi nápomocen po celou dobu tvorby této práce a vytrvale mi poskytoval užitečné rady, tipy a informace, které jsem mohl využít pro zkvalitnění jejího obsahu. Dále bych rád poděkoval své rodině, přítelkyni a přátelům za to, že mi po celé tři roky studia byli velkou oporou a vytvářeli příjemné prostředí pro mé studium. V neposlední řadě děkuji i pánům Mgr. Danielu Palubovi a doc. RNDr. Přemyslu Štychovi, Ph.D. za jejich cenné rady a poznatky k práci s užitým softwarem a slečně Bc. Daniele Valchářové za poskytnutá data a konzultace.

## Abstrakt

Tato bakalářská práce je zaměřena na porovnání klasifikátorů Random Forest (RF) a CART na příkladu etiopského regionu Sidama. Pro tento region byla provedena analýza vývoje krajinného pokryvu mezi roky 2014 a 2020. Softwarem využitým ke klasifikaci byla cloudová platforma Google Earth Engine (GEE). Řízená klasifikace byla provedena na snímcích z misí Landsat 8 a Sentinel-2, které byly načteny z datového katalogu Earth Engine. Pro trénovací body byla využita data z in-situ měření, u vstupních dat byla ověřena variabilita v čase pomocí volně dostupných dat v Google Earth Pro. V rámci řešeršní části se práce věnuje metodám a výsledkům výzkumů, které byly prováděny v tématu blízkém této práci. V empirické části se práce věnuje analýze dat Landsat 8 a Sentinel-2, porovnáno bylo temporální, prostorové i spektrální rozlišení. Z hlediska temporálního rozlišení bylo prokázáno, že data Sentinel-2 díky dvěma paralelně snímajícím družicím umožňují snímat až třikrát více snímků pro stejné území v rámci Etiopie. Spektrální a prostorové rozlišení Sentinel-2 umožňuje lépe pozorovat menší a hůře odlišitelné prvky. Data byla následně využita pro klasifikace land cover pomocí klasifikátorů RF a CART v cloud based prostředí GEE. Klasifikátor RF umožnil získat vyšší celkovou přesnost, konkrétně až 82 % u dat Sentinel-2 a 80 % u dat Landsat 8. Klasifikátor RF pak byl využit i pro analýzu změn mezi roky 2014 a 2020 pomocí dat Landsat 8. Naopak klasifikátor CART dosahoval nižší celkové přesnosti pro oba typy družicových dat.

Klíčová slova: vývoj krajinného pokryvu, řízená klasifikace, Random Forest, CART, Google Earth Engine, Landsat 8, Sentinel-2, Sidama

## **Abstract**

This bachelor thesis is focused on the comparison of Random Forest (RF) and CART classifiers on the example of the Ethiopian region of Sidama. An analysis of land cover change between 2014 and 2020 was performed for this region. The cloud-based platform Google Earth Engine (GEE) was used for classifications. Supervised classifications were performed on images from Landsat 8 and Sentinel-2 missions, which were retrieved from the Earth Engine data catalogue. Data from in-situ measurement was used for training polygons, variability of input data over time was verified with Google Earth Pro. In the research part, the work deals with the methods and results of research that were conducted in a topic close to this work. In the empirical part, the work deals with the analysis of Landsat 8 and Sentinel-2 data. The temporal, spatial and spectral resolution were compared. In terms of temporal resolution, it has been shown that Sentinel-2 data allows up to three times more images for the same area thanks to the two satellites scanning in parallel. Spectral and spatial resolution of Sentinel-2 allows better observation of smaller and less distinguishable elements. The data was then used for land cover classifications using RF and CART classifiers in the cloud-based GEE environment. The RF classifier made it possible to obtain higher overall accuracy, up to 82 % for Sentinel-2 data and 80 % for Landsat 8 data. The RF classifier was used to analyse changes between 2014 and 2020 using Landsat 8 data. In contrast with CART whose overall accuracies for both types of satellite data were lower.

**Keywords:** land cover change, supervised classification, Random Forest, CART, Google Earth Engine, Landsat 8, Sentinel-2, Sidama

## Obsah

Seznam zkratk.....	9
Seznam obrázků .....	10
1 Úvod.....	11
2 Rešeršní část.....	12
3 Teoretická část.....	14
3.1 Platforma GEE a klasifikační algoritmy.....	14
3.2 Data Landsat 8 a Sentinel-2.....	16
4 Zájmové území.....	19
5 Metodika.....	21
5.1 Použitá data.....	21
5.2 Metody.....	21
5.2.1 Porovnání prostorového, spektrálního a temporálního rozlišení.....	21
5.2.2 Klasifikace.....	22
5.2.3 Klasifikační legenda.....	23
5.2.4 Změny land cover.....	24
5.3 Softwary.....	24
6 Výsledky.....	25
6.1 Porovnání prostorového, spektrálního a temporálního rozlišení.....	25
6.2 Klasifikace v roce 2020 a 2014 .....	28
6.3 Změny land cover mezi roky 2020 a 2014 z dat Landsat 8.....	32
6.3.1 Webová mapová aplikace.....	34
7 Diskuse .....	35
8 Závěr.....	37
9 Zdroje literatury.....	38
10 Přílohy .....	41



## Seznam zkratek

BOA	Bottom of Atmosphere
BSI	Bare-soil Index
CART	Classification and Regression Tree
CCDC	Continuous Change Detection and Classification
CNES	The National Centre for Space Studies
DEM	Digital Elevation Model
DPZ	Dálkový průzkum Země
DT	Decision tree
ESA	European Space Agency
GBM	Gradient-boosted Machine
GEE	Google Earth Engine
GEP	Google Earth Pro
GPS	Global Positioning System
LaSRC	Land Surface Reflectance Code
LEDAPS	The Landsat Ecosystem Disturbance Adaptive Processing System
L1TP	Level-1 Precision and Terrain
ML	Machine Learning
MMU	Minimal Mapping Unit
MSI	MultiSpectral Instrument
MODIS	The Moderate Resolution Imaging Spectroradiometer
NOAA	National Oceanic and Atmospheric Administration
NASA	The National Aeronautics and Space Administration
NDTI	Normalized Difference Tillage Index
NDVI	Normalized Difference Vegetation Index
NIR	Near Infrared
OLI/TIRS	Operational Land Imager / Thermal Infrared Sensor
OOB	Out-of-bag
RF	Random Forest
RMSE	Root Mean Square Error
SC	Scene Classification
SR	Surface Reflectance
SAVI	Soil-adjusted Vegetation Index
SNNPR	Southern Nation, Nationalities, and People's Region
SVM	Support Vector Machine
SWIR	Short-wave Infrared
S2AC	Sentinel-2 Atmospheric Collection
TOA	Top of Atmosphere
USGS	United States Geological Survey
VNIR	Visible and Near Infrared

## Seznam obrázků

Obr. 1: Schéma klasifikátoru CART na příkladu rozdělení pomerančů a mandarinek.....	14
Obr. 2: Schéma Random Forest .....	15
Obr. 3: Mise Landsat 1-9.....	16
Obr. 4: Generování dat Landsat 7 až 9, Collection 2 .....	17
Obr. 5: Poloha Sidamy v rámci Etiopie.....	20
Obr. 6: Porovnání prostorového rozlišení dvou kompozitů Landsat 8 a Sentinel-2 .....	26
Obr. 7: Porovnání prostorového rozlišení dvou oblačných snímků Landsat 8 a Sentinel-2 ....	27
Obr. 8: Klasifikace území Sidama pomocí RF a dat Sentinel-2 v roce 2020 (a), RF a dat Landsat 8 v roce 2020 (b), CART a dat Sentinel-2 v roce 2020 (c), CART a dat Landsat 8 v roce 2020 (d), RF a dat Landsat 8 v roce 2014 (e), ESRI World Imagery (f).....	29
Obr. 9: Ukázka změn land cover na území Sidama mezi roky 2014 a 2020.....	33

## Seznam tabulek

Tab. 1: Porovnání Sentinel-2 L2A a Landsat 8 SR Collection 2 Tier 1.....	18
Tab. 2: Počet trénovacích bodů v jednotlivých datových sadách.....	22
Tab. 3: Porovnání temporálního rozlišení dat Landsat 8 a Sentinel-2 .....	27
Tab. 4: Otestovaná nastavení klasifikátoru RF .....	28
Tab. 5: Otestovaná nastavení klasifikátoru CART.....	28
Tab. 6: Chybová matice s výsledky klasifikace RF s daty Sentinel-2 v roce 2020.....	30
Tab. 7: Chybová matice s výsledky klasifikace CART s daty Sentinel-2 v roce 2020.....	31
Tab. 8: Chybová matice s výsledky klasifikace RF s daty Landsat 8 v roce 2014 .....	31
Tab. 9: Chybová matice s výsledky klasifikace RF s daty Landsat 8 v roce 2020 .....	32
Tab. 10: Chybová matice s výsledky klasifikace CART s daty Landsat 8 v roce 2020.....	32
Tab. 11: Porovnání vývoje jednotlivých kategorií .....	33

## Seznam grafů

Graf 1: Spektrální charakteristiky in-situ měření pro Sentinel-2 v roce 2020 .....	25
Graf 2: Spektrální charakteristiky in-situ měření pro Landsat 8 v roce 2020 .....	25
Graf 3: Spektrální charakteristiky in-situ měření pro Landsat 8 v roce 2014.....	26
Graf 4: Porovnání temporálního rozlišení dat Landsat 8 a Sentinel-2 .....	28

# 1 Úvod

Úvodem je třeba zdůraznit, že především díky rozvoji moderních technologií nabízí v dnešní době dálkový průzkum Země (DPZ, angl. Earth Observation / Remote Sensing) detailnější a přesnější informace stále širší populaci. Tato poměrně mladá vědní disciplína, která nám pomáhá poznávat a analyzovat svět kolem nás, se neustále vyvíjí a posouvá své hranice možností. Vzhledem k tomu, že se DPZ úzce dotýká rozsáhlé škály ostatních vědních oborů, je důležité jí věnovat patřičnou pozornost a využívat jejích možností v maximálním možném měřítku.

Velkou inovací v současné oblasti DPZ je volně dostupná platforma Google Earth Engine (GEE), která vědeckým pracovníkům umožňuje zefektivnění a zrychlení analýz zkoumaného území. Výsadou tohoto softwaru, který využívá programovacích jazyků Python a JavaScript, je obsáhlá databáze volně dostupných satelitních snímků, např. mise Landsat a Sentinel-2. V posledních letech nabývá GEE na významu a využívá se například pro detailní a rozsáhlá pozorování změn naší krajiny v případech, kde je časově náročné využívat desktopových platforem.

Hlavním cílem této práce je pozorování změn land cover v čase pomocí vhodných volně dostupných dat a pokročilých klasifikačních algoritmů. Zájmovou oblast představuje etiopský region Sidama v horizontu posledních deseti let. Práce je zaměřena na pokročilé klasifikace land cover a vyhodnocení změn ve zkoumaném území pomocí dat misí Landsat a Sentinel-2.

Seznam dílčích cílů této bakalářské práce je uveden níže:

1. Porovnání a zhodnocení výstupů klasifikace kompozitu pomocí Random Forest a CART
2. Otestování parametrizace vybraných klasifikačních algoritmů a vliv této parametrizace na výsledek/přesnost klasifikace
3. Srovnání výsledků klasifikace u volně dostupných dat Landsat 8 a Sentinel-2
4. Vyhodnocení změn land cover pomocí dat Landsat 8
5. Sestavení metody/klasifikačního algoritmu ve volně dostupném výzkumném prostředí GEE, případně ve vybrané alternativě
6. Porovnání temporálního, prostorového a spektrálního rozlišení dat Landsat 8 a Sentinel-2 a vlivu těchto aspektů na přesnost klasifikace

## 2 Rešeršní část

Informace o krajinném pokryvu hrají důležitou roli v mnoha odvětvích lidské činnosti (např. v územním plánování, urbanismu, pozorování urbanizačních a sub-urbanizačních procesů a dalších oblastech). Proto jsou přesné a včasné informace o land cover velmi žádané (Noi Phan, Kuch, Lehnert 2020). „Ačkoli lze změny land use a land cover sledovat pomocí tradičních inventarizací a průzkumů, dálkový průzkum Země poskytuje větší množství informací o geografickém rozložení využití území a jeho změnách, spolu s výhodami úspory nákladů a času i pro územně větší oblasti“ (Yuan a kol. 2005, str. 317-318). Yuan a kol. (2005) považují data z dálkového průzkumu Země za významný zdroj informací pro kvantifikaci změn krajiny a pro pochopení podstaty změn a vývoje land cover. Tyto informace jsou podle nich nezbytné pro plánování nejen městského růstu a rozvoje. Další odvětví, které hojně využívá dálkový průzkum Země je například i zemědělství nebo ekologie.

I proto získala v poslední době velkou pozornost při land cover klasifikacích cloudová výpočetní platforma Google Earth Engine (Noi Phan, Kuch, Lehnert 2020; Zurqani a kol. 2018), umožňující rychlý přístup k předzpracovaným datům a také přístup k výkonnému serveru či superpočítači pomocí rozhraní internetového prohlížeče). Rovněž užití metod strojového učení, např. klasifikátoru Random Forest má své logické opodstatnění. Jedná se totiž o jeden z nejpoužívanějších algoritmů pro klasifikaci krajinného pokryvu (Noi Phan, Kuch, Lehnert 2020).

Noi Phan, Kuch, Lehnert (2020) i Zurqani a kol. (2018) shodně kvitují, že Google Earth Engine platforma usnadňuje práci s datovými sadami a poskytuje družicová data s vysokým rozlišením, které lze využít ke klasifikaci a efektivně tak detekovat změny ve využívání půdy, vegetace, vodních ploch apod. Významnou devizou této platformy je poskytnutí výzkumníkům bohaté sady předzpracovaných multispektrálních optických dat, například mise Landsat (data Landsat 4, 5, 7 a 8) a Copernicus (data Sentinel-2), čímž značně usnadňuje mnohdy zdoluhavou přípravu, výběr a předzpracování dat. Zároveň data disponují vysokým temporálním, prostorovým i spektrálním rozlišením. Všechny tři autorské skupiny rovněž potvrzují, že pomocí snímků Landsat, v kombinaci například se snímky Sentinel-2, lze analyzovat vývoj land cover s vysokou přesností, a to od lokálních území, jakou je metropolitní oblast Minneapolis-Saint Paul (Yuan a kol. 2005) až po rozsáhlé regiony či státy, jakým je Mongolsko (Yuan a kol. 2005; Zurqani a kol. 2018; Noi Phan, Kuch, Lehnert 2020). Ang a kol. (2021) však upozorňují na fakt, že čím starší snímky k analýze používáme, tím se přesnost klasifikace zpravidla snižuje. Apelují také na důležitost údajů o trénovacích bodech z in-situ měření, které mohou přesnost naopak zvýšit.

Hlavním problémem při mapování krajinného pokryvu je výběr klasifikátoru (Heydari, Mountrakis 2018). Zurqani a kol. (2018) a Noi Phan, Kuch, Lehnert (2020) využívají pro svůj výzkum Random Forest. Podle Noi Phan, Kuch, Lehnert (2020) patří mezi hlavní výhody tohoto klasifikátoru mj. vysoký výkon při práci s multi-source datovými sadami, vyšší přesnost oproti jiným klasifikátorům či zvýšení rychlosti zpracování díky parametrizaci vstupních proměnných (např. množství iterací nebo počet trees a úrovní trees). I díky tomu přesahuje u všech tří výzkumů celková přesnost klasifikace hodnotu 75 %, což lze považovat za uspokojivý výsledek. Noi Phan a Kappas (2017) dokonce v rámci svého výzkumu porovnávají Random Forest na snímcích Sentinel-2 s ostatními užívanými klasifikátory. Při použití několika různých vzorků se přesnost klasifikace u RF pohybovala zhruba mezi hodnotami 91 a 95 %, což byl hned po klasifikátoru Support Vector Machine nejlepší výsledek. Mírně odlišnými výsledky disponuje výzkum Ang a kol. (2021), kteří se věnovali změně struktury krajiny v oblasti zlatomědného dolu Didipio na Filipínách. Ti svůj vzorek trénovacích dat z roku 2010 nechali otestovat na všech klasifikačních algoritmech, které GEE nabízí k použití. V tomto testu

si nejlépe vedl klasifikátor RF (hodnocení přesnosti klasifikace 96 %), a naopak SVM obsadil s přesností klasifikace kolem 76 % zcela s přehledem poslední, šestou příčku. Naive Bayes byl hodnocen jako čtvrtý nejlepší z celkových n pozorovaných klasifikátorů s přesností 86 %. Noi Phan a Kappas (2017) také doporučují, aby při klasifikaci krajinného pokryvu pomocí snímků dálkového průzkumu Země a algoritmů strojového učení představovala velikost tréninkového vzorku přibližně 0,25 % z celkové studijní oblasti.

Z vybraných článků je důležité vyzdvihnout práci Ang a kol. (2021), kteří běžně dosahovali celkové přesnosti klasifikace přes 95 %. Velkou zásluhu na tom má dle samotných autorů mj. důkladná komunikace s místními odborníky ohledně vývoje land cover v pozorované lokalitě. Zurqani a kol. (2018) představili studii zaměřenou na hodnocení zalesňování a odlesňování ve sledovaném území. Všechny čtyři skupiny autorů (Ang a kol. 2021; Noi Phan, Kuch, Lehnert 2020; Zurqani a kol. 2018; Yuan a kol. 2005) se pak shodně zaměřili na podrobnou interpretaci zjištěných výsledků a statistické zhodnocení zkoumaných lokalit. Velmi důležitá je rovněž celková přesnost klasifikací, kde velkou roli hrála kvalita vstupních dat.

Dalším řešeným problémem klasifikací je i výběr vhodných dat ke klasifikaci. Tento problém je možné řešit z hlediska prostorového, spektrálního / radiometrického či temporálního. V dnešní době lze využívat volně dostupných dat Sentinel-2 nebo Landsat, které umožňují využívat vysoké prostorové rozlišení (Štych a kol. 2018; Paluba, Štych, Laštovička 2018). Štych a kol. (2019) se zabývají též zpracováním komerčních dat s velmi vysokým rozlišením WorldView-2, které pomocí klasifikátorů Neural Network a Support Vector Machine využívají k detailním pokročilým klasifikacím. Tato komerční data pak porovnávají i s volně dostupnými daty Landsat 8, kde Štych a kol. potvrzují výhody vyššího prostorového rozlišení, které se projevuje až na 15 % celkové přesnosti klasifikace, i přes menší počet spektrálních pásem. Laštovička a kol. (2020) se pak věnují detailním analýzám dat Landsat 8 a Sentinel-2. Data porovnávají z hlediska temporálního a prostorového rozlišení pro vybrané lokality v Česku (Šumava) a na Slovensku (Nízké Tatry). Na základě analýz dostupných snímků potvrzují, že mise Sentinel-2 využívající paralelní snímání dvou družic Sentinel-2A a Sentinel-2B mají až dvojnásobné množství dostupných snímků, což může mít vliv na tvorbu bezoblačné mozaiky nebo kompozitu při klasifikaci. Vliv spektrálního rozlišení a možnost využívat red edge pásem Sentinel-2 k detailnějšímu zkoumání vegetace v porovnání s daty Landsat 8 zmiňuje i Laštovička (2020).

Změny krajiny v čase lze z hlediska klasifikací pojmout z více pohledů. První z nich představuje problematiku časových řad klasifikovaných družicových snímků, kterými se ve své disertační práci zabývá Laštovička (2020). Druhým pohledem mohou být change detection metody. Mezi nejčastěji užívané můžeme zařadit metodu CCDC (Continuous Change Detection and Classification), která se postupně stává součástí mnoha knihoven, pluginů, softwarů či předních cloud based platform, mimo jiné bylo CCDC aplikováno Arévalo a kol. (2020) v GEE. Poslední možností je hodnocení land cover change (např. Štych a kol. 2018). Metody land cover change prozatím nejsou implementovány přímo do cloud based platform, jako je GEE nebo Sentinel Hub, na rozdíl od desktopových platform pro GIS. Nicméně se vícero autorů pokusilo o implementaci těchto metod do GEE, např. Nyland a kol. (2018).

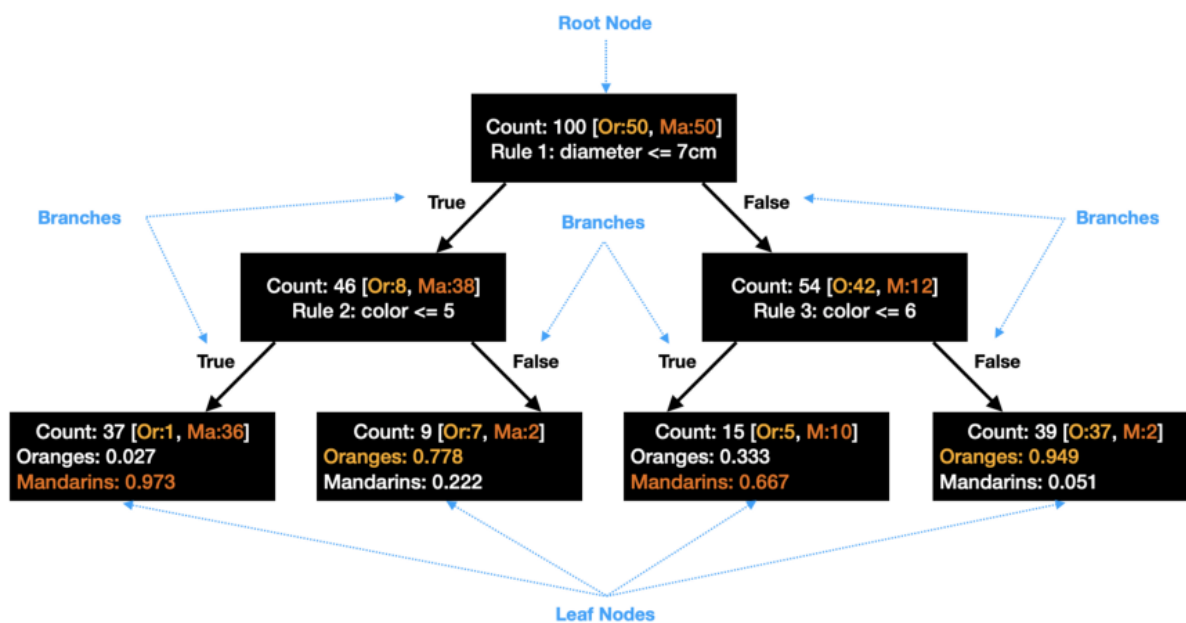
### 3 Teoretická část

#### 3.1 Platforma GEE a klasifikační algoritmy

Platforma GEE nabízí výkonné funkce pro zpracování velkého množství snímků dálkového průzkumu Země, které lze použít například pro účely detailní analýzy krajiny. Kromě velkého množství satelitních snímků poskytuje GEE také sadu nejmodernějších metod DPZ, např. moderních ML (machine learning) klasifikátorů (Shelestov a kol. 2017). K dispozici jsou i klasifikátory pro neřízenou klasifikaci nebo i pro sub-pixelovou (spectral unmixing metody) či objektovou klasifikaci (object based metody). Tato práce je zaměřena zejména na metody řízené pixelové klasifikace, jejichž v GEE dostupné klasifikátory si nyní představíme.

Support Vector Machine je jedním z nejčastěji používaných klasifikátorů v oblasti DPZ (Shetty 2019). Řadí se mezi neparametrické statistické metody strojového učení s dozorem (Kulkarni, Lowe 2016; Mountrakis, Im, Ogole 2011). SVM se primárně zaměřuje na tréninkové vzorky, které jsou v prostoru funkcí nejbližší optimální hranici mezi třídami (Maxwell, Warner, Fang 2018; Mountrakis, Im, Ogole 2011). Těmto vzorkům se říká tzv. podpůrné vektory, od čehož je odvozen samotný název metody. Cílem SVM je najít optimální hranici, která maximalizuje rozdělení nebo okraj mezi podpůrnými vektory (Maxwell, Warner, Fang 2018). SVM byly původně navrženy k identifikaci hranice lineární třídy (tzv. nadroviny). Ta odděluje datovou sadu do diskrétního předdefinovaného počtu tříd způsobem, který je konzistentní s příklady z tréninku (Mountrakis, Im, Ogole 2011). SVM se skládá z několika hyperparametrů: kernel type, gamma value a penalty value. Tyto hyperparametry lze vyladit a upravit tak, aby zlepšily výkon SVM při klasifikaci snímků (Mountrakis, Im, Ogole 2011).

Obr. 1: Schéma klasifikátoru CART na příkladu rozdělení pomerančů a mandarinek



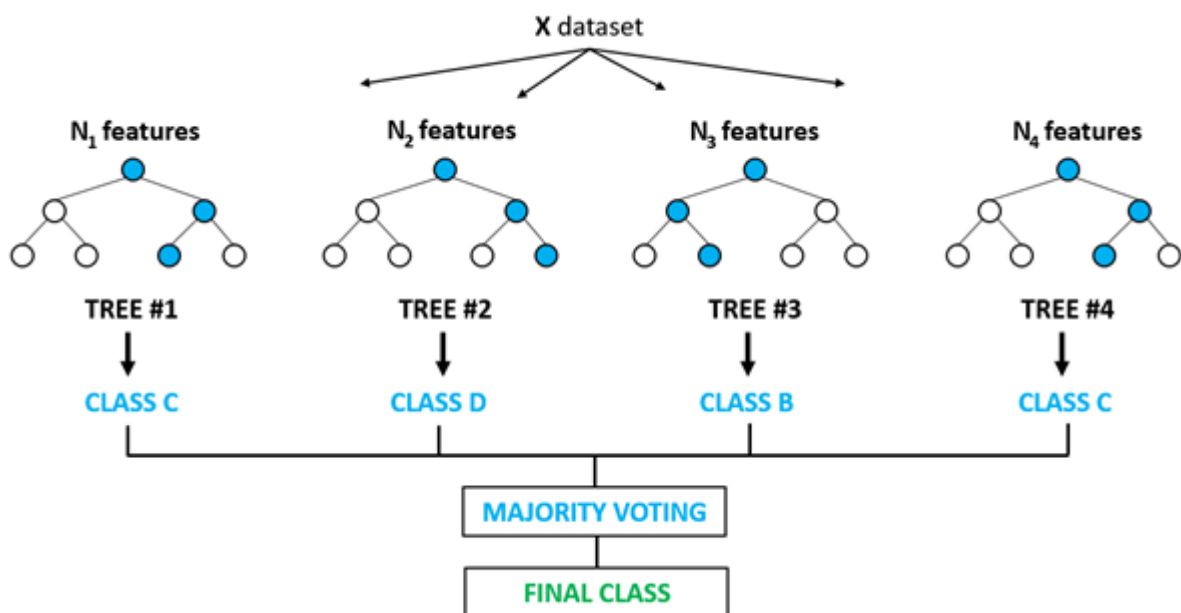
zdroj: Dobilas (2021)

Classification and Regression Tree (CART) je typ algoritmu strojového učení s dozorem, který tvoří binární rozhodovací strom (viz Obr. 1). Zahrnuje identifikaci a konstrukci stromu pomocí trénovacích vzorků, pro které není známa správná klasifikace (Shaharum a kol. 2020). Rozhodovací strom začíná kořenovým uzlem odvozeným z jakékoli proměnné v prostoru funkcí a minimalizuje míru nečistoty dvou sourozeneckých uzlů. Poté DT roste pomocí

postupných dělení, dokud nedosáhne fáze, kdy nedojde k významnému snížení míry nečistoty při provádění dalšího dělení (Shaharum a kol. 2020). Jeho kritériem je normalizovaný zisk informací, který je výsledkem výběru atributu pro rozdělení dat. Pro rozhodnutí o rozdělení je vybrán atribut s nejvyšším normalizovaným ziskem informací. Algoritmus se poté opakuje u menších sublistů (Shelestov a kol. 2017). Jednou z nevýhod tohoto klasifikátoru je značná citlivost na tréninkovou datovou sadu, takže malá změna tréninkových dat může vyústit ve velmi odlišné uspořádání podmnožin (Shelestov a kol. 2017; Bishop 2006). V prostředí GEE jsou parametry tohoto klasifikátoru označovány jako maxNodes a minLeafPopulation. MaxNodes značí maximální počet uzlů v každém stromě. MinLeafPopulation je parametr pro označení minimálního počtu tréninkových bodů, pro něž ještě klasifikátor vytváří uzly. Přednastavené neboli defaultní hodnoty jsou v případě CARTu nastaveny na hodnoty null (bez limitu) a 1 (GEE 2021b).

Random Forest je klasifikátor souborového učení (angl. ensemble learning), který produkuje několik decision trees pomocí náhodně vybrané podmnožiny tréninkových vzorků a proměnných (Belgiu, Drăguț 2016). V klasifikačním režimu je přiřazení třídy dosaženo hlasováním (viz Obr. 2), tzn. třída s největším počtem hlasů z klasifikačních stromů je třída přiřazená k predikci. Filozofie třídících souborů je založena na základním předpokladu, že sada klasifikátorů provádí lepší klasifikace než individuální klasifikátor (Rodriguez-Galiano a kol. 2012). Breiman (2001) představil RF algoritmus pro seskupení více DT, z nichž jsou rozdělující proměnné náhodně vybranými podmnožinami funkcí s „bagovanými“ vzorky. Zbývající instance nevybrané pro trénink, označované jako vzorky out-of-bag (OOB), se používají pro testování modelu pomocí křížové validace (Zhang, Yang 2020). Tyto OOB vzorky tvoří zhruba třetinu z původní datové sady (Collins a kol. 2020). Počet stromů v RF (ntree) a počet proměnných uvažovaných v každém uzlu ve stromu (mtry) jsou definovány uživatelem (Obr. 2). Klasifikátor RF se stal populárním v komunitě dálkového průzkumu Země hlavně díky přesnosti jeho klasifikací (Belgiu, Drăguț 2016).

Obr. 2: Schéma Random Forest



zdroj: Spiro (2020)

Bayesův klasifikátor pracuje na základě jednoduchého pravděpodobnostního přístupu, který je založen na Bayesově teorému a předpokladu nezávislosti mezi vstupními funkcemi.


Hlavní výhodou tohoto klasifikátoru je, že pro výpočet rozhodovací plochy vyžaduje malý počet tréninkových dat (Shelestov a kol. 2017). Jeho odvození je však podmíněno předpokladem, že podkladová data mají Gaussovo rozdělení, což může omezit oblast jeho použití (Shelestov a kol. 2017). V rámci GEE se pak setkáváme s NaiveBayes klasifikátorem, který je typem Bayesovského klasifikátoru.

Mezi další klasifikátory využitelné v prostředí GEE patří také GMO Max Entropy, MultiClassPerceptron, Intersection Kernel Passive Aggressive Method for Information Retrieval (IKPamir), Winnow či Primal Estimated sub-GrADient SOLver for Svm (Pegasos). Ty však nejsou mezi výzkumníky z oblasti DPZ příliš využívané.

### 3.2 Data Landsat 8 a Sentinel-2 v prostředí Google Earth Engine

Platforma GEE nabízí k dispozici celou řadu volně dostupných dat. Obecně je lze rozdělit do několika tematických skupin. První skupinu tvoří klimatická data a data o počasí. Jedná se například o data z družic NOAA (National Oceanic and Atmospheric Administration) či nejrůznější atmosférické modely např. od NASA (The National Aeronautics and Space Administration), vytvořené z dat MODIS (The Moderate Resolution Imaging Spectroradiometer). Druhou skupinu tvoří geofyzikální data (poskytující informace o DEM, například z dat SRTM) a třetí skupinu pak tvoří obrazové snímky, kde máme k dispozici data mise Landsat, Sentinel, MODIS a snímky s velmi vysokým rozlišením (např. The US National Agriculture Imagery Program) (GEE 2021a). V rámci této práce se detailně zaměříme na optická multispektrální data Landsat 8 a Sentinel-2, která si nyní blíže představíme.

Obr. 3: Mise Landsat 1-9

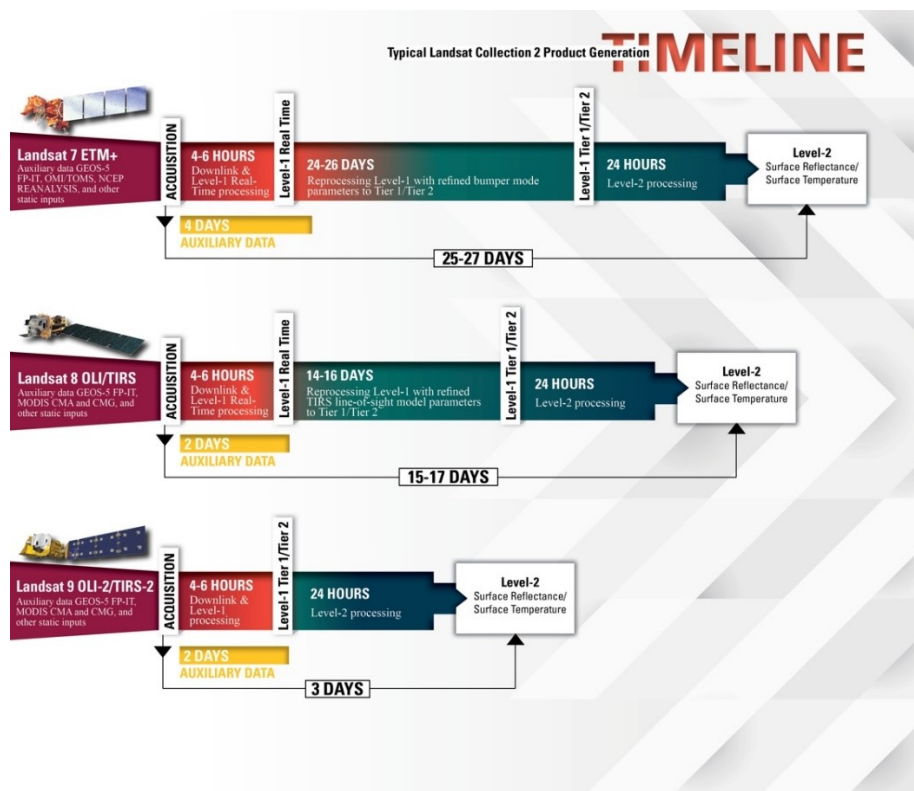


zdroj: (USGS 2021d)



Mise Landsat představuje nejstarší kontinuální vesmírnou misi od roku 1972. K dispozici máme data mise Landsat 1, 2, 3, 4, 5, 7 a 8. V současné době je připravována i mise Landsat 9 (Obr. 3). Poskytovatelem dat je USGS (United States Geological Survey) a NASA. Data jsou poskytována ve dvou kolekcích, konkrétně v Collection 1 a Collection 2. Obě kolekce se liší způsobem distribuce a metodami předzpracování dat. Data Collection 1 představují starší způsob distribuce dat po Level 1. U dat Collection 1 je nutné o získání SR snímků (Surface Reflectance), tedy snímků úrovně předzpracování Level 2 (data s radiometrickými / atmosférickými korekcemi), žádat (data jsou k dispozici tzv. on demand). Výhodou této metody je využití nejnovějšího algoritmu LEDAPS (pro Landsat 4-7) či LaSRC (pro Landsat 8) pro zpracování radiometrických korekcí (USGS 2021b). Tyto radiometrické / atmosférické korekce jsou plně automatizovány. Po zažádání o data je nutné vyčkat na zpracování procesu přípravy dat serverem a k vytvoření dat je využito dat úrovně Level 1 (USGS 2021a). Novější přístup představují data Collection 2, která již nejsou k dispozici na žádost. Data jsou nově dopředu předzpracována a připravena rovnou ke stažení. Opět se jedná o produkty Level 1 a Level 2 (USGS 2021c). Ukázkou časové náročnosti předzpracování je možno vidět na Obr. 4, zpracování trvá od 15 do 27 dní v závislosti na družici. Revoluci by měla představovat nově přichozí mise, která bude mít předzpracovaná volně dostupná data v časovém intervalu do 3 dnů. Snímky v Collection 2 jsou na rozdíl od předchozí verze poskytovány v scénách, nikoliv již tedy v dlaždicích. V Collection 2 máme k dispozici dvě úrovně zpracování tzv. data Tier 1 a Tier 2. Data Tier 1 poskytují nejvyšší možnou kvalitu, ideální pro časové analýzy (USGS 2021b). Jedná se o data s velmi přesnými geometrickými korekcemi L1TP (Level-1 Precision and Terrain), kde radiální RMSE nepřesahuje 12 m. Data Tier 2 mají k dispozici pouze jednodušší korekci terénu (USGS 2021b). Součástí úrovně Level-2 je pomocí algoritmu Fmask generovaná maska oblačnosti, stínů, sněhu a dalších prvků.

Obr. 4: Generování dat Landsat 7 až 9, Collection 2



zdroj: (USGS 2021b)

Data Sentinel-2 jsou poskytována v rámci programu Copernicus společností ESA. Součástí mise Copernicus jsou satelity Sentinel-1A/B (radarová data), Sentinel-2A/B (multispektrální optická data), Sentinel-3A/B (pro pozorování topografie, teplot oceánu a zemského povrchu, zkoumání počasí a klimatu), Sentinel-4 a Sentinel-5 (obě pro pozorování složení atmosféry). Tato bakalářská práce je pak zaměřena na multispektrální optická data Sentinel-2, která jsou poskytována od roku 2015. Data jsou k dispozici ve 2 úrovních předzpracování (obdobně jako u dat Landsat). Konkrétně se jedná o Level-1C a Level-2A. Level-1C představuje data TOA (Top of Atmosphere) reflectance, tedy odrazivost na horní hranici atmosféry. Naopak data Level-2A představují předzpracování BOA (Bottom of Atmosphere) reflectance, které jsou obdobou SR / Level 2 dat mise Landsat. Velkou výhodou programu Copernicus je párové snímání u většiny misí družic. Úroveň 2A může být také generována uživatelem z produktu úrovně 1C pomocí Sentinel-2 Toolbox nebo samostatně pomocí algoritmu Sen2Cor. Celkové zpracování úrovně 2A je rozděleno na dvě části. Cílem klasifikace scén (SC) je vytvořit mapu klasifikace pixelů (oblaky, stíny oblaků, vegetace, půdy, pouště, voda, sníh atd.). Následuje atmosférická korekce (S2AC), která si klade za cíl transformovat odrazivost TOA na odrazivost BOA. Algoritmy úrovně 2A byly vyvinuty společností DLR / Telespazio.

Porovnání vlastností obou typů dat Sentinel-2 L2A a Landsat 8 SR je možné vidět v Tabulce 1. Datová sada Landsat je atmosféricky korigovaná povrchová odrazivost senzorů Landsat 8 OLI / TIRS. Tyto snímky obsahují 5 viditelných a blízkých infračervených pásem (VNIR), 2 krátkovlnná infračervená pásma (SWIR) a dvě termální infračervená pásma (TIR). Prostorové rozlišení těchto snímků je 30 m, respektive 100 m u termálních pásem a 15 m u panchromatického pásma. V této datové sadě lze nalézt snímky od dubna 2013 až po současnost (květen 2021). Dataset Sentinel-2 MSI Level-2A poskytuje snímky zemského povrchu v úrovni L2A od března 2017 a mladší. Celosvětového pokrytí však bylo dosaženo až u snímků od prosince 2018 (COPERNICUS 2019). Datová sada se skládá z 13 spektrálních pásem s rozlišením od 10 m do 60 m.

Tab. 1: Porovnání Sentinel-2 L2A a Landsat 8 SR Collection 2 Tier 1

Mise	Radiometrické rozlišení	Temporální rozlišení	Spektrální pásmo	Coastal/Aerosol	Blue	Green	Red	NIR 2	NIR 3	NIR 4	NIR 1	NIR 5	Atmospheric/			Datum			
													Water Vapour	Cirrus	Panchromatic		SWIR 1	SWIR 2	
Landsat 8	12bit (16bit přeškálováno) GeoTIFF	16 dní	Střední vlnová délka (nm)	443,0	482,0	561,4	654,6	-	-	-	864,7	-	-	1373,4	1373,4	1608,9	2200,7	11. února 2013 (aktivní)	
			Šířka pásma (nm)	16	60	57	37	-	-	-	28	-	-	-	20	172	85		187
			Prostorové rozlišení (m)	30	30	30	30	-	-	-	30	-	-	-	30	15	30		30
Sentinel-2A	12bit JPEG 2000	10 dní	Střední vlnová délka (nm)	443,9	496,6	560	664,5	703,9	740,2	782,5	835,1	864,8	945	1373,5	-	1613,7	2202,4	23. června 2015 (aktivní)	
			Šířka pásma (nm)	27	98	45	38	19	18	28	145	33	26	75	-	143	242		
			Prostorové rozlišení (m)	60	10	10	10	20	20	20	10	20	60	60	-	20	20		
Sentinel-2B			Střední vlnová délka (nm)	442,3	492,1	559	665	703,8	739,1	779,7	833	864	943,2	1376,9	-	1610,4	2185,7	7. března 2017 (aktivní)	
			Šířka pásma (nm)	45	98	46	39	20	18	28	133	32	27	76	-	141	238		
			Prostorové rozlišení (m)	60	10	10	10	20	20	20	10	20	60	60	-	20	20		

zdroj: NASA (2021b), ESA (2021) a Laštovička a kol. 2020 / vlastní zpracování

## 4 Zájmové území

Zkoumaný region Sidama je území ve středojižní Etiopii (viz Obr. 5) o rozloze 6 878 km<sup>2</sup>. Od 18. června 2020 je zároveň jedním ze svazových států Etiopie. Stalo se tak poté, co se region na základě referenda odtrhl od Státu jižních národů, národností a lidu (SNNPR), což je další etiopská správní jednotka na jihozápadě země (Paravicini 2019). Sidama se dále dělí na 19 distriktů, místně zvaných „woredas“. Hlavním a největším městem regionu je Awasa s 320 tisíci obyvateli, které je prozatím hlavním městem i pro SNNPR.

Sidama se rozkládá kolem šestého stupně severní zeměpisné šířky a mezi 38. a 39. poledníkem východní délky. Na západě a jihozápadě sousedí s regionem SNNPR, ale většina její hranice sousedí s nejrozlehlejší svazovým státem – Oromií. Mezi významné fyzickogeografické prvky patří jezera Awasa na severu a Abaya na jihu. Mezi největší řeky patří Bilate a Genale. Velká východoafrická příkopová propadlina fakticky rozkládá území Sidamy na dvě části – západní nížiny a východní vysočiny. Charakteristika těchto oblastí se tedy značně odlišuje. Na jedné straně tu nalezneme oblast horských vrchovin, které pokrývají zhruba 16 % celkové plochy země a mají nadmořskou výšku mezi 2 500 m a 3 500 m. Tato část země má nejvyšší množství srážek v rozmezí od 1 600 mm do 2 000 mm a průměrnou roční teplotu mezi 15 a 20 °C. Nachází se zde však rovněž horké klimatické pásmo, které pokrývá 30% celkové plochy. Jeho nadmořská výška se pohybuje od 500 do 1 500 m. Zde lze naměřit průměrné roční srážky kolem 600 mm a průměrná roční teplota osciluje mezi 20 a 25 °C (SDC 2000).

Dle orální historie sahá počátek Sidamů, jakožto obyvatel oblasti Sidama, do prvního století našeho letopočtu, kdy v Africe probíhala migrace národů ze Severní a Východní Afriky směrem na jih. Skupiny Sidamů se postupně rozptýlily na území od současné Sidamy po řeku Dawa na etiopsko-keňské hranici, aby se poté v průběhu dějin postupně navrátili zpět na původní území Sidamy, které se zachovalo dodnes (Kumo 2013). Sidamský lid zde zřídil nezávislý národní stát, který toto úrodné území po staletí obhospodařoval a stabilně poskytoval svým příslušníkům dobrou životní úroveň. Zlom nastal v roce 1891, kdy byl tento stát připojen králem Minelikem II. k dnešní Etiopii. Touto anexí tak zanikly i specifické politické a socioekonomické systémy, které zde do té doby fungovaly (Kumo 2013).

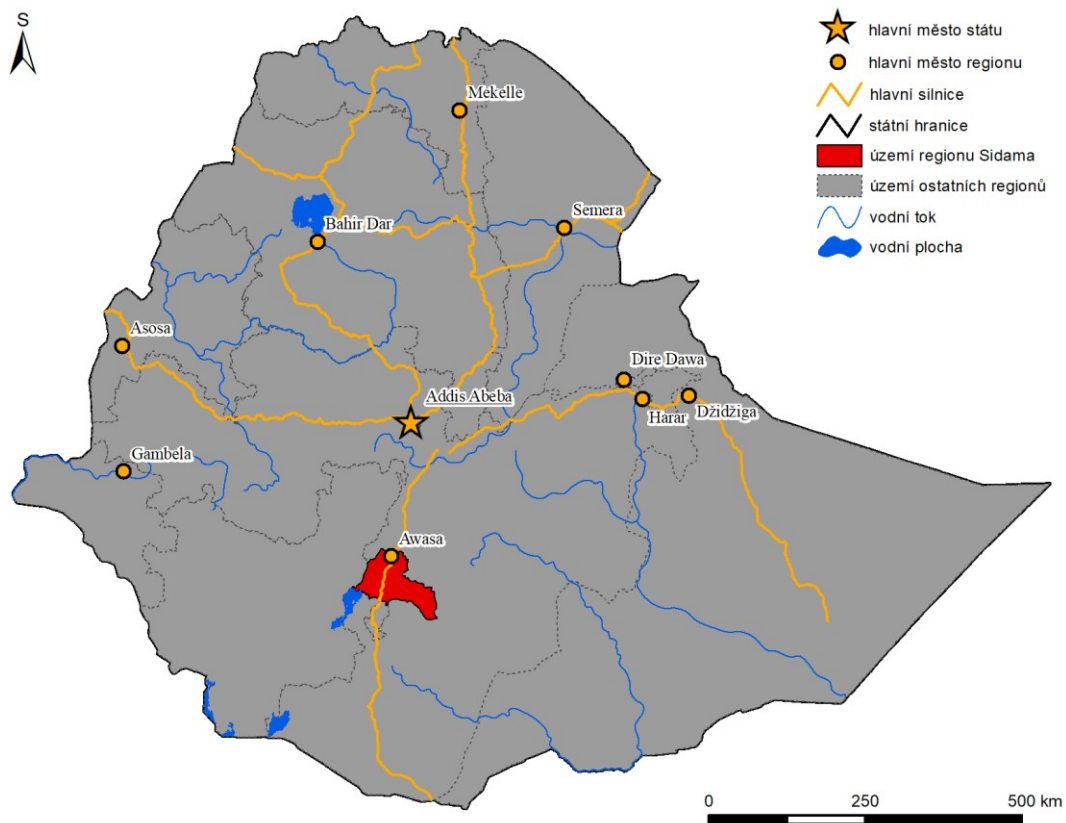
Dalším významným milníkem historie Sidamy je již zmiňované referendum o vytvoření vlastního svazového státu. Tomu předcházela tlak ze strany sidamského lidu na etiopskou vládu, který na základě jistých sociokulturních, jazykových a ekonomických důvodů žádal odtržení od SNNPR. Etiopská vláda Sidamům v srpnu 2019 vyhověla a ti tak díky 98,5 % hlasů rozhodli v listopadu téhož roku o své samostatnosti (Paravicini 2019).

Sidama je s hustotou osídlení přes 533 obyv./km<sup>2</sup> jednou z nejhustěji osídlených oblastí v Etiopii. Celková míra plodnosti zde v roce 2018 dosahovala hodnoty 2,9 dětí na jednu ženu. Hrubá míra porodnosti byla 22,8 ‰ a hrubá míra úmrtnosti 5,2‰ (Areru a kol. 2020). Tyto hodnoty jsou oproti etiopskému průměru nižší, neboť Sidama patří mezi vyspělejší regiony. Obyvatele regionu tvoří z 93 % Sidamové, 2,5 % Oromové a 1,9 % Amharové. Zbýlých 2,6 % tvoří menší etnika. Hlavním jazykem oblasti je sidamština, kterou hovoří jako svým prvním jazykem 94,2 % obyvatel. Dalšími jazyky jsou pak amharština a oromština. Zatímco amharština jako etiopský úřední jazyk patří mezi semitské jazyky, sidamština a oromština spadají do kušitské jazykové větve, která je typická převážně pro východní Afriku (CSA 2010).

Ekonomika v Sidamě je založena na samozásobitelském zemědělství prováděném pomocí zastaralých výrobních technik. Většinu obyvatelstva tedy tvoří farmáři pěstující plodiny. Bohatší z nich zároveň chovají i dobytek. Typickou plodinou tohoto regionu je káva, která je také hlavním vývozním artiklem. Export této komodity však není prováděn příliš efektivně, a tudíž jsou jakékoli nepříznivé faktory spojené s pěstováním kávy pro místní farmáře stěžejní. Ať už se jedná o kolísající cenu kávy ve světě nebo například špatné přírodní

podmínky v průběhu roku. I z toho důvodu se Sidamě, potažmo celé Etiopii, nevyhýbá hladomor, který však v Sidamě nemá zásadní vliv na fungování ekonomiky či společenského života (Kumo 2013). Přesto se v oblasti rozšířilo pěstování dalších plodin, které jsou odolné, nenáročné na pěstování a pomáhají hladomoru předcházet. Netypičtější z nich je banánovník habešský, jinak také zvaný falešný banánovník. Tato rostlina může sloužit jako léčivo či obživa pro lid a zvířata, ale díky svým stonkům a listům také jako materiál při výrobě např. rohoží a provazů. Mezi další pěstované plodiny patří například kukuřice a pšenice (Karsa, Darebo 2020).

Obr. 5: Poloha Sidamy v rámci Etiopie



zdroj: Geofabrik (2021) a Open Africa (2020) / vlastní zpracování

## 5 Metodika

### 5.1 Použitá data

Pro trénovací data bylo vybráno 318 bodů pořízených během in-situ měření provedeného Bc. Danielou Valchářovou v rámci vědecké expedice s kolegy z České geologické služby zaměřené na mapování Etiopie v listopadu 2020. Data byla pořízena pomocí zařízení Samsung Galaxy tab Active 2 se zabudovaným GPS přijímačem a nainstalovanou aplikací ArcGIS Collector. K validaci in-situ měření v čase byl využit volně dostupný software Google Earth Pro (GEP), který disponuje snímky Airbus / CNES a snímky od Maxar Technologies s velmi vysokým rozlišením. Ty jsou v GEP pro celé území Sidamy k zobrazení pravidelně již od roku 2014, což bylo hlavním kritériem pro to, že byl pro pozorování změny land cover zvolen časový horizont šesti let. Díky těmto archivním snímkům bylo možné detekovat krajinný pokryv a případně změny v čase, které byly zaznamenávány do tabulky MS Excel a následně propojeny s vrstvou validačních bodů v softwaru ArcMap.

K samotné klasifikaci byla využita data Landsat 8 Collection 1 Surface Reflectance Tier 1, která poskytuje NASA v kooperaci s USGS a též data od ESA z mise Copernicus, konkrétně Sentinel-2 MSI: MultiSpectral Instrument, Level-2A. Užity byly snímky Sentinel-2A i -2B.

Jako validační data posloužilo 750 bodů náhodně vygenerovaných metodou Stratified Sampling. Validace byla provedena v softwaru ArcGIS na základě dat Airbus / CNES a dat od Maxar Technologies dostupných v aplikaci GEP, a to ze snímků z let 2014 a 2020.

### 5.2 Metody

#### 5.2.1 Porovnání prostorového, spektrálního a temporálního rozlišení

Kompozity dat Sentinel-2 a Landsat 8 byly vyexportovány a na základě vhodně vybraného výřezu bylo provedeno srovnání obou datových sad. Zároveň byly staženy a vyexportovány dva vybrané snímky Sentinel-2 (doplnit ID scény / datum) a Landsat 8 (doplnit ID scény / datum) s oblačností pro možné porovnání vykreslení oblak a dalších nežádoucích prvků.

Získaná in-situ data byla validována mezi roky 2014 a 2020. Snahou bylo vyhledat invariantní, tedy neměnná místa v krajinném pokryvu. V případě, že se body nacházely na okrajích jednotlivých tříd, musely být z datasetu odstraněny. Zároveň bylo provedeno ruční přemístění některých bodů do středu land cover území pro následné získání většího počtu pixelů pro vstupní data. Toho bylo docíleno užitím bufferu. U dat Sentinel-2 byl využit 40m buffer v okolí bodů. Naopak u dat Landsat bylo využito pouze 30m bufferu vlivem prostorového rozlišení mise Landsat. Následně byly u jednotlivých bodů naměřeny jejich spektrální charakteristiky, které byly vyneseny do grafu (a porovnány možnosti dat Sentinel-2 a Landsat 8). Následně byly nalezeny odlehle hodnoty trénovacích dat a finální vrstva vybraných bodů byla použita jako trénovací data pro klasifikace. Vzhledem k odlišným hodnotám spektrálních charakteristik pro různé roky a typy dat se vlivem odstranění nevhodných bodů struktura trénovacích množin liší (viz Tab. 2).

Tab. 2: Počet trénovacích bodů v jednotlivých datových sadách

Datová sada (rok)	Počet trénovacích bodů
Sentinel-2 (2020)	304
Landsat 8 (2014)	296
Landsat 8 (2020)	306

zdroj: vlastní zpracování

Z hlediska temporálního rozlišení bylo provedeno pomocí Open Access Hub od ESA (Sentinel-2 MSI: MultiSpectral Instrument, Level-2A) a Earth Explorer od USGS (Landsat 8 Collection 2 Surface Reflectance Tier 1) porovnání dostupných snímků pro území města Irgalem, které se nachází ve středu zájmového území. U dat Sentinel-2 bylo provedeno porovnání i z hlediska dostupnosti z různých družic Sentinel-2A a Sentinel-2B. Pro data Sentinel-2 se jedná o tily T37NDH. U dat Landsat-8 se jedná o scény s Path 168 a 169 a Row 155.

## 5.2.2 Klasifikace

Pro klasifikace byla využita pásma B2, B3, B4, B5, B6, B7, B8, B8A, B11 a B12 u dat Sentinel-2 a pásma B2, B3, B4, B5, B6 a B7 u dat Landsat 8. Prvotní výsledek klasifikace ukázal, že pouhé použití pásem nebude pro uspokojivý výsledek klasifikace stačit. Po vzoru ostatních vědeckých výzkumů z oblasti analýzy land cover tak bylo zapotřebí implementovat do kódu v GEE vybrané vegetační indexy, které by pomohly zpřesnit výsledek klasifikace.

Největším problémem se zdál být nadhodnocený výskyt zástavby na úkor třídy plodin. Snaha vyřešit tento problém vedla k často používaným indexům NDVI (=Normalized Difference Vegetation Index) a SAVI (=Soil-adjusted Vegetation Index), které pro svůj výzkum efektivně použili Silva a kol. (2019). Starší z těchto dvou indexů – NDVI byl u samého prvopočátku vzniku vegetačních indexů, ale poprvé ho popsali až Rouse a kol. (1973). Spočívá v poměru rozdílu a součtu blízkého infračerveného a červeného pásma. Na stejném principu funguje i SAVI, který má však ve vzorci navíc parametr, jenž je nastavitelný uživatelem a závisí na hustotě vegetace ve sledovaném území (Huete 1988). Nejčastěji se používá hodnota 0.5, která značí středně hustou vegetaci a využití se jí dostalo i v této práci. Tato diference mezi indexy v praxi způsobuje, že u snímání husté vegetace dochází k saturaci dřívě u NDVI, a tak je SAVI užitečný právě zejména v oblastech s velmi hustou vegetací (Sykas 2020).

Ani přidání těchto dvou indexů však nevedlo k rapidnímu zlepšení výsledku klasifikace. Nově vzniklým úskalím bylo nedostatečně dobré rozlišení zástavby a holé půdy. Ettehadi a kol. (2019) se však ve své práci zabývali přímo touto problematikou a nabídli několik alternativ, jak tento nešvar vyřešit. Zcela jasně nejefektivnější se zdálo použití NDTI (=Normalized Difference Tillage Index). Tento index, který sestavili van Deventer a kol. (1997), dosahoval ze všech devíti zkoumaných indexů s přehledem největší schopnost zvyšovat kontrast mezi holou půdou a zástavbou. Jediným problémem tohoto indexu je snižování kontrastu mezi holou půdou a vodními útvary. Tento problém byl však odstraněn přidáním dalšího indexu s názvem BSI (=Bare Soil Index). Roy, Miyatake, Rikimaru (1997) vytvořili tento normalizovaný index využívající pásma Red, Blue, SWIR1 a NIR k odlišení holé, suché půdy od ostatních, vodou nasycených povrchů. Kombinované použití výše zmíněných indexů nakonec skutečně zajistilo lepší výsledek klasifikace, a to především u dat Sentinel-2. Celkový přehled vzorců použitých indexů je k vidění zde:

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

$$SAVI = \frac{(NIR) - (RED)}{(NIR) + (RED) + 0,5} (1 + 0,5)$$

$$NDTI = \frac{(SWIR 1) - (SWIR 2)}{(SWIR 1) + (SWIR 2)}$$

$$BSI = \frac{(SWIR 1 + RED) - (NIR + BLUE)}{(SWIR 1 + RED) + (NIR + BLUE)}$$

Následně byl vytvořen kompozit ze všech dostupných snímků v období od 1. 1. 2020 do 31. 3. 2020 pro data Sentinel-2 a Landsat 8. A dále pak pro období 1. 1. 2014 až 31. 3. 2014 pouze pro data Landsat 8 ke studiu změn land cover.

Pro klasifikaci bylo využito dvou vybraných klasifikátorů, u nichž bylo otestováno nastavení. Na základě inspirace ze studií Shetty (2019) a ManojKumar, Sugumaran, Zerr (2002) byly vybrány klasifikátory Random Forest a CART. RF byl zvolen jako jeden z klasifikátorů, který je u vědeckých pracovníků velmi oblíbený a využíváný, neboť dosahuje tradičně dobrých výsledků a jako protipól byl zvolen méně využívaný CART, který však mnohdy dosahuje podobných výsledků jako osvědčené klasifikátory. Jak již bylo zmíněno v teoretické části, jeho největší nevýhodou je velká citlivost na nízký počet trénovacích dat (ManojKumar, Sugumaran, Zerr 2002).

Stěžejním bodem klasifikace byl vhodný výběr nastavení parametrů. Jako nejvhodnější pro klasifikátor RF se ukázalo být nastavení: počet stromů – 250, resp. 900 a počet proměnných na rozdělení – 3. U klasifikátoru CART se jednalo o hodnoty: maximální počet leaf nodes – 45, resp. 150 a minimální leaf population 1, resp. 10.

Následně byly provedeny post-klasifikační úpravy. Byla provedena majoritní filtrace výsledných klasifikací. U dat Sentinel-2 byly odstraněny objekty menší 26 pixelů a obdobně pak i u Landsat 8, kde byly objekty menší 4 pixelů odstraněny (tj. 1-3 solitérní pixely) a rozpuštěny do okolí. MMU bylo pro tištěné a digitální mapy v měřítku 1 : 100 000 stanoveno na 0,25 ha u Sentinel-2 a 0,26 ha u Landsat 8. Následně bylo provedeno hodnocení přesnosti, využít byl i Kappa index.

### 5.2.3 Klasifikační legenda

V rámci klasifikace bylo zvoleno celkem 7 typů krajinného pokryvu (zástavba, plodiny, louka/pastvina, les, křoviny, holá půda a vodní plocha). Tyto typy vycházejí z označení tříd Bc. Danielou Valchářovou, která sbírala podkladová data přímo v terénu a definovala jich dokonce osm. Pro účely klasifikace však byla třída mokřad/bažina odstraněna, a to ze dvou hlavních důvodů. Tím prvním je vysoká proměnlivost této třídy nejen v průběhu roku, ale i během samotných měsíců, a bylo by tak obtížné ji správně vyklasifikovat. Dalším pádným důvodem pro neklasifikování bažin je zvolené sledované období (leden až květen). V této části roku panují v Etiopii období sucha, a tak je naprostá většina bažin a mokřadů vysušená a mění se nejčastěji na louky a pastviny, v některých případech i na zemědělskou plochu. Bažiny, které se zachovávají pak dosahují již jen velmi malých rozměrů. Vytvoření samostatné třídy by tedy v tomhle případě nemělo velký význam. Zbylé třídy byly vybrány z toho důvodu, že zabírají na území Sidamy významnou část území a není přípustné, aby byly jakkoli vynechány.

Třída zástavby zahrnuje veškeré oblasti, které člověk přetvořil pomocí různých stavebních prvků. Nejčastěji se jedná o budovy (od hliněných domků na periferii až po velké haly ve městech), ale řadí se sem také asfaltové cesty či dlážděná prostranství. Třída plodin je území, na němž člověk provozuje rostlinné hospodářství. Vyjma orné půdy, strukturou podobné té např. ve střední Evropě, jsou do této kategorie přiřazeny i plochy, kde je skladba rostlin, keřů a stromů velmi heterogenní, ale člověk tyto plodiny pravidelně obhospodařuje. K nejběžněji pěstovaným rostlinám z této kategorie patří obilniny, kukuřice, kávovník, falešný banánovník, chat, cukrová třtina či avokádovník. Jako louka/pastvina je míněno území, které se využívá buď pro pastvu hospodářských zvířat nebo slouží jen jako volné prostranství protkané např. pěšinami. Řadí se sem však i částečně zatopené louky (mokřady) na březích řek. Lesem se v případě této studie rozumí oblast, která je souvisle zarostlá stromy o výšce alespoň 3 m, hustota korun musí dosahovat alespoň 50 %. Nejčastěji se jedná o borovice či eukalypty. Křoviny jsou třídou, která zahrnuje keře o výšce maximálně 3 m, ale zpravidla se jedná o husté, zakrslé keře o výšce kolem 1 m. Třída holá půda zahrnuje veškeré oblasti s odhaleným půdním vzorkem, který není porostlý žádnou travinou ani plodinou. Její struktura bývá nejčastěji hlinitá až šterkovitá a z velké většiny bývá degradovaná čili nevyužitelná pro pastevectví ani zemědělství. Poslední rozlišovanou třídou jsou vodní plochy. Sem vyjma jezer patří i vodní toky a nádrže.

#### 5.2.4 Změny land cover

Pro vyhodnocení změn land cover byl využit software ArcGIS. Konkrétně byly využity funkce Raster Calculator a Reclassify pro výpočet rastru změněných a nezměněných ploch. Oblaka byla z obou klasifikací před výpočtem změněných a nezměněných ploch odmaskována. Následně byly po převedení rastru na polygon funkcí Raster to Polygon kvantifikovány změněné a nezměněné plochy. Dále jsme provedli vytvoření mapy land cover, kde nedošlo ke změnám.

### 5.3 Softwary

Pro práci bylo využito cloud based prostředí GEE. Skripty (viz Přílohy 1-5) byly vytvořeny pomocí programovacího jazyku JavaScript. Výsledné klasifikace/kompozity/snímky byly vyexportovány do GeoTIFF v WGS 84 / UTM zone 37N (EPSG 32637) a následně zpracovány do map v softwaru ArcGIS. Finální webová mapová aplikace, ve které jsou mapy prezentovány v digitální podobě byla vytvořena v ESRI Web App Builder, což představuje prostředí pro tvorbu webových mapových aplikací v ArcGIS Online rozhraní.

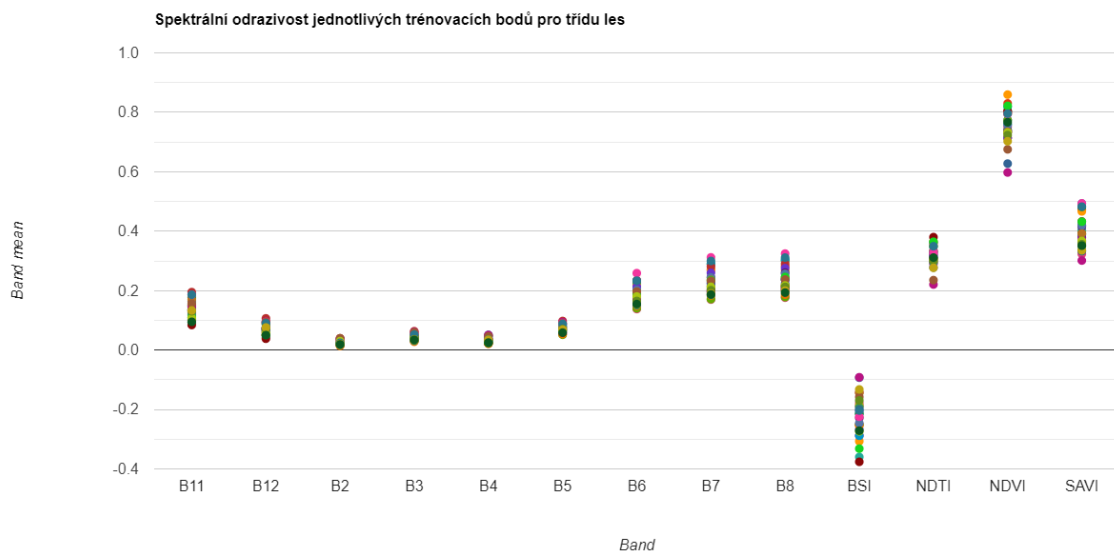


## 6 Výsledky

### 6.1 Porovnání prostorového, spektrálního a temporálního rozlišení

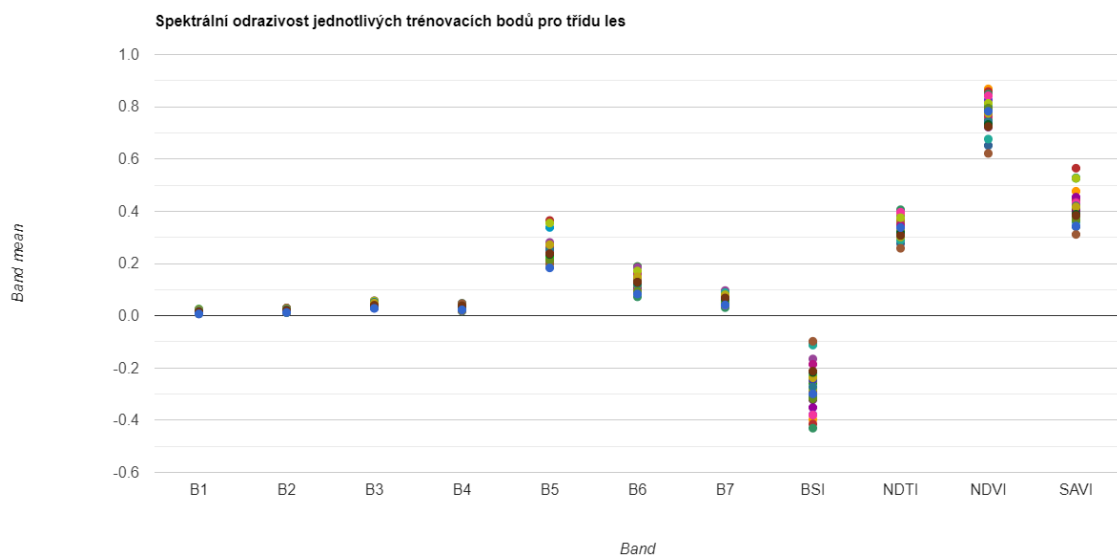
Na Grafech 1-3 jsou vidět spektrální charakteristiky jednotlivých pásem včetně hodnot vegetačních indexů, a to již po odmazání odlehlých bodů. Je třeba brát v potaz, že označení pásem je pro data Landsat 8 a Sentinel-2 odlišné. Rozdíl mezi Landsat 8 2014 a 2020 je jen málo znatelný, a to navíc jen v některých indexech (např. BSI a SAVI).

Graf 1: Spektrální charakteristiky in-situ měření pro Sentinel-2 v roce 2020



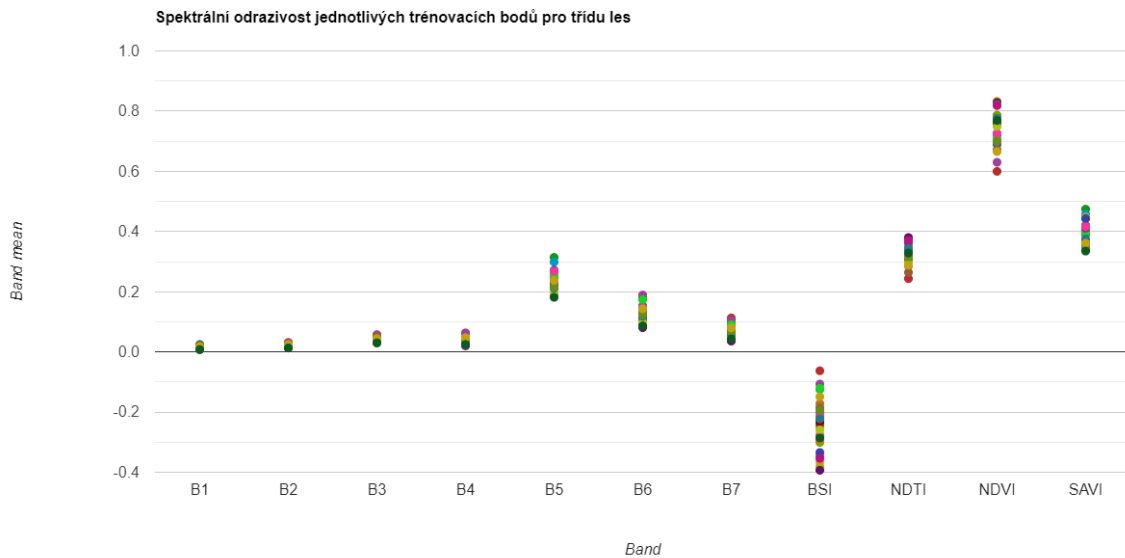
zdroj: vlastní zpracování

Graf 2: Spektrální charakteristiky in-situ měření pro Landsat 8 v roce 2020



zdroj: vlastní zpracování


Graf 3: Spektrální charakteristiky in-situ měření pro Landsat 8 v roce 2014



zdroj: vlastní zpracování

Obr. 6 znázorňuje ukázkou a porovnání dvou kompozitů. První z nich je pořízen z dat Sentinel-2 a druhý z dat Landsat 8. Na snímcích je patrné nižší prostorové rozlišení u dat Landsat, které je 30 m. Naopak Sentinel-2 disponuje prostorovým rozlišením 10 m pro pásma pořízená ve viditelné části spektra. Data Sentinel-2 tak umožňují rozlišit drobnější struktury, což je ideální při pozorování menších objektů, jako jsou například menší budovy, cesty, řeky atp. Obr. 7 pak porovnává dva vybrané oblačné snímky. Na snímcích Sentinel-2 je možné lépe rozlišit cirová oblaka, což je důležité pro tvorbu bezoblačných kompozitů.

Obr. 6: Porovnání prostorového rozlišení dvou kompozitů Landsat 8 a Sentinel-2



zdroj: vlastní zpracování

Pro lepší porovnání snímků je ve všech čtyřech zobrazeno totožné jihosidamské území o rozměrech 900x900 m. Snímky z Obr. 6 jsou oba pořízeny 19. 1. 2020. Oblačný snímek Landsat 8 z Obr. 7 je pak pořízen 22. 2. 2021 a snímek napravo z 23. 2. 2020.

Obr. 7: Porovnání prostorového rozlišení dvou oblačných snímků Landsat 8 a Sentinel-2



(zdroj: vlastní zpracování)

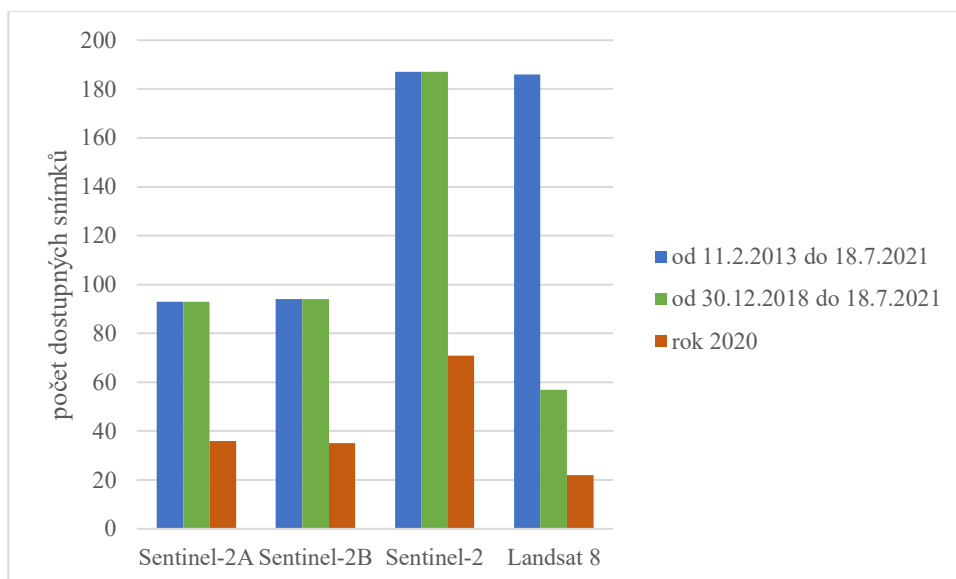
V Tabulce 3 můžeme vidět množství dostupných snímků pro středosidamskou obec Irgalem dle různých typů družic. Data Sentinel-2 L2A jsou k dispozici pro tuto oblast od 30. 12. 2018. Naopak data Landsat 8 jsou k dispozici již od 2. 4. 2013. Celkově bylo k dispozici 186 snímků Landsat 8 a 187 snímků Sentinel-2 (do 18. 7. 2021). Můžeme zaznamenat srovnatelné množství snímků pro družici Sentinel-2A a Sentinel-2B. Od počátku dat L2A je množství dat z obou družic Sentinel-2 více než trojnásobný. V roce 2020 bylo k dispozici celkem 71 snímků Sentinel-2 a pouze 22 snímků z mise Landsat 8. K dispozici tedy bylo přibližně třikrát více dostupných snímků Sentinel-2 než snímků Landsat 8. To může být z hlediska výběru dat pro tvorbu bezoblačné mozaiky nebo kompozitu rozhodující faktor.

Tab. 3: Porovnání temporálního rozlišení dat Landsat 8 a Sentinel-2

Sentinel-2A	Sentinel-2B	Sentinel-2	Landsat 8
<i>od 2.4.2013 do 18.7.2021 (počátek dat Landsat 8 pro Etiopii)</i>			
93	94	187	186
<i>od 30.12.2018 do 18.7.2021 (počátek dat S-2 L2A pro Etiopii)</i>			
93	94	187	57
<i>rok 2020</i>			
36	35	71	22

zdroj: vlastní zpracování; data vztahena ke dni 18.7.2021

Graf 4: Porovnání temporálního rozlišení dat Landsat 8 a Sentinel-2



zdroj: vlastní zpracování

## 6.2 Klasifikace v roce 2020 a 2014

V rámci tvorby klasifikací bylo detailně otestováno nastavení klasifikátorů RF a CART. V Tabulce 4 jsou vidět vybraná nastavení RF pro oba typy dat a vliv tohoto nastavení na celkovou přesnost klasifikace a kappa index. Jako nejvhodnější se pro data Landsat 8 ukázalo nastavení ntree s hodnotou 900 (2014) a 250 (2020). U dat Sentinel-2 vycházela klasifikace nejlépe taktéž pro hodnotu 250 ntree. Obdobě bylo otestováno i nastavení metody CART, kde se jako nejvhodnější jeví nastavení maximální počet leaf nodes 45 a minimální leaf population 5 pro Landsat 8 (2020) a naopak pro Sentinel-2 maximální počet leaf nodes 150 a minimální leaf population na 5 (viz Tab. 5).

Tab. 4: Otestovaná nastavení klasifikátoru RF

	počet stromů (ntree) Landsat 8 (2014)			počet stromů (ntree) Landsat 8 (2020)			počet stromů (ntree) Sentinel-2 (2020)		
	50	250	900	50	250	900	50	250	500
celková přesnost [%]	76	76,3	76,9	80,6	80,7	80,3	85,1	85,9	85,8
kappa index	0,629	0,628	0,638	0,687	0,69	0,684	0,757	0,769	0,77

Pozn.: zbylým parametrům klasifikátoru byly ponechány defaultní hodnoty

zdroj: vlastní zpracování

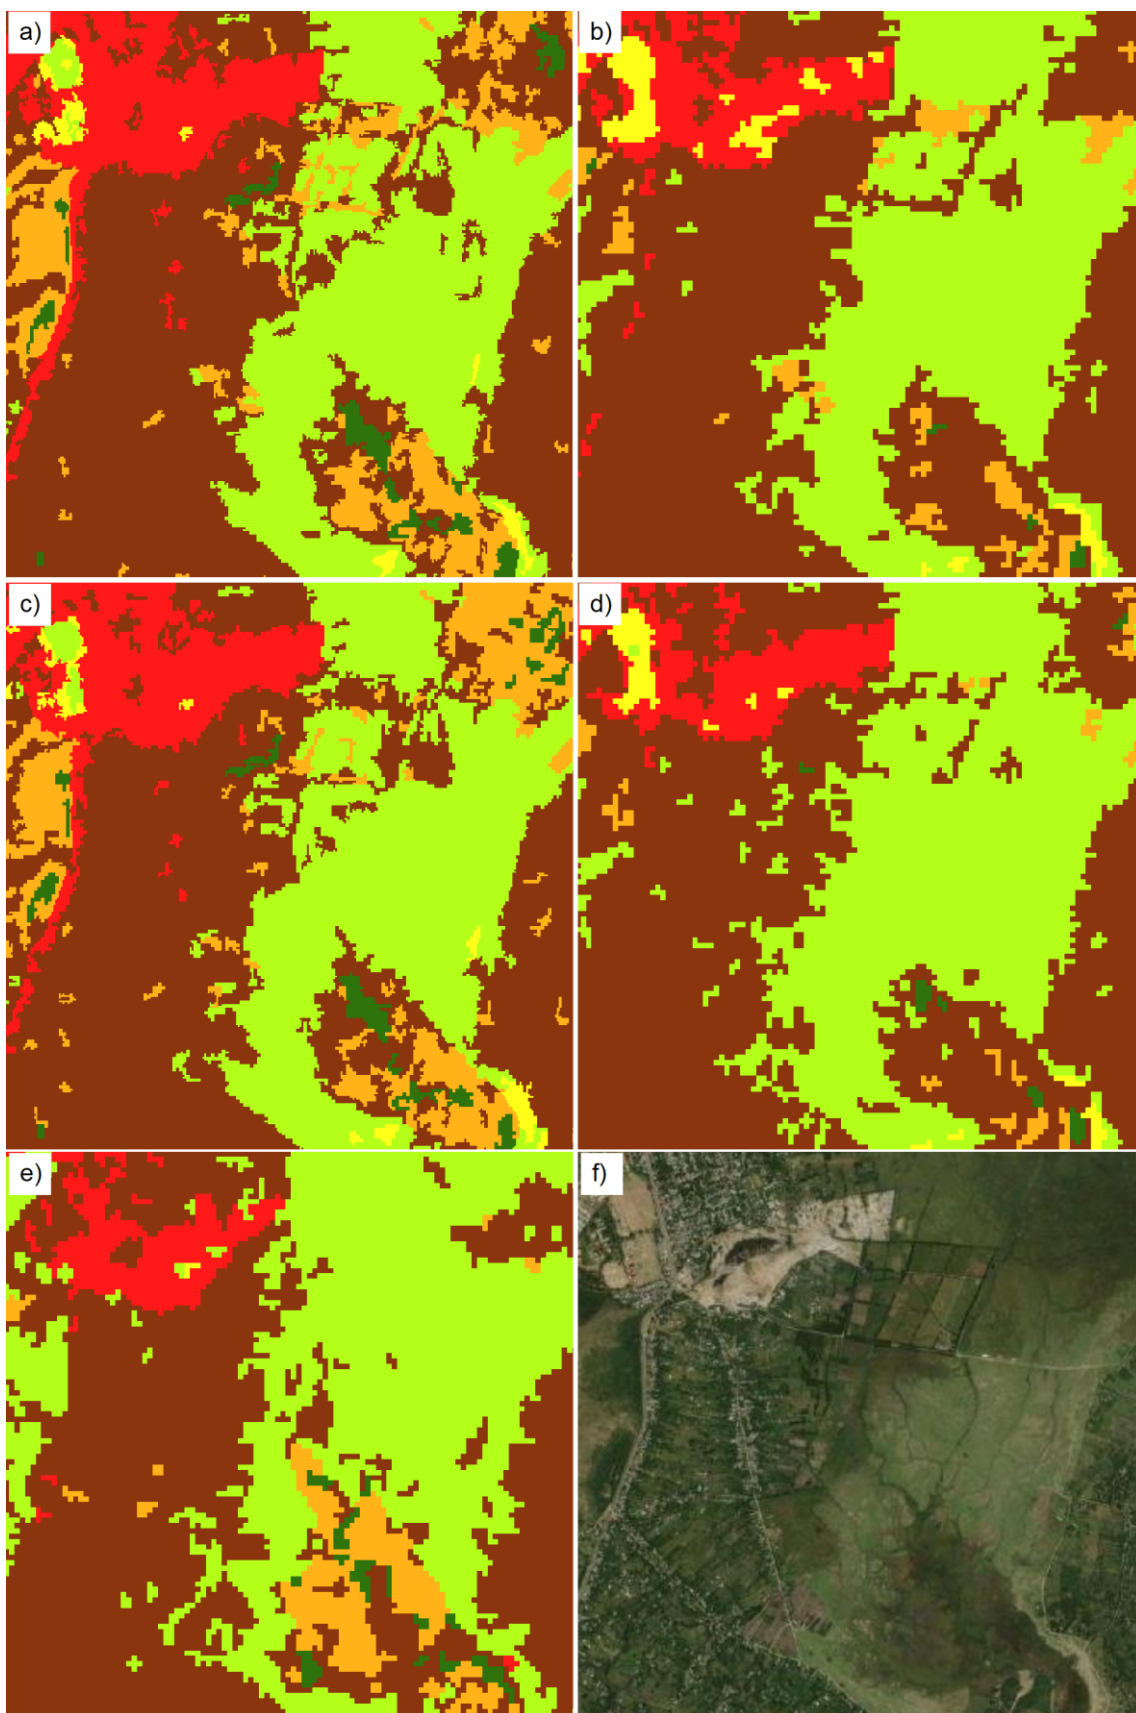
Tab. 5: Otestovaná nastavení klasifikátoru CART

parametry a hodnoty		maximální počet leaf nodes			maximální počet leaf nodes		
		Landsat 8 (2020)			Sentinel-2		
		20	45	100	45	100	150
minimální leaf population	1	77,6 / 0,617	79,2 / 0,660	76,9 / 0,645	80,7 / 0,680	81,6 / 0,709	82,3 / 0,719
	5	77,2 / 0,627	77,7 / 0,644	77,5 / 0,639	80,8 / 0,688	82,3 / 0,721	82,6 / 0,726
	10	76,1 / 0,623	76,9 / 0,641	76,9 / 0,640	81,8 / 0,708	82,6 / 0,724	81,9 / 0,712

Pozn.: výsledky jsou ve formátu [celková přesnost v % / kappa index]

zdroj: vlastní zpracování

Obr. 8: Klasifikace území Sidama pomocí RF a dat Sentinel-2 v roce 2020 (a), RF a dat Landsat 8 v roce 2020 (b), CART a dat Sentinel-2 v roce 2020 (c), CART a dat Landsat 8 v roce 2020 (d), RF a dat Landsat 8 v roce 2014 (e), ESRI World Imagery (f)



zdroj: ESRI (2021)/ vlastní zpracování

Na Obrázku 8 je vidět porovnání výsledků různých klasifikačních metod a dat v roce 2020 na příkladu oblasti jihovýchodního okraje města Awasa. Tyto výřezy vhodně ilustrují prostorové rozlišení dat Sentinel-2 a Landsat 8 a jejich vliv na výsledek klasifikace. Ze snímku je vidět, že úzké jednoproudé silnice, jaké najdeme v Etiopii, se na datech Landsat 8 nezobrazí. Finální mapové výstupy pro celé území regionu Sidama byly vytvořeny v měřítku 1 : 100 000 a jsou dostupné jako přílohy této bakalářské práce (Příloha 5-10).

V Tabulkách 6-10 můžeme vidět chybové matice pro jednotlivé typy klasifikací a typy dat. Nejvyšší celková přesnost klasifikace byla dosažena u kombinace dat Sentinel-2 (pro rok 2020) s klasifikátorem Random Forest – 85,92 %. Naopak nejnižší hodnotu vykázala klasifikace dat Landsat 8 (pro rok 2014), rovněž s klasifikátorem RF – 76,94 %.

Chybové matice jsou obecně velmi cenné prvky pro detailní zhodnocení provedené klasifikace. Již při zevrubném zkoumání výsledných klasifikačních map je zřejmé, že velmi problematickou třídou u provedených klasifikací je zástavba. Vyjma Tabulky 6 klesala její uživatelská i zpracovatelská přesnost až ke 40 %. Další třídou, jejíž přesnosti se pohybovaly kolem 50 % je spektrálně obtížně zařaditelná třída křovin, u níž docházelo nejčastěji k záměně se třídou plodin. Ostatní třídy až na výjimky (holá půda u RF Landsat 8 2014 a louka/pastvina u CART Landsat 8 2020) stabilně vykazovaly hodnoty uživatelské i zpracovatelské přesnosti přes 70 %, což lze považovat za uspokojivou bilanci.

Tab. 6: Chybová matice s výsledky klasifikace RF s daty Sentinel-2 v roce 2020

Třída	Zástavba	Plodiny	Louka/ pastvina	Les	Křoviny	Holá půda	Vodní plocha	Celkem	Uživatelská přesnost
Zástavba	8	1	0	0	0	1	0	10	80,00%
Plodiny	0	391	6	19	8	1	0	425	92,00%
Louka/pastvina	0	18	85	1	1	5	0	110	77,27%
Les	0	16	1	69	3	0	0	89	77,53%
Křoviny	0	18	0	1	25	0	0	44	56,82%
Holá půda	0	1	3	0	0	50	0	54	92,59%
Vodní plocha	0	1	0	0	0	0	13	14	92,86%
Celkem	8	446	95	90	37	57	13	746	
Zpracovatelská přesnost	100,00%	87,67%	89,47%	76,67%	67,57%	87,72%	100,00%		
Celková přesnost									85,94%
Kappa index									0,769

zdroj: vlastní zpracování

Za zmínku však stojí i třídy, jimž se naopak v klasifikaci vedlo nadmíru zdařile. Skvělých výsledků dosahovala třída holá půda. Ve dvou případech se této třídě dokonce podařilo překonat hranici 90 % u zpracovatelské přesnosti. Přesných výsledků se podařilo dosáhnout i v případě vodních ploch, které i na přiložených mapových dílech působí dojmem správného určení.

Ve všech chybových maticích je zároveň zjevný pozitivní vliv použití vegetačních indexů, a to zejména v případě vztahu zástavba – holá půda, neboť výsledné hodnoty naznačují, že se vzájemnou záměnu podařilo efektivně redukovat. Přijatelných přesností dosahovala i třída plodin, u níž bylo velké riziko záměny především s třídami louka/pastvina, les a křoviny. Hodnoty zpracovatelské přesnosti kolem 85 % však dokazují, že záměna nebyla nikterak markantní.

Pozornost budí porovnání klasifikací s daty Sentinel-2 a s daty Landsat 8. Při použití stejných klasifikátorů bylo dosaženo větší celkové přesnosti s daty Sentinel-2, a to v obou případech o alespoň 3 %. Stejně tak lze pozorovat porovnání obou klasifikátorů při použití stejné datové sady. I zde je situace jednoznačná.

Tab. 7: Chybová matice s výsledky klasifikace CART s daty Sentinel-2 v roce 2020

Třída	Zástavba	Plodiny	Louka/ pastvina	Les	Křoviny	Holá půda	Vodní plocha	Celkem	Uživatelská přesnost
Zástavba	7	1	0	0	1	1	0	10	70,00%
Plodiny	2	370	11	26	13	3	0	425	87,06%
Louka/pastvina	0	17	83	1	3	6	0	110	75,45%
Les	0	14	1	69	5	0	0	89	77,53%
Křoviny	1	16	2	0	25	0	0	44	56,82%
Holá půda	3	0	2	0	0	49	0	54	90,74%
Vodní plocha	0	1	0	0	0	0	13	14	92,86%
Celkem	13	419	99	96	47	59	13	746	
Zpracovatelská přesnost	53,85%	88,31%	83,84%	71,88%	53,19%	83,05%	100,00%		
Celková přesnost									82,44%
Kappa index									0,722

zdroj: vlastní zpracování

Tab. 8: Chybová matice s výsledky klasifikace RF s daty Landsat 8 v roce 2014

Třída	Zástavba	Plodiny	Louka/ pastvina	Les	Křoviny	Holá půda	Vodní plocha	Celkem	Uživatelská přesnost
Zástavba	5	2	0	0	1	1	0	9	55,56%
Plodiny	1	349	23	32	18	2	0	425	82,12%
Louka/pastvina	2	27	86	0	2	1	1	119	72,27%
Les	0	4	2	64	7	0	0	77	83,12%
Křoviny	0	20	2	1	23	0	0	46	50,00%
Holá půda	3	11	8	0	0	34	0	56	60,71%
Vodní plocha	0	0	0	0	1	0	13	14	92,86%
Celkem	11	413	121	97	52	38	14	746	
Zpracovatelská přesnost	45,45%	84,50%	71,07%	65,98%	44,23%	89,47%	92,86%		
Celková přesnost									76,94%
Kappa index									0,638

zdroj: vlastní zpracování

Tab. 9: Chybová matice s výsledky klasifikace RF s daty Landsat 8 v roce 2020

Třída	Zástavba	Plodiny	Louka/ pastvina	Les	Křoviny	Holá půda	Vodní plocha	Celkem	Uživatelská přesnost
Zástavba	5	4	0	0	0	1	0	10	50,00%
Plodiny	2	369	21	25	6	2	0	425	86,82%
Louka/pastvina	0	24	81	0	1	3	1	110	73,64%
Les	0	12	0	70	7	0	0	89	78,65%
Křoviny	0	20	1	2	21	0	0	44	47,73%
Holá půda	2	5	4	0	0	43	0	54	79,63%
Vodní plocha	0	1	0	0	0	0	13	14	92,86%
Celkem	9	435	107	97	35	49	14	746	
Zpracovatelská přesnost	55,56%	84,83%	72,16%	72,16%	60,00%	87,76%	92,86%		
Celková přesnost									80,70%
Kappa index									0,690

zdroj: vlastní zpracování

Tab. 10: Chybová matice s výsledky klasifikace CART s daty Landsat 8 v roce 2020

Třída	Zástavba	Plodiny	Louka/ pastvina	Les	Křoviny	Holá půda	Vodní plocha	Celkem	Uživatelská přesnost
Zástavba	4	5	0	0	0	1	0	10	40,00%
Plodiny	1	372	30	18	2	2	0	425	87,53%
Louka/pastvina	0	32	74	0	1	3	0	110	67,27%
Les	0	12	0	73	4	0	0	89	82,02%
Křoviny	0	22	1	3	18	0	0	44	40,91%
Holá půda	2	9	4	0	0	39	0	54	72,22%
Vodní plocha	0	0	1	2	0	0	11	14	78,57%
Celkem	7	452	110	96	25	45	11	746	
Zpracovatelská přesnost	57,14%	82,30%	67,27%	76,04%	72,00%	86,67%	100,00%		
Celková přesnost									79,22%
Kappa index									0,660


zdroj: vlastní zpracování

### 6.3 Změny land cover mezi roky 2020 a 2014 z dat Landsat 8

Obrázek 9 je výřez o velikosti 9x9 km, který zaměřuje území jihozápadně od hlavního města Sidamy – Awasy. Jeho hlavním cílem je ukázat způsob, jakým byla zmapována stabilita jednotlivých plošek na území Sidamy. Bílá barva znázorňuje oblasti, které prošly mezi roky 2014 a 2020 určitou změnou krajinného pokryvu. Podkladem je klasifikace Random Forest na datech Landsat 8 z roku 2020. Výsledná mapa změn pro celou oblast Sidamy včetně legendy je k dispozici v Příloze 11.



Obr. 9: Ukázka změn land cover na území Sidama mezi roky 2014 a 2020



zdroj: vlastní zpracování

V Tabulce 11 můžeme vidět porovnání rozlohy jednotlivých kategorií mezi roky 2014 a 2020. Při čtení grafu je však třeba mít na paměti přesnost klasifikací, a to zejména té z roku 2014, která nepřinesla pro všechny třídy zcela vypovídající hodnoty. Nepřesné hodnoty se na výsledku projeví tím spíše, pokud se jedná o území s nepřilíš velkou rozlohou (např. zástavba). Na základě pozorování satelitních a leteckých snímků totiž lze s jistotou vyloučit, že by na území Sidamy docházelo k úbytku zastavěné plochy. Trend je spíše opačný.

Tab. 11: Porovnání vývoje jednotlivých kategorií

	Rozloha v roce 2014 [km <sup>2</sup> ]	Podíl na rozloze v roce 2014 [%]	Rozloha v roce 2020 [km <sup>2</sup> ]	Podíl na rozloze v roce 2014 [%]
zástavba	141,56	2,06	129,78	1,89
plodiny	4037,83	58,71	4328,39	62,93
louka/pastvina	1213,35	17,64	973,94	14,16
les	558,72	8,12	604,29	8,79
křoviny	514,69	7,48	340,50	4,95
holá půda	297,00	4,32	372,22	5,41
vodní plocha	106,67	1,55	114,58	1,67
chybí data (oblačnost)	8,10	0,12	14,21	0,21
celkem	6878	100,00	6878	100,00

zdroj: vlastní zpracování

### 6.3.1 Webová mapová aplikace

Výsledné mapové produkty jsou prezentovány ve webovém mapovém rozhraní ESRI Web App Builder. Mapa umožňuje základní uživatelské operace, jako je hledání míst, výběr mapových podkladů, funkce měření vzdálenosti či sdílení (včetně embed). Do rozhraní byly nahrány vytvořené klasifikace. Je zde k dispozici i funkce swipe, která umožňuje porovnání dvou výsledků klasifikací. Webová mapová aplikace je přístupná z internetové stránky: <http://www.filipzadrazil.wz.cz>.

## 7 Diskuse

Jednou z nejvíce problematických částí práce bylo vytvoření kompozitu snímků. Etiopská oblast Sidama se nachází mezi 6. a 7. stupněm severní šířky, kde je téměř každodenní výskyt oblačnosti. Pro tvorbu kompozitů se jevilo jako bezoblačné období mezi říjnem a prosincem či mezi lednem a květnem. Na základě vlastních měření bylo nakonec vybráno období mezi lednem a květnem, které se zdálo být pro účely klasifikace vhodnější (bylo získáno nejvyšší celkové přesnosti). Výběr delších období, např. celého roku nebo více než 6 měsíců způsoboval snížení celkové přesnosti klasifikací, což bylo způsobeno vybranou metodou pro tvorbu kompozitu, v případě této práce pomocí mediánu, který počítá hodnoty ze všech vybraných snímků. Špatných výsledků z delšího pozorování může být získáno zejména vlivem špatně odmaskované oblačnosti nebo heterogenitou prostředí v čase, např. vlivem změn zemědělských polí, kde dochází ke sklizni dvakrát až třikrát do roka (tedy i změnami plodin, které mohou mít odlišné spektrální příznaky). Zároveň vlivem značné oblačnosti a nižšího temporální rozlišení se nepodařilo pomocí dat Landsat 8 pokrýt celou pozorovanou oblast. V tomto ohledu (temporálním rozlišení) měla data Sentinel-2 značnou převahu, stejně jako v lepší detekci a odmaskování oblak, které mají oporu ve vyšším prostorovém a spektrálním rozlišení.

Svízelná je v Sidamě, potažmo v celé Etiopii a přilehlých státech, samotná struktura jednotlivých tříd. Vyjma vodních ploch, jsou mezi sebou zbylé třídy poměrně jednoduše zaměnitelné. Stěžejní rozkol nastává při rozlišení třídy plodin a křovin, popř. lesa. Skladba plodin je v Sidamě opravdu velmi rozmanitá, s čímž souvisí velká různorodost spektrální odrazivosti trénovacích bodů této třídy. I proto došlo při klasifikaci k několika záměnám s lesy, křoviny, ale i loukami. Lze říct, že třída les je v Sidamě poměrně problematická a nejasná. Lesy zde nejsou zcela běžné a rozlišení například hustě nasázených avokádovníků či falešných banánovníků bývá leckdy obtížné. Specifické jsou také hustě zarostlé, převážně křovinaté oblasti, kde se mezi klečí často objevují i o něco málo vyšší stromy. Tato místa jsou nesnadno rozlišitelná už pro lidské oko při in-situ průzkumu, natož pro klasifikátor. Nejvíce totiž kappa index utrpěl kvůli třídě křovin. U ní se přesnost klasifikace pohybovala pouze kolem 50 % a to především ve prospěch třídy plodin.

Nižší temporální rozlišení dat Landsat je způsobeno snímáním pouze jednou družicí. V září 2021 však NASA plánuje start Landsat 9 OLI2/TIRS2, která by měla mít kompatibilní parametry s Landsat 8 OLI/TIRS. Snímání těchto dvou družic by mělo snížit temporální rozlišení mise Landsat ze současných 16 dní na pouhých 8 dní. NASA (2021) tak slibuje zefektivnění v oblasti sledování zemského povrchu a chce i nadále přispívat k detekci a analýze závažných geoklimatických problémů, jakými jsou tání ledovců, sucho či náhlé přírodní katastrofy, ale například i pozorování vlivu urbanizace, zejména ve velkých městech. V potaz je však třeba také brát životnost jednotlivých družic.

S ohledem na výsledky klasifikací lze konstatovat, že prostorové rozlišení má značný vliv na celkovou přesnost klasifikace, obdobné zjištění je známo i z práce Štych a kol. (2019). Metoda RF v kombinaci s daty Sentinel-2 se jeví jako velmi vhodná pro klasifikace kompozitů rozsáhlejších území.

Dílejší část práce se zaměřila na hodnocení prostorového, spektrálního a temporálního rozlišení. Bylo zjištěno, že lepších výsledků dosahují datové sady s vyššími hodnotami zmíněných rozlišení – konkrétně zde Sentinel-2. Díky vytvoření bufferů pro účely klasifikace však v případě této práce bylo prostorové rozlišení dat poměrně potlačeno a nelze ho tak na základě výsledků jednoznačně hodnotit. Zatímco vyšší temporální rozlišení Sentinelu-2 se efektivně projevilo tím, že zajistilo vytvoření bezoblačného kompozitu.

Je téměř jisté, že v závěru každého vědeckého článku či práce objeví autor větší či menší detaily, které by bývaly vedly k lepším výsledkům. Nejinak je tomu i u této práce. Právě tato kapitola je více než vhodná ke zmínění těchto slabín a vede k zamyšlení se nad nimi.

Jednou z cest, která potenciálně vede k přesnější klasifikaci jsou vegetační indexy. Vzhledem k tomu, jak velké množství jich již existuje, zcela jistě by stálo za to udělat důkladnější vhléd do jejich seznamu a otestovat jejich fungování v praxi. Pravděpodobnost, že by se našel, byť jen jeden index vedoucí k přesnější klasifikaci, je jistě velmi vysoká. Zejména pokud se jedná o data Sentinel-2, která mají více (především red edge) pásem, což dává výzkumníkům možnost vytvořit větší množství vegetačních indexů a odlišit od sebe více vizuálně podobných povrchů. Pro lepší porovnání dat Landsat 8 a Sentinel-2 však bylo rozhodnuto, že budou použity pro obě datové sady stejné kombinace indexů.

Další faktor, který často ovlivňuje celkové výsledky klasifikace může být počet trénovacích bodů. Jak je však známo z výzkumů Li a kol. (2011) a Ramezan a kol. (2021), závislost celkové přesnosti klasifikace na počtu trénovacích dat roste logaritmicky – od určitého počtu trénovacích dat se už přesnost klasifikace téměř vůbec nezlepšuje. Konkrétně u klasifikátorů, jakými jsou např. Random Forest nebo GBM (Gradient-boosted Machine), nehraje počet trénovacích množin tak velkou roli, na rozdíl od klasifikátorů CART či Neural Networks (ManojKumar, Sugumaran, Zerr 2002; Ramezan a kol. 2021).

## 8 Závěr

Cílem této bakalářské práce bylo testování pokročilých klasifikačních metod, konkrétně metody RF a CART. Porovnání proběhlo na základě aplikace těchto vybraných metod na kompozity volně dostupných data Sentinel-2 a Landsat 8 pro rozmanité území etiopského regionu Sidama, ve kterém proběhlo detailní in-situ měření. V rámci porovnání těchto dvou vybraných klasifikačních metod se jevila metoda RF jako přesnější, konkrétně pro data Sentinel-2 bylo dosaženo 85,9 % celkové přesnosti a pro data Landsat 8 pak 80,7 %. Na základě parametrizace metod byla získána celková přesnost u obou metod převyšující 76,5 %. Výstupem klasifikací jsou i vytvořené mapy v měřítku 1 : 100 000, které jsou přílohami této práce.

Dalším cílem práce bylo sestavení metody / klasifikačního algoritmu, která by mohla být přenositelná pro jiná území. Pro tyto účely byly vytvořeny detailní skripty (v programovacím jazyce JavaScript) v cloud based rozhraní Google Earth Engine. Tyto skripty jsou součástí příloh této bakalářské práce.

Snahou bylo též provést hodnocení změn land cover. K těmto čelům posloužila data Landsat 8 a klasifikace RF v roce 2014 a 2020. U získaných bodů z in-situ měření byla ověřena neměnnost v čase. Díky tomu jsou vytvořené skripty a data použitelná pro vytvoření klasifikace v časové řadě mezi roky 2014 a 2020 pomocí parametrizace připraveného skriptu.

Posledním cílem této práce bylo porovnání temporálního, prostorového a spektrálního rozlišení. Bylo zjištěno, že data Sentinel-2 poskytují až třikrát vyšší temporální rozlišení, kterého je získáno především díky paralelnímu snímání dvou družic Sentinel-2A a Sentinel 2B. To může představovat rozhodující faktor pro výběr dat při sestavování mozaiky nebo kompozitu snímků. Nevýhodou dat Sentinel-2 je pak kratší časová řada, protože data jsou dostupná až od roku 2015 a ve verzi s atmosférickými korekcemi až od roku 2017 (v případě Etiopie až dokonce od 30. 12. 2018). Data Landsat 8 jsou pak poskytována již od roku 2013 a to i pro území Etiopie, ke starším pozorování lze využít i předchůdce Landsat 8. Z hlediska spektrálního rozlišení lze považovat za značnou výhodu množství red edge spektrálních pásem, které umožňují lépe detekovat rozdíly ve vegetaci.

Mapové výstupy pak byly prezentovány pomocí webové mapové aplikace v prostředí ESRI Web App Builder.

## 9 Zdroje literatury

- ANG, M. L. E., ARTS, D., CRAWFORD, D., LABATOS, B. V., NGO, K. D., OWEN, J. R., GIBBINS, C., LECHNER, A. M. (2021): Socio-environmental land cover time-series analysis of mining landscapes using Google Earth Engine and web-based mapping. *Remote Sensing Applications: Society and Environment*, 21.
- ARÉVALO, P., BULLOCK, E. L., WOODCOCK, C. E., OLOFSSON, P. (2020): A Suite of Tools for Continuous Land Change Monitoring in Google Earth Engine. *Frontiers in Climate*, 2.
- BELGIU, M., DRĂGUȚ, L. (2016): Random forest in remote sensing: A review of applications and future directions. *Elsevier B.V.*, 114, 24–31.
- BISHOP, C. M. (2006): *Pattern Recognition and Machine Learning*. Springer, Berlin.
- CENTRAL STATISTICAL AGENCY (CSA), INTERNATIONAL FOOD POLICY RESEARCH INSTITUTE (IFPRI), ETHIOPIAN DEVELOPMENT RESEARCH INSTITUTE (EDRI) (2010): *Population & Housing census atlas of Ethiopia 2007*. Addis Abeba.
- COLLINS, L., MCCARTHY, G., MELLOR, A., NEWELL, G., SMITH, L. (2020): Training data requirements for fire severity mapping using Landsat imagery and random forest. *Remote Sensing of Environment*, 245.
- COPERNICUS (2019): Start of global service, <https://land.copernicus.eu/imagery-in-situ/global-image-mosaics/> (cit. 22. 7. 2021).
- DEVENTER, A. V., WARD, A., GOWDA, P., LYON, J. G. (1997): Using Thematic Mapper Data to Identify Contrasting Soil Plains and Tillage Practices. *Remote Sens*, 63, 87–93.
- DOBILAS, S. (2021): CART: Classification and Regression Trees for Clean but Powerful Models, <https://towardsdatascience.com/cart-classification-and-regression-trees-for-clean-but-powerful-models-cc89e60b7a85> (cit. 13. 7. 2021).
- ESA (2021): Resolution and Swath, <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/instrument-payload/Resolution-and-swath> (28. 7. 2021).
- ESRI (2021): ESRI World Imagery. Dostupné online v programu ArcGIS Desktop.
- ETTEHADI, P., KAYA, S., SERTEL, E., ALGANCI, U. (2019): Separating built-up areas from bare land in mediterranean cities using Sentinel-2A imagery. *Remote Sensing*, 3, 11.
- GEE (2021a): Earth Engine Data Catalog. <https://developers.google.com/earth-engine/datasets/catalog> (cit. 28. 6. 2021)
- GEE (2021b): smileCart. <https://developers.google.com/earth-engine/apidocs/ee-classifier-smilecart> (cit. 1. 7. 2021)
- GEOFABRIK (2021): Ethiopia, <https://download.geofabrik.de/africa/ethiopia.html> (cit. 1. 7. 2021).
- HUETE, A. R. (1988): A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 3, 25, 295–309.
- KULKARNI, A., LOWE, B. (2016): *Random Forest Algorithm for Land Cover Classification*. Computer Science Faculty Publications and Presentations.
- LAŠTOVIČKA, J. (2020): Hodnocení lesní vegetace pomocí časových řad družicových snímků. Univerzita Karlova, Přírodovědecká fakulta, Praha.
- LAŠTOVIČKA, J., ŠVEC, P., PALUBA, D., KOBLIUK, N., SVOBODA, J., HLADKÝ, R., ŠTYCH, P. (2020): Sentinel-2 Data in an Evaluation of the Impact of the Disturbances on Forest Vegetation. *Remote Sensing*, 1914, 12.
- LI, B., GANGADHAR, S., CHENG, S., VERMA, P. K. (2011): Predicting user comfort level using machine learning for smart grid environments. *IEEE PES Innovative Smart Grid*

- Technologies Conference Europe, ISGT Europe.
- MANOJKUMAR, P., SUGUMARAN, R., ZERR, D. (2002): A rule-based classifier using classification and regression tree (CART) approach for urban landscape dynamics. International Geoscience and Remote Sensing Symposium (IGARSS), 2, 1193–1194.
- MAXWELL, A. E., WARNER, T. A., FANG, F. (2018): Implementation of machine-learning classification in remote sensing: An applied review. Taylor and Francis Ltd., 39, 2784–2817.
- MOUNTRAKIS, G., IM, J., OGOLE, C. (2011): Support vector machines in remote sensing: A review. 66, 247–259.
- NASA (2021a): Landsat 9 Overview.
- NASA (2021b): Spectral Response of the Operational Land Imager In-Band, Band-Average Relative Spectral Response, <https://landsat.gsfc.nasa.gov/landsat-8/spectral-response-operational-land-imager-band-band-average-relative-spectral-response> (28. 7. 2021).
- NOI PHAN, T., KAPPAS, M. (2017): Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors*, 18, 18.
- NOI PHAN, T., KUCH, V., LEHNERT, L. W. (2020): Land cover classification using google earth engine and random forest classifier-the role of image composition. *Remote Sensing*, 15, 12.
- NYLAND, K. E., GUNN, G. E., SHIKLOMANOV, N. I., ENGSTROM, R. N., STRELETSKIY, D. A. (2018): Land Cover Change in the Lower Yenisei River Using Dense Stacking of Landsat Imagery in Google Earth Engine. *Remote Sensing* 2018, 10, 1226, 8, 10.
- OPEN AFRICA (2020): Ethiopia shapefiles, <https://africaopendata.org/dataset/ethiopia-shapefiles> (cit. 2. 7. 2021).
- PALUBA, D., ŠTYCH, P., LAŠTOVIČKA, J. (2018): Hodnotenie metód a dát DPZ pre účely klasifikácie krajinej pokrývky na príklade bývalých vojenských obvodov Brdy a Ralsko. *Kartografické listy / Cartographic letters*, 2, 26, 76–90.
- PARAVICINI, G. (2019): Ethiopia’s Sidama vote overwhelmingly to form autonomous region, Reuters, <https://www.reuters.com/article/us-ethiopia-politics/ethiopias-sidama-vote-overwhelmingly-to-form-autonomous-region-idUSKBN1XX0GR?il=0> (cit 20. 6. 2021).
- RAMEZAN, C. A., WARNER, T. A., MAXWELL, A. E., PRICE, B. S. (2021): Effects of Training Set Size on Supervised Machine-Learning Land-Cover Classification of Large-Area High-Resolution Remotely Sensed Data. *Remote Sensing* 2021, 13, 368, 3, 13.
- RODRIGUEZ-GALIANO, V. F., GHIMIRE, B., ROGAN, J., CHICA-OLMO, M., RIGOL-SANCHEZ, J. P. (2012): An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 1, 67, 93–104.
- ROUSE, J. W., HAAS, R. H., SCHELL, J. A., DEERING, D. W. (1973): Monitoring vegetation systems in the Great Plains with ERTS. *Third Earth Resources Technology Satellite-1 Symposium*, 1.
- ROY, P. S., MIYATAKE, S., RIKIMARU, A. (1997): Biophysical spectral response modeling approach for forest density stratification. *Forestry*.
- SHAHARUM, N. S. N., SHAFRI, H. Z. M., GHANI, W. A. W. A. K., SAMSATLI, S., AL-HABSHI, M. M. A., YUSUF, B. (2020): Oil palm mapping over Peninsular Malaysia using Google Earth Engine and machine learning algorithms. *Remote Sensing Applications: Society and Environment*, 17.
- SHELESTOV, A., LAVRENIUK, M., KUSSUL, N., NOVIKOV, A., SKAKUN, S. (2017):

- Exploring Google earth engine platform for big data processing: Classification of multi-temporal satellite imagery for crop mapping. *Frontiers in Earth Science*, 5, 1–10.
- SHETTY, S. (2019): Analysis of Machine Learning Classifiers for LULC Classification on Google Earth Engine. Faculty of Geo-Information Science and Earth Observation, University of Twente.
- SIDAMA DEVELOPMENT CORPORATION (SDC) (2000): Planning and statistics bulletin.
- SILVA, V. S. da, SALAMI, G., SILVA, M. I. O. da, SILVA, E. A., JUNIOR, J. J. M., ALBA, E. (2019): Methodological evaluation of vegetation indexes in land use and land cover (LULC) classification. *Geology, Ecology, and Landscapes*, 2, 4, 159–169.
- SPIRO, R. (2020): Hyperparameter Tuning For Random Forest, [https://rspiro9.github.io/hyperparameter\\_tuning\\_for\\_random\\_forest](https://rspiro9.github.io/hyperparameter_tuning_for_random_forest). (cit. 18. 7. 2021)
- ŠTYCH, P., JERABKOVA, B., LASTOVICKA, J., RIEDL, M., PALUBA, D. (2019): A Comparison of WorldView-2 and Landsat 8 Images for the Classification of Forests Affected by Bark Beetle Outbreaks Using a Support Vector Machine and a Neural Network: A Case Study in the Sumava Mountains. *Geosciences*, 396, 9.
- ŠTYCH, P., PALUBA, D., LAŠTOVIČKA, J., OTRATA, D., HLADKÝ, R. (2018): Hodnocení změn krajinného pokryvu bývalého vojenského újezdu Brdy pomocí dálkového průzkumu Země Evaluation of the land cover changes in the former military training area Brdy using remote sensing. *Bohemia centralis*, Praha, 34, 51–73.
- SYKAS, D. (2020): SAVI and NDVI spectral index comparison, <https://www.geo.university/pages/savi-and-ndvi-spectral-index-comparison> (cit. 22. 7. 2021).
- USGS (2021a): Landsat Collection 1. [https://www.usgs.gov/core-science-systems/nli/landsat/landsat-collection-1?qt-science\\_support\\_page\\_related\\_con=1#qt-science\\_support\\_page\\_related\\_con](https://www.usgs.gov/core-science-systems/nli/landsat/landsat-collection-1?qt-science_support_page_related_con=1#qt-science_support_page_related_con) (cit. 20. 7. 2021)
- USGS (2021b): Landsat Collection 2, [https://www.usgs.gov/core-science-systems/nli/landsat/landsat-collection-2?qt-science\\_support\\_page\\_related\\_con=1#qt-science\\_support\\_page\\_related\\_con](https://www.usgs.gov/core-science-systems/nli/landsat/landsat-collection-2?qt-science_support_page_related_con=1#qt-science_support_page_related_con) (cit. 21. 7. 2021).
- USGS (2021c): Landsat Collection 2 Level-1 Data. [https://www.usgs.gov/core-science-systems/nli/landsat/landsat-collection-2-level-1-data?qt-science\\_support\\_page\\_related\\_con=1#qt-science\\_support\\_page\\_related\\_con](https://www.usgs.gov/core-science-systems/nli/landsat/landsat-collection-2-level-1-data?qt-science_support_page_related_con=1#qt-science_support_page_related_con) (cit. 21. 7. 2021)
- USGS (2021d): Landsat Satellite Missions. [https://www.usgs.gov/core-science-systems/nli/landsat/landsat-satellite-missions?qt-science\\_support\\_page\\_related\\_con=0#qt-science\\_support\\_page\\_related\\_con](https://www.usgs.gov/core-science-systems/nli/landsat/landsat-satellite-missions?qt-science_support_page_related_con=0#qt-science_support_page_related_con) (cit. 20. 7. 2021)
- YUAN, F., SAWAYA, K. E., LOEFFELHOLZ, B. C., BAUER, M. E. (2005): Land cover classification and change analysis of the Twin Cities (Minnesota) metropolitan area by multitemporal Landsat remote sensing. *Remote Sensing of Environment*, 2–3, 98, 317–328.
- ZHANG, F., YANG, X. (2020): Improving land cover classification in an urbanized coastal area by random forests: The role of variable selection. *Remote Sensing of Environment*, 251.
- ZURQANI, H. A., POST, C. J., MIKHAILOVA, E. A., SCHLAUTMAN, M. A., SHARP, J. L. (2018): Geospatial analysis of land use change in the Savannah River Basin using Google Earth Engine. *International Journal of Applied Earth Observation and Geoinformation*, 69, 175–185.



## **10 Přílohy**

V elektronické a tištěné podobě:

Příloha 1: Skript RF a dat Sentinel-2 v roce 2020

Příloha 2: Skript CART a dat Sentinel-2 v roce 2020

Příloha 3: Skript RF a dat Landsat v roce 2020

Příloha 4: Skript CART a dat Landsat v roce 2020

Příloha 5: Skript RF a dat Landsat v roce 2014

Pouze v elektronické podobě:

Příloha 6: Mapa land cover regionu Sidama (RF a data Sentinel-2 v roce 2020)

Příloha 7: Mapa land cover regionu Sidama (CART a data Sentinel-2 v roce 2020)

Příloha 8: Mapa land cover regionu Sidama (RF a data Landsat 8 v roce 2020)

Příloha 9: Mapa land cover regionu Sidama (CART a data Landsat 8 v roce 2020)

Příloha 10: Mapa land cover regionu Sidama (RF a data Landsat 8 v roce 2014)

Příloha 11: Mapa změn land cover mezi roky 2014 a 2020 (RF a data Landsat 8 2020)

## Příloha 1: Skript RF a dat Sentinel-2 v roce 2020

Dostupné online zde:

<https://code.earthengine.google.com/ce7d5c206c9ad320a6a933b71712a1fe>

```
////////// Klasifikátor Random Forest pro snímky Sentinel-2 (2020) ////////////
// vložení polygonu ohraničující region Sidama a přidání vrstvy do mapy
var sidama_borders = ee.FeatureCollection(borders);
Map.addLayer(sidama_borders, undefined, 'Sidama region borders');

// funkce na odmaskování oblačnosti snímků Sentinel-2
function maskS2clouds(sentinel) {
  var qa = sentinel.select('QA60');
  var cloudBitMask = 1 << 10;
  var cirrusBitMask = 1 << 11;
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)
    .and(qa.bitwiseAnd(cirrusBitMask).eq(0));
  return sentinel.updateMask(mask).divide(10000);
}

//// indexy
// funkce pro vytvoření indexů NDVI, SAVI, NDTI a BSI
function ndviANDsaviANDndtiANDbsi(sentinel) {
  // výpočet a uložení indexů do proměnných
  var ndvi = sentinel.expression('(NIR - Red) / (NIR + Red)', {
    'NIR': sentinel.select('B8'),
    'Red': sentinel.select('B4')
  });

  var savi = sentinel.expression('((NIR - Red) / (NIR + Red + 0.5)) * (1.0 + 0.5)', {
    'NIR': sentinel.select('B8'),
    'Red': sentinel.select('B4')
  });

  var ndti = sentinel.expression('(SWIR1 - SWIR2) / (SWIR1 + SWIR2)', {
    'SWIR1': sentinel.select('B11'),
    'SWIR2': sentinel.select('B12')
  });

  var bsi = sentinel.expression('((SWIR1 + Red) - (NIR + Blue)) / ((SWIR1 + Red) + (NIR + Blue))', {
    'SWIR1': sentinel.select('B11'),
    'Red': sentinel.select('B4'),
    'Blue': sentinel.select('B2'),
    'NIR': sentinel.select('B8')
  });

  // přidání indexů ve formě pásem do mozaiky
  return
  sentinel.addBands(savi.rename('SAVI')).addBands(ndvi.rename('NDVI')).addBands(ndti.rename('NDTI')).addBands(bsi.rename('BSI'));
}

// nahrání pásem snímků Sentinel-2 pro vybrané období a území + tvorba kompozitu
var sentinel = ee.ImageCollection('COPERNICUS/S2_SR')
  .filterDate('2020-01-01', '2020-04-01')
  .filterBounds(borders)
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 1))
  .select(['B2', 'B3', 'B4', 'B5', 'B6', 'B7', 'B8', 'B11', 'B12', 'B8A', 'QA60'])
  .map(maskS2clouds)
  .map(ndviANDsaviANDndtiANDbsi)
  .median()
  .clip(sidama_borders);

// vložení parametrů pro vizualizaci v mapě
var visParams = {
```

```
    min: 0.0,
    max: 0.3,
    bands: ['B4', 'B3', 'B2'],
  };

  // přidání kompozitu do mapy
  Map.addLayer(sentinel.reproject('EPSG:32637', null, 10), visParams, 'Sentinel-2
  kompozit');

  //// trénovací body
  // vložení trénovacích bodů + odfiltrování odlehlých bodů
  var TrainData = ee.FeatureCollection(training_points)
    .filter(ee.Filter.neq('Name', '345'))
    .filter(ee.Filter.neq('Name', '92'))
    .filter(ee.Filter.neq('Name', '58'))
    .filter(ee.Filter.neq('Name', '53'))
    .filter(ee.Filter.neq('Name', '66'))
    .filter(ee.Filter.neq('Name', '174'))
    .filter(ee.Filter.neq('Name', '187'))
    .filter(ee.Filter.neq('Name', '42'))
    .filter(ee.Filter.neq('Name', '517'))
    .filter(ee.Filter.neq('Name', '268'))
    .filter(ee.Filter.neq('Name', '69'))
    .filter(ee.Filter.neq('Name', '82'))
    .filter(ee.Filter.neq('Name', '577'))
    .filter(ee.Filter.neq('Name', '88'));

  // tvorba bufferů kolem trénovacích bodů
  var bufferzone = TrainData.map(function(f){
    return f.buffer(30);
  });
  Map.addLayer(bufferzone, {color: '008800'}, 'Training polygons');

  //// klasifikace
  // funkce pro klasifikaci kompozitu na základě zvolených parametrů
  var RF_Sentinel_20 = function(Composite, bufferzone, Attribute, Bands){
    var training = Composite.select(bands).sampleRegions({
      collection: bufferzone,
      properties: [Attribute],
      scale: 10
    });

    var classifier = ee.Classifier.smileRandomForest(250).train({
      features: training,
      classProperty: Attribute,
      inputProperties: bands
    });
    var classified = Composite.classify(classifier).rename('RF_Sentinel_20');

    return Composite.addBands(classified);
  };

  // atribut s třídami pro klasifikaci
  var label = 'class';

  // pásma na základě kterých chci klasifikovat
  var bands =
  (['BSI', 'NDTI', 'NDVI', 'SAVI', 'B2', 'B3', 'B4', 'B5', 'B6', 'B7', 'B8', 'B11', 'B12']);

  // aplikování klasifikace na mozaiku
  var RFS2Result =
  RF_Sentinel_20(sentinel, bufferzone, label, bands).select('RF_Sentinel_20');

  //// aplikace majority filtru, autor: Daniel Paluba (@danielp) 2021
```

```
// výpočet patch sizes
var patchsize = RFS2Result.connectedPixelCount(26, false);

// spuštění majority filtru
var filtered = RFS2Result.focal_mode(12.5, "square");

// aplikace majority filtru na prvky s patchsize menší 26
var final = RFS2Result.where(patchsize.lt(26),filtered);

// výpočet patch sizes
var patchsize2 = final.connectedPixelCount(26, false);

// spuštění majority filtru
var filtered2 = final.focal_mode(3, "square");

// aplikace majority filtru na prvky s patchsize menší 26
var final2 = final.where(patchsize2.lt(26),filtered2);

// výpočet patch sizes
var patchsize3 = final2.connectedPixelCount(26, false);

// spuštění majority filtru
var filtered3 = final2.focal_mode(1, "square");

// aplikace majority filtru na prvky s patchsize menší 26
var final3 = final2.where(patchsize3.lt(26),filtered3);

// přidání vrstvy do mapy
//Map.addLayer(final3, {palette:
['FF0000','654321','00FF00','006400','AA8500','FFF700','0000FF'],min: 1, max:
7 }, 'Klasifikovaný obraz RF/Sentinel-2');

//// kontrola přesnosti klasifikace
// vložení kontrolních dat
var Validation = ee.FeatureCollection(validation_points);

// accuracy assessment (CZ: hodnocení přesnosti)
var ExtractValues = final3.reduceRegions({
  collection: Validation,
  reducer: ee.Reducer.median(),
  scale: 10,
  tileScale: 16
});
//print(ExtractValues);

var testAccuracy = ExtractValues.errorMatrix('validati_3', 'median'); // výpočet
accuracy assessment

// vytisknutí výsledných hodnot
print('Overall validation: ', testAccuracy.accuracy()); // celková přesnost
print('Validation matrix: ', testAccuracy); // validační matice
print('Kappa index: ', testAccuracy.kappa()); // kappa index

// tvorba grafů spektrální odrazivosti pro jednotlivé polygony ve všech pásmech
snímku
var zastavba = bufferzone.filter(ee.Filter.eq('class', 1));
var plodiny = bufferzone.filter(ee.Filter.eq('class', 2));
var louka_pastvina = bufferzone.filter(ee.Filter.eq('class', 3));
var les = bufferzone.filter(ee.Filter.eq('class', 4));
var kroviny = bufferzone.filter(ee.Filter.eq('class', 5));
var hola_puda = bufferzone.filter(ee.Filter.eq('class', 6));
var vodni_plocha = bufferzone.filter(ee.Filter.eq('class', 7));
var chart1 =
ui.Chart.image.regions(sentinel.select(bands),zastavba,ee.Reducer.mean(),30,'Nam
```

```
e').setChartType('ScatterChart').setOptions({
    title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu zástavba'});
var chart2 =
ui.Chart.image.regions(sentinel.select(bands), plodiny, ee.Reducer.mean(), 30, 'Name
').setChartType('ScatterChart').setOptions({
    title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu plodiny'});
var chart3 =
ui.Chart.image.regions(sentinel.select(bands), louka_pastvina, ee.Reducer.mean(), 30, 'Name
').setChartType('ScatterChart').setOptions({
    title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu louka/pastvina'});
var chart4 =
ui.Chart.image.regions(sentinel.select(bands), les, ee.Reducer.mean(), 30, 'Name').s
etChartType('ScatterChart').setOptions({
    title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu les'});
var chart5 =
ui.Chart.image.regions(sentinel.select(bands), kroviny, ee.Reducer.mean(), 30, 'Name
').setChartType('ScatterChart').setOptions({
    title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu křoviny'});
var chart6 =
ui.Chart.image.regions(sentinel.select(bands), hola_puda, ee.Reducer.mean(), 30, 'Na
me').setChartType('ScatterChart').setOptions({
    title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu holá půda'});
var chart7 =
ui.Chart.image.regions(sentinel.select(bands), vodni_plocha, ee.Reducer.mean(), 30,
'Name').setChartType('ScatterChart').setOptions({
    title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu vodní plocha'});
print(chart1, chart2, chart3, chart4, chart5, chart6, chart7);

// export klasifikace do zvolené složky na Google Drive
Export.image.toDrive({
    image: final3,
    description: "RF_Sentinel_2020_filter",
    folder: "EarthEngine",
    region: sidama_borders,
    scale: 10,
    maxPixels: 1e9,
    crs: "EPSG:32637",
});
```

## Příloha 2: Skript CART a dat Sentinel-2 v roce 2020

Dostupné online zde:

<https://code.earthengine.google.com/38d735f9de3c66deb8463d7dd0257254>

```
////////// Klasifikátor CART pro snímky Sentinel-2 (2020) ////////////
// vložení polygonu ohraničující region Sidama a přidání vrstvy do mapy
var sidama_borders = ee.FeatureCollection(borders);
Map.addLayer(sidama_borders, undefined, 'Sidama region borders');

// funkce na odmaskování oblačnosti snímků Sentinel-2
function maskS2clouds(sentinel) {
  var qa = sentinel.select('QA60');
  var cloudBitMask = 1 << 10;
  var cirrusBitMask = 1 << 11;
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)
    .and(qa.bitwiseAnd(cirrusBitMask).eq(0));
  return sentinel.updateMask(mask).divide(10000);
}

//// indexy
// funkce pro vytvoření indexů NDVI, SAVI, NDTI a BSI
function ndviANDsaviANDndtiANDbsi(sentinel) {
  // výpočet a uložení indexů do proměnných
  var ndvi = sentinel.expression('(NIR - Red) / (NIR + Red)', {
    'NIR': sentinel.select('B8'),
    'Red': sentinel.select('B4')
  });

  var savi = sentinel.expression('((NIR - Red) / (NIR + Red + 0.5)) * (1.0+0.5)', {
    'NIR': sentinel.select('B8'),
    'Red': sentinel.select('B4')
  });

  var ndti = sentinel.expression('(SWIR1 - SWIR2) / (SWIR1 + SWIR2)', {
    'SWIR1': sentinel.select('B11'),
    'SWIR2': sentinel.select('B12')
  });

  var bsi = sentinel.expression('((SWIR1 + Red) - (NIR + Blue)) / ((SWIR1 + Red) + (NIR + Blue))', {
    'SWIR1': sentinel.select('B11'),
    'Red': sentinel.select('B4'),
    'Blue': sentinel.select('B2'),
    'NIR': sentinel.select('B8')
  });

  // přidání indexů ve formě pásem do mozaiky
  return
  sentinel.addBands(savi.rename('SAVI')).addBands(ndvi.rename('NDVI')).addBands(ndti.rename('NDTI')).addBands(bsi.rename('BSI'));
}

// nahrání pásem snímků Sentinel-2 pro vybrané období a území + tvorba kompozitu
var sentinel = ee.ImageCollection('COPERNICUS/S2_SR')
  .filterDate('2020-01-01', '2020-04-01')
  .filterBounds(borders)
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE',1))
  .select(['B2', 'B3', 'B4', 'B5', 'B6', 'B7', 'B8', 'B11', 'B12', 'B8A',
'QA60'])
  .map(maskS2clouds)
  .map(ndviANDsaviANDndtiANDbsi)
  .median()
  .clip(sidama_borders);

// vložení parametrů pro vizualizaci v mapě
```

```
var visualization = {
  min: 0.0,
  max: 0.3,
  bands: ['B4', 'B3', 'B2'],
};

// přidání kompozitu do mapy
Map.addLayer(sentinel, visualization, 'Sentinel-2 kompozit');

//// trénovací body
// nahrání trénovacích bodů a uložení do proměnné
var TrainData = ee.FeatureCollection(training_points)
  .filter(ee.Filter.neq('Name', '345'))
  .filter(ee.Filter.neq('Name', '92'))
  .filter(ee.Filter.neq('Name', '58'))
  .filter(ee.Filter.neq('Name', '53'))
  .filter(ee.Filter.neq('Name', '66'))
  .filter(ee.Filter.neq('Name', '174'))
  .filter(ee.Filter.neq('Name', '187'))
  .filter(ee.Filter.neq('Name', '42'))
  .filter(ee.Filter.neq('Name', '517'))
  .filter(ee.Filter.neq('Name', '268'))
  .filter(ee.Filter.neq('Name', '69'))
  .filter(ee.Filter.neq('Name', '82'))
  .filter(ee.Filter.neq('Name', '577'))
  .filter(ee.Filter.neq('Name', '88'));

// funkce na tvorbu bufferů pro klasifikaci včetně přidání vrstvy do mapy
var bufferzone = TrainData.map(function(f){
  return f.buffer(30);
});
Map.addLayer(bufferzone, {color: '008800'}, 'Training polygons');

//// klasifikace
// funkce pro klasifikaci kompozitu na základě zvolených parametrů
var CART_Sentinel_20 = function(Composite, bufferzone, Attribute, Bands){
  var training = Composite.select(bands).sampleRegions({
    collection: bufferzone,
    properties: [Attribute],
    scale: 10
  });

  var classifier = ee.Classifier.smileCart(100,10).train({
    features: training,
    classProperty: Attribute,
    inputProperties: bands
  });
  var classified = Composite.classify(classifier).rename('CART_Sentinel_20');

  return Composite.addBands(classified);
};

// atribut s třídami pro klasifikaci
var label = 'class';

// pásma na základě kterých chci klasifikovat
var bands =
(['BSI', 'NDTI', 'NDVI', 'SAVI', 'B2', 'B3', 'B4', 'B5', 'B6', 'B7', 'B8', 'B11', 'B12', 'B8A
']);

// aplikování klasifikace na mozaiku
var CARTS2Result =
CART_Sentinel_20(sentinel,bufferzone, label,bands).select('CART_Sentinel_20');
```

```
// přidání vrstvy do mapy
Map.addLayer(CARTS2Result, {palette:
  ['FF0000','654321','00FF00','006400','AA8500','FFF700','0000FF'],min: 1, max:
  7 }, 'Klasifikovaný obraz');

//// aplikace majority filtru; autor: Daniel Paluba (@danielp) 2021
// výpočet patch sizes
var patchsize = CARTS2Result.connectedPixelCount(26, false);

// spuštění majority filtru
var filtered = CARTS2Result.focal_mode(12.5, "square");

// aplikace majority filtru na prvky s patchsize menší 26
var final = CARTS2Result.where(patchsize.lt(26),filtered);

// výpočet patch sizes
var patchsize2 = final.connectedPixelCount(26, false);

// spuštění majority filtru
var filtered2 = final.focal_mode(3, "square");

// aplikace majority filtru na prvky s patchsize menší 26
var final2 = final.where(patchsize2.lt(26),filtered2);

// výpočet patch sizes
var patchsize3 = final2.connectedPixelCount(26, false);

// spuštění majority filtru
var filtered3 = final2.focal_mode(2, "square");

// aplikace majority filtru na prvky s patchsize menší 26
var final3 = final2.where(patchsize3.lt(26),filtered3);

// výpočet patch sizes
var patchsize4 = final3.connectedPixelCount(26, false);

// spuštění majority filtru
var filtered4 = final3.focal_mode(1, "square");

// aplikace majority filtru na prvky s patchsize menší 26
var final4 = final3.where(patchsize4.lt(26),filtered4);

// přidání filtrovaného výsledku do mapy
Map.addLayer(final4, {palette:
  ['FF0000','654321','00FF00','006400','AA8500','FFF700','0000FF'],min: 1, max:
  7 }, 'Klasifikovaný obraz RF/Landsat 8');

//// kontrola přesnosti klasifikace
// vložení kontrolních dat
var Validation = ee.FeatureCollection(validation_points);

// accuracy assessment (CZ: hodnocení přesnosti)
var ExtractValues = final4.reduceRegions({
  collection: Validation,
  reducer: ee.Reducer.median(),
  scale: 10,
  tileSize: 4});
print(ExtractValues);

var testAccuracy = ExtractValues.errorMatrix('validati_3', 'median'); // výpočet
accuracy assessment

// vytisknutí výsledných hodnot
print('Overall validation: ', testAccuracy.accuracy()); // celková přesnost
```



```
print('Validation matrix: ', testAccuracy);           // validační matice
print('Kappa index: ', testAccuracy.kappa());        // kappa index

// tvorba grafů spektrální odrazivosti pro jednotlivé polygony ve všech pásmech
snímku
var zastavba = bufferzone.filter(ee.Filter.eq('class', 1));
var plodiny = bufferzone.filter(ee.Filter.eq('class', 2));
var louka_pastvina = bufferzone.filter(ee.Filter.eq('class', 3));
var les = bufferzone.filter(ee.Filter.eq('class', 4));
var kroviny = bufferzone.filter(ee.Filter.eq('class', 5));
var hola_puda = bufferzone.filter(ee.Filter.eq('class', 6));
var vodni_plocha = bufferzone.filter(ee.Filter.eq('class', 7));
var chart1 =
ui.Chart.image.regions(sentinel.select(bands),zastavba,ee.Reducer.mean(),30,'Name')
.setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu zástavba'});
var chart2 =
ui.Chart.image.regions(sentinel.select(bands),plodiny,ee.Reducer.mean(),30,'Name')
.setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu plodiny'});
var chart3 =
ui.Chart.image.regions(sentinel.select(bands),louka_pastvina,ee.Reducer.mean(),30,
'Name').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu louka/pastvina'});
var chart4 =
ui.Chart.image.regions(sentinel.select(bands),les,ee.Reducer.mean(),30,'Name').s
etChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu les'});
var chart5 =
ui.Chart.image.regions(sentinel.select(bands),kroviny,ee.Reducer.mean(),30,'Name')
.setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu křoviny'});
var chart6 =
ui.Chart.image.regions(sentinel.select(bands),hola_puda,ee.Reducer.mean(),30,'Name')
.setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu holá půda'});
var chart8 =
ui.Chart.image.regions(sentinel.select(bands),vodni_plocha,ee.Reducer.mean(),30,
'Name').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu vodní plocha'});
print(chart1, chart2, chart3, chart4, chart5, chart6, chart7);

// export klasifikace do zvolené složky
Export.image.toDrive({
  image: final4,
  description: "CART_Sentinel_2020_filter2",
  folder: "EarthEngine",
  region: sidama_borders,
  scale: 10,
  maxPixels: 1e9,
  crs: "EPSG:32637",
});
```

## Příloha 3: Skript RF a dat Landsat v roce 2020

Dostupné online zde:

<https://code.earthengine.google.com/4805a23afcd958b1944b2d6e1c9819c5>

```
////////// Klasifikátor Random Forest pro snímky Landsat 8 (2020)//////////
// vložení polygonu ohraničující region Sidama a přidání vrstvy do mapy
var sidama_borders = ee.FeatureCollection(borders);
Map.addLayer(sidama_borders, undefined, 'Sidama region borders');

// funkce na odmaskování oblačnosti snímků Landsat 8
function maskL8sr(landsat) {
  var cloudShadowBitMask = (1 << 3);
  var cloudsBitMask = (1 << 5);
  var qa = landsat.select('pixel_qa');
  var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0)
    .and(qa.bitwiseAnd(cloudsBitMask).eq(0));
  return landsat.updateMask(mask).divide(10000);
}

//// indexy
// funkce pro vytvoření indexů NDVI, SAVI, NDTI a BSI
function indexes(landsat) {
  // výpočet a uložení indexů do proměnných
  var ndvi = landsat.expression('(NIR - Red) / (NIR + Red)', {
    'NIR': landsat.select('B5'),
    'Red': landsat.select('B4')
  });

  var savi = landsat.expression('((NIR - Red) / (NIR + Red + 0.5)) * (1.0+0.5)', {
    'NIR': landsat.select('B5'),
    'Red': landsat.select('B4')
  });

  var ndti = landsat.expression('(SWIR1 - SWIR2) / (SWIR1 + SWIR2)', {
    'SWIR1': landsat.select('B6'),
    'SWIR2': landsat.select('B7')
  });

  var bsi = landsat.expression('((SWIR1 + Red) - (NIR + Blue)) / ((SWIR1 + Red) + (NIR + Blue))', {
    'SWIR1': landsat.select('B6'),
    'Red': landsat.select('B4'),
    'Blue': landsat.select('B2'),
    'NIR': landsat.select('B5')
  });

  // přidání indexů ve formě pásem do mozaiky
  return
  landsat.addBands(ndvi.rename('NDVI')).addBands(savi.rename('SAVI')).addBands(ndt
i.rename('NDTI')).addBands(bsi.rename('BSI'));
}

// nahrání pásem snímků Landsat 8 pro vybrané období a území + tvorba kompozitu
var landsat = ee.ImageCollection('LANDSAT/LC08/C01/T1_SR')
  .filterDate('2020-01-01', '2020-04-01')
  .filterBounds(borders)
  .map(maskL8sr)
  .map(indexes)
  .median()
  .clip(sidama_borders);

// vložení parametrů pro vizualizaci v mapě
var visParams = {
  bands: ['B4', 'B3', 'B2'],
  min: 0.0,
  max: 0.3,
};
```

```
// přidání kompozitu do mapy
Map.addLayer(landsat.reproject('EPSG:32637', null, 30), visParams, 'Landsat 8
kompozit');

//// trénovací body
// vložení trénovacích bodů + odfiltrování odlehlých bodů
var TrainData = ee.FeatureCollection(training_points)
  .filter(ee.Filter.neq('Name', '345'))
  .filter(ee.Filter.neq('Name', '92'))
  .filter(ee.Filter.neq('Name', '264'))
  .filter(ee.Filter.neq('Name', '58'))
  .filter(ee.Filter.neq('Name', '53'))
  .filter(ee.Filter.neq('Name', '88'))
  .filter(ee.Filter.neq('Name', '268'))
  .filter(ee.Filter.neq('Name', '82'))
  .filter(ee.Filter.neq('Name', '254'))
  .filter(ee.Filter.neq('Name', '42'))
  .filter(ee.Filter.neq('Name', '77'))
  .filter(ee.Filter.neq('Name', '174'))
  .filter(ee.Filter.neq('Name', '268'));

// tvorba bufferů kolem trénovacích bodů
var bufferzone = TrainData.map(function(f){
  return f.buffer(30);
});
Map.addLayer(bufferzone, {color: '008800'}, 'Training polygons');

//// klasifikace
// funkce pro klasifikaci kompozitu na základě zvolených parametrů
var RFLandsat8 = function(Composite, bufferzone, Attribute, Bands){
  var training = Composite.select(bands).sampleRegions({
    collection: bufferzone,
    properties: [Attribute],
    scale: 30
  });

  var classifier = ee.Classifier.smileRandomForest(250).train({
    features: training,
    classProperty: Attribute,
    inputProperties: Bands
  });
  var classified = Composite.classify(classifier).rename('RFLandsat8');
  return Composite.addBands(classified);
};

// atribut s třídami pro klasifikaci
var label = 'class';

// pásma, na základě kterých chci klasifikovat
var bands = ['BSI', 'NDTI', 'NDVI', 'SAVI', 'B2', 'B3', 'B4', 'B5', 'B6', 'B7'];

// aplikování klasifikace na mozaiku
var RFL8Result =
RFLandsat8(landsat,bufferzone,label,bands).select('RFLandsat8');

//// aplikace majority filtru; autor: Daniel Paluba (@danielp) 2021
// výpočet patch sizes
var patchsize = RFL8Result.connectedPixelCount(4, false);

// spuštění majority filtru
var filtered = RFL8Result.focal_mode(3, "square");

// aplikace majority filtru na prvky s patchsize menší 4
var final = RFL8Result.where(patchsize.lt(4),filtered);
```

```
// výpočet patch sizes
var patchsize2 = final.connectedPixelCount(4, false);

// spuštění majority filtru
var filtered2 = final.focal_mode(1, "square");

// aplikace majority filtru na prvky s patchsize menší 4
var final2 = final.where(patchsize2.lt(4),filtered2);

// přidání filtrovaného výsledku do mapy
Map.addLayer(final2, {palette:
['FF0000','654321','00FF00','006400','AA8500','FFF700','0000FF'],min: 1, max:
7 }, 'Klasifikovaný obraz RF/Landsat 8');

//// kontrola přesnosti klasifikace
// vložení kontrolních dat
var Validation = ee.FeatureCollection(validation_points);

// accuracy assessment (CZ: hodnocení přesnosti)
var ExtractValues = final2.reduceRegions({
  collection: Validation,
  reducer: ee.Reducer.median(),
  scale: 30,
});
print(ExtractValues);

var testAccuracy = ExtractValues.errorMatrix('validati_3', 'median'); // výpočet
accuracy assessment

print('Overall validation: ', testAccuracy.accuracy()); // celková přesnost
klasifikace
print('Validation matrix: ', testAccuracy); // validační matice
print('Kappa index: ', testAccuracy.kappa()); // kappa index

// tvorba grafů spektrální odrazivosti pro jednotlivé polygony ve všech pásmech
snímku
var zastavba = bufferzone.filter(ee.Filter.eq('class', 1));
var plodiny = bufferzone.filter(ee.Filter.eq('class', 2));
var louka_pastvina = bufferzone.filter(ee.Filter.eq('class', 3));
var les = bufferzone.filter(ee.Filter.eq('class', 4));
var kroviny = bufferzone.filter(ee.Filter.eq('class', 5));
var hola_puda = bufferzone.filter(ee.Filter.eq('class', 6));
var vodni_plocha = bufferzone.filter(ee.Filter.eq('class', 7));
var chart1 =
ui.Chart.image.regions(landsat.select(bands),zastavba,ee.Reducer.mean(),30,'Name
').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu zástavba'});
var chart2 =
ui.Chart.image.regions(landsat.select(bands),plodiny,ee.Reducer.mean(),30,'Name'
).setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu plodiny'});
var chart3 =
ui.Chart.image.regions(landsat.select(bands),louka_pastvina,ee.Reducer.mean(),30
,'Name').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu louka/pastvina'});
var chart4 =
ui.Chart.image.regions(landsat.select(bands),les,ee.Reducer.mean(),30,'Name').se
tChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu les'});
```

```
var chart5 =
ui.Chart.image.regions(landsat.select(bands),kroviny,ee.Reducer.mean(),30,'Name')
.setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu křoviny'});
var chart6 =
ui.Chart.image.regions(landsat.select(bands),hola_puda,ee.Reducer.mean(),30,'Name')
.setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu holá půda'});
var chart7 =
ui.Chart.image.regions(landsat.select(bands),vodni_plocha,ee.Reducer.mean(),30,'Name')
.setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu vodní plocha'});
print(chart1, chart2, chart3, chart4, chart5, chart6, chart7);

// export klasifikovaného obrazu do zvolené složky na Google Drive
Export.image.toDrive({
  image: final2,
  description: "RF_Landsat_2020_filter",
  folder: "EarthEngine",
  region: sidama_borders,
  scale: 30,
  maxPixels: 1e9,
  crs: "EPSG:32637",
});
```

## Příloha 4: Skript CART a dat Landsat v roce 2020

Dostupné online z:

<https://code.earthengine.google.com/a555b9dbb60677b37c675bd1e8f85fbb>

```
////////// Klasifikátor CART pro snímky Landsat 8 (2020) ////////////
// vložení polygonu ohraničující region Sidama a přidání vrstvy do mapy
var sidama_borders = ee.FeatureCollection(borders);
Map.addLayer(sidama_borders, undefined, 'Sidama region borders');

// funkce na odmaskování oblačnosti snímků Landsat 8
function maskL8sr(landsat) {
  var cloudShadowBitMask = (1 << 3);
  var cloudsBitMask = (1 << 5);
  var qa = landsat.select('pixel_qa');
  var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0)
    .and(qa.bitwiseAnd(cloudsBitMask).eq(0));
  return landsat.updateMask(mask).divide(10000);
}

//// indexy
// funkce pro vytvoření indexů NDVI, SAVI, NDTI a BSI
function ndviANDsaviANDndtiANDbsi(landsat) {
  // výpočet a uložení indexů do proměnných
  var ndvi = landsat.expression('(NIR - Red) / (NIR + Red)', {
    'NIR': landsat.select('B5'),
    'Red': landsat.select('B4')
  });

  var savi = landsat.expression('((NIR - Red) / (NIR + Red + 0.5)) * (1.0+0.5)', {
    'NIR': landsat.select('B5'),
    'Red': landsat.select('B4')
  });

  var ndti = landsat.expression('(SWIR1 - SWIR2) / (SWIR1 + SWIR2)', {
    'SWIR1': landsat.select('B6'),
    'SWIR2': landsat.select('B7')
  });

  var bsi = landsat.expression('((SWIR1 + Red) - (NIR + Blue)) / ((SWIR1 + Red) + (NIR + Blue))', {
    'SWIR1': landsat.select('B6'),
    'Red': landsat.select('B4'),
    'Blue': landsat.select('B2'),
    'NIR': landsat.select('B5')
  });

  // přidání indexů ve formě pásem do mozaiky
  return
  landsat.addBands(savi.rename('SAVI')).addBands(ndvi.rename('NDVI')).addBands(ndti
  i.rename('NDTI')).addBands(bsi.rename('BSI'));
}

// nahrání pásem snímků Landsat 8 pro vybrané období a území + tvorba kompozitu
var landsat = ee.ImageCollection('LANDSAT/LC08/C01/T1_SR')
  .filterDate('2020-01-01', '2020-04-01')
  .filterBounds(borders)
  .map(maskL8sr)
  .map(ndviANDsaviANDndtiANDbsi)
  .median()
  .clip(sidama_borders);

// vložení parametrů pro vizualizaci v mapě
var visParams = {
  bands: ['B4', 'B3', 'B2'],
  min: 0,
  max: 0.3,
  gamma: 1.4,
};
```

```
Map.addLayer(landsat.reproject('EPSG:32637', null, 30), visParams, 'Landsat 8  
kompozit');  
  
//// trénovací body  
// vložení trénovacích bodů + odfiltrování odlehlých bodů  
var TrainData = ee.FeatureCollection(training_points)  
  .filter(ee.Filter.neq('Name', '345'))  
  .filter(ee.Filter.neq('Name', '92'))  
  .filter(ee.Filter.neq('Name', '264'))  
  .filter(ee.Filter.neq('Name', '58'))  
  .filter(ee.Filter.neq('Name', '53'))  
  .filter(ee.Filter.neq('Name', '88'))  
  .filter(ee.Filter.neq('Name', '268'))  
  .filter(ee.Filter.neq('Name', '82'))  
  .filter(ee.Filter.neq('Name', '77'))  
  .filter(ee.Filter.neq('Name', '254'))  
  .filter(ee.Filter.neq('Name', '42'))  
  .filter(ee.Filter.neq('Name', '174'))  
  .filter(ee.Filter.neq('Name', '268'));  
  
// tvorba bufferů kolem trénovacích bodů  
var bufferzone = TrainData.map(function(f){  
  return f.buffer(30);  
});  
Map.addLayer(bufferzone, {color: '008800'}, 'Training polygons');  
  
//// klasifikace  
// funkce provádějící klasifikaci  
var CARTLandsat8 = function(Composite, bufferzone, Attribute, Bands){  
  var training = Composite.select(bands).sampleRegions({  
    collection: bufferzone,  
    properties: [Attribute],  
    scale: 30  
  });  
  
  var classifier = ee.Classifier.smileCart(45,1).train({  
    features: training,  
    classProperty: Attribute,  
    inputProperties: Bands  
  });  
  var classified = Composite.classify(classifier).rename('CARTLandsat8');  
  return Composite.addBands(classified);  
};  
  
// atribut s třídami pro klasifikaci  
var label = 'class';  
  
// pásma na základě kterých chci klasifikovat  
var bands = (['BSI', 'NDTI', 'NDVI', 'SAVI', 'B2', 'B3', 'B4', 'B5', 'B6', 'B7']);  
  
// aplikování klasifikace na mozaiku  
var CARTL8Result =  
CARTLandsat8(landsat, bufferzone, label, bands).select('CARTLandsat8');  
  
// přidání vrstvy do mapy  
Map.addLayer(CARTL8Result, {palette:  
['FF0000', '654321', '00FF00', '006400', 'AA8500', 'FFF700', '0000FF'], min: 1, max:  
7 }, 'Klasifikovaný obraz Landsat8');  
  
//// aplikace majority filtru; autor: Daniel Paluba (@danielp) 2021  
// výpočet patch sizes  
var patchsize = CARTL8Result.connectedPixelCount(4, false);
```

```
// spuštění majority filtru
var filtered = CARTL8Result.focal_mode(3, "square");

// aplikace majority filtru na prvky s patchsize menší 4
var final = CARTL8Result.where(patchsize.lt(4),filtered);

// výpočet patch sizes
var patchsize2 = final.connectedPixelCount(4, false);

// spuštění majority filtru
var filtered2 = final.focal_mode(1, "square");

// aplikace majority filtru na prvky s patchsize menší 4
var final2 = final.where(patchsize2.lt(4),filtered2);

// přidání filtrovaného výsledku do mapy
Map.addLayer(final2, {palette:
['FF0000','654321','00FF00','006400','AA8500','FFF700','0000FF'],min: 1, max:
7 }, 'Klasifikovaný obraz RF/Landsat 8');

//// kontrola přesnosti klasifikace
// vložení kontrolních dat
var Validation = ee.FeatureCollection(validation_points);

// accuracy assessment (CZ: hodnocení přesnosti)
var ExtractValues = final2.reduceRegions({
  collection: Validation,
  reducer: ee.Reducer.median(),
  scale: 30,
});
print(ExtractValues);

var testAccuracy = ExtractValues.errorMatrix('validati_3', 'median'); // výpočet
accuracy assessment

// vytisknutí výsledných hodnot
print('Overall validation: ', testAccuracy.accuracy()); // celková přesnost
print('Validation matrix: ', testAccuracy); // validační matice
print('Kappa index: ', testAccuracy.kappa()); // kappa index

// tvorba grafů spektrální odrazivosti pro jednotlivé polygony ve všech pásmech
snímku
var zastavba = bufferzone.filter(ee.Filter.eq('class', 1));
var plodiny = bufferzone.filter(ee.Filter.eq('class', 2));
var louka_pastvina = bufferzone.filter(ee.Filter.eq('class', 3));
var les = bufferzone.filter(ee.Filter.eq('class', 4));
var kroviny = bufferzone.filter(ee.Filter.eq('class', 5));
var hola_puda = bufferzone.filter(ee.Filter.eq('class', 6));
var vodni_plocha = bufferzone.filter(ee.Filter.eq('class', 7));
var chart1 =
ui.Chart.image.regions(landsat.select(bands),zastavba,ee.Reducer.mean(),30,'Name
').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu zástavba});
var chart2 =
ui.Chart.image.regions(landsat.select(bands),plodiny,ee.Reducer.mean(),30,'Name'
).setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu plodiny});
var chart3 =
ui.Chart.image.regions(landsat.select(bands),louka_pastvina,ee.Reducer.mean(),30
,'Name').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu louka/pastvina});
```



```
var chart4 =
ui.Chart.image.regions(landsat.select(bands), les, ee.Reducer.mean(), 30, 'Name').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu les'});
var chart5 =
ui.Chart.image.regions(landsat.select(bands), kroviny, ee.Reducer.mean(), 30, 'Name').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu křoviny'});
var chart6 =
ui.Chart.image.regions(landsat.select(bands), hola_puda, ee.Reducer.mean(), 30, 'Name').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu holá půda'});
var chart7 =
ui.Chart.image.regions(landsat.select(bands), vodni_plocha, ee.Reducer.mean(), 30, 'Name').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu vodní plocha'});
print(chart1, chart2, chart3, chart4, chart5, chart6, chart7);

// export klasifikovaného obrazu do zvolené složky na Google Drive
Export.image.toDrive({
  image: final2,
  description: "CART_Landsat_2020_filter",
  folder: "EarthEngine",
  region: sidama_borders,
  scale: 30,
  maxPixels: 1e9,
  crs: "EPSG:32637",
});
```

## Příloha 5: Skript RF a dat Landsat v roce 2014

Dostupné online z:

<https://code.earthengine.google.com/da9f4994dcadf22f802f23d11666d4b7>

```
//////// Klasifikátor Random Forest pro snímky Landsat 8 (2014) //////////
// vložení polygonu ohraničující region Sidama a přidání vrstvy do mapy
var sidama_borders = ee.FeatureCollection(borders);
Map.addLayer(sidama_borders, undefined, 'Sidama region borders');

// funkce na odmaskování oblačnosti snímků Landsat 8
function maskL8sr(landsat) {
  var cloudShadowBitMask = (1 << 3);
  var cloudsBitMask = (1 << 5);
  var qa = landsat.select('pixel_qa');
  var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0)
    .and(qa.bitwiseAnd(cloudsBitMask).eq(0));
  return landsat.updateMask(mask).divide(10000);
}

//// indexy
// funkce pro vytvoření indexů NDVI, SAVI, NDTI a BSI
function ndviANDsaviANDndtiANDbsi(landsat) {
  // výpočet a uložení indexů do proměnných
  var ndvi = landsat.expression('(NIR - Red) / (NIR + Red)', {
    'NIR': landsat.select('B5'),
    'Red': landsat.select('B4')
  });

  var savi = landsat.expression('((NIR - Red) / (NIR + Red + 0.5)) * (1.0+0.5)', {
    'NIR': landsat.select('B5'),
    'Red': landsat.select('B4')
  });

  var ndti = landsat.expression('(SWIR1 - SWIR2) / (SWIR1 + SWIR2)', {
    'SWIR1': landsat.select('B6'),
    'SWIR2': landsat.select('B7')
  });

  var bsi = landsat.expression('((SWIR1 + Red) - (NIR + Blue)) / ((SWIR1 + Red) + (NIR + Blue))', {
    'SWIR1': landsat.select('B6'),
    'Red': landsat.select('B4'),
    'Blue': landsat.select('B2'),
    'NIR': landsat.select('B5')
  });

  // přidání indexů ve formě pásem do mozaiky
  return
  landsat.addBands(savi.rename('SAVI')).addBands(ndvi.rename('NDVI')).addBands(ndti.rename('NDTI')).addBands(bsi.rename('BSI'));
}

// nahrání pásem snímků Landsat 8 pro vybrané období a území + tvorba kompozitu
var landsat = ee.ImageCollection('LANDSAT/LC08/C01/T1_SR')
  .filterDate('2014-01-01', '2014-04-01')
  .filterBounds(borders)
  .map(maskL8sr)
  .map(ndviANDsaviANDndtiANDbsi)
  .median()
  .clip(sidama_borders);

// vložení parametrů pro vizualizaci v mapě
var visParams = {
  bands: ['B4', 'B3', 'B2'],
  min: 0,
  max: 0.3,
  gamma: 1.4,
};
```

```
// přidání kompozitu do mapy
Map.addLayer(landsat.reproject('EPSG:32637', null, 30), visParams, 'Landsat 8
composite');

//// trénovací body
// vložení trénovacích bodů + odfiltrování odlehlých bodů
var TrainData = ee.FeatureCollection(training_points)
  .filter(ee.Filter.neq('Name', '345'))
  .filter(ee.Filter.neq('Name', '333'))
  .filter(ee.Filter.neq('Name', '118'))
  .filter(ee.Filter.neq('Name', '182'))
  .filter(ee.Filter.neq('Name', '53'))
  .filter(ee.Filter.neq('Name', '88'))
  .filter(ee.Filter.neq('Name', '268'))
  .filter(ee.Filter.neq('Name', '82'))
  .filter(ee.Filter.neq('Name', '254'))
  .filter(ee.Filter.neq('Name', '42'))
  .filter(ee.Filter.neq('Name', '124'))
  .filter(ee.Filter.neq('Name', '34'))
  .filter(ee.Filter.neq('Name', '174'))
  .filter(ee.Filter.neq('Name', '66'))
  .filter(ee.Filter.neq('Name', '19'))
  .filter(ee.Filter.neq('Name', '111'))
  .filter(ee.Filter.neq('Name', '49'))
  .filter(ee.Filter.neq('Name', '58'))
  .filter(ee.Filter.neq('Name', '59'))
  .filter(ee.Filter.neq('Name', '577'))
  .filter(ee.Filter.neq('Name', '86'))
  .filter(ee.Filter.neq('Name', '38'));

// tvorba bufferů kolem trénovacích bodů
var bufferzone = TrainData.map(function(f){
  return f.buffer(30);
});
Map.addLayer(bufferzone, {color: '008800'}, 'Training polygons');

//// klasifikace
// funkce pro klasifikaci kompozitu na základě zvolených parametrů
var RFLandsat8 = function(Composite, bufferzone, Attribute, Bands){
  var training = Composite.select(bands).sampleRegions({
    collection: bufferzone,
    properties: [Attribute],
    scale: 30
  });

  var classifier = ee.Classifier.smileRandomForest(900).train({
    features: training,
    classProperty: Attribute,
    inputProperties: Bands
  });
  var classified = Composite.classify(classifier).rename('RFLandsat8');
  return Composite.addBands(classified);
};

// atribut s třídami pro klasifikaci
var label = 'class';

// pásma na základě kterých chci klasifikovat
var bands = (['BSI', 'NDTI', 'NDVI', 'SAVI', 'B2', 'B3', 'B4', 'B5', 'B6', 'B7']);

// aplikování klasifikace na mozaiku
var RFL8Result =
RFLandsat8(landsat, bufferzone, label, bands).select('RFLandsat8');
```

```
// přidání vrstvy do mapy
Map.addLayer(RFL8Result, {palette:
['FF0000','654321','00FF00','006400','AA8500','FFF700','0000FF'],min: 1, max:
7 }, 'Klasifikovaný obraz Landsat8');

//// aplikace majority filtru, zdroj: Daniel Paluba (@danielp) 2021
// výpočet patch sizes
var patchsize = RFL8Result.connectedPixelCount(4, false);

// spuštění majority filtru
var filtered = RFL8Result.focal_mode(3, "square");

// aplikace majority filtru na prvky s patchsize menší 4
var final = RFL8Result.where(patchsize.lt(4),filtered);

// výpočet patch sizes
var patchsize2 = final.connectedPixelCount(4, false);

// spuštění majority filtru
var filtered2 = final.focal_mode(1, "square");

// aplikace majority filtru na prvky s patchsize menší 4
var final2 = final.where(patchsize2.lt(4),filtered2);

// přidání filtrovaného výsledku do mapy
Map.addLayer(final2, {palette:
['FF0000','654321','00FF00','006400','AA8500','FFF700','0000FF'],min: 1, max:
7 }, 'Klasifikovaný obraz RF/Landsat 8');

//// kontrola přesnosti klasifikace
// vložení kontrolních dat
var Validation = ee.FeatureCollection(validation_points);

// accuracy assessment (CZ: hodnocení přesnosti)
var ExtractValues = final2.reduceRegions({
  collection: Validation,
  reducer: ee.Reducer.median(),
  scale: 30,
});
print(ExtractValues);

var testAccuracy = ExtractValues.errorMatrix('validati_2', 'median'); // výpočet
accuracy assessment

print('Overall validation: ', testAccuracy.accuracy()); // celková přesnost
print('Validation matrix: ', testAccuracy); // validační matice
print('Kappa index: ', testAccuracy.kappa()); // kappa index

// tvorba grafů spektrální odrazivosti pro jednotlivé polygony ve všech pásmech
snímku
var zastavba = bufferzone.filter(ee.Filter.eq('class', 1));
var plodiny = bufferzone.filter(ee.Filter.eq('class', 2));
var louka_pastvina = bufferzone.filter(ee.Filter.eq('class', 3));
var les = bufferzone.filter(ee.Filter.eq('class', 4));
var kroviny = bufferzone.filter(ee.Filter.eq('class', 5));
var hola_puda = bufferzone.filter(ee.Filter.eq('class', 6));
var vodni_plocha = bufferzone.filter(ee.Filter.eq('class', 7));
var chart1 =
ui.Chart.image.regions(landsat.select(bands),zastavba,ee.Reducer.mean(),30,'Name
').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu zástavba'});
var chart2 =
```

```
ui.Chart.image.regions(landsat.select(bands),plodiny,ee.Reducer.mean(),30,'Name')
).setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu plodiny'});
var chart3 =
ui.Chart.image.regions(landsat.select(bands),louka_pastvina,ee.Reducer.mean(),30
,'Name').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu louka/pastvina'});
var chart4 =
ui.Chart.image.regions(landsat.select(bands),les,ee.Reducer.mean(),30,'Name').se
tChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu les'});
var chart5 =
ui.Chart.image.regions(landsat.select(bands),kroviny,ee.Reducer.mean(),30,'Name'
).setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu křoviny'});
var chart6 =
ui.Chart.image.regions(landsat.select(bands),hola_puda,ee.Reducer.mean(),30,'Nam
e').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu holá půda'});
var chart7 =
ui.Chart.image.regions(landsat.select(bands),vodni_plocha,ee.Reducer.mean(),30,'
Name').setChartType('ScatterChart').setOptions({
  title: 'Spektrální odrazivost jednotlivých trénovacích bodů
pro třídu vodní plocha'});
print(chart1, chart2, chart3, chart4, chart5, chart6, chart7);

// export klasifikace do zvolené složky na Google Drive
Export.image.toDrive({
  image: final2,
  description: "RF_Landsat_2014_filter",
  folder: "EarthEngine",
  region: sidama_borders,
  scale: 30,
  maxPixels: 1e9,
  crs: "EPSG:32637",
});
```