

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

FAKULTA ŽIVOTNÍHO PROSTŘEDÍ

KATEDRA PROSTOROVÝCH VĚD



Česká
zemědělská
univerzita
v Praze

**Klasifikace vegetace z družicových hyperspektrálních
snímků**

DIPLOMOVÁ PRÁCE

Vedoucí práce: Ing. Tomáš Klouček, Ph.D.

Diplomant: Bc. Lukáš Hošek

2023

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Lukáš Hošek

Prostorové vědy v životním prostředí

Název práce

Klasifikace vegetace z družicových hyperspektrálních snímků

Název anglicky

Classification of vegetation from satellite hyperspectral imageries

Cíle práce

Cílem diplomové práce je klasifikovat krajinný pokryv, a to s důrazem na druhy zemědělských plodin, pomocí dat pořízených družicovými hyperspektrálními senzory v okolí Školního zemědělského podniku Lány (Amálie).

Dílní cíle práce souvisí s těmito výzkumnými otázkami:

- (a) Je možné pomocí družicových hyperspektrálních snímků klasifikovat jednotlivé druhy zemědělských plodin?
- (b) Jsou hyperspektrální snímky vhodnější variantou pro zjištění druhů zemědělských plodin v porovnání s volně dostupnými multispektrálními daty?
- (c) Jaký z vybraných algoritmů klasifikace je pro řešení této problematiky nejvhodnější a naopak?

Metodika

Metodiku lze rámcově rozdělit na:

- 1) Předzpracování vstupních dat;
- 2) Tvorbu referenčních dat (trénovací vs. validační);
- 3) Klasifikace krajinné pokryvu s důrazem na zemědělské plodiny;
- 4) Vyhodnocení přesnosti klasifikace;
- 5) Zodpovězení výše uvedených výzkumných otázek.

Doporučený rozsah práce

40-60 stran

Klíčová slova

dálkový průzkum Země; klasifikační algoritmy; krajinný pokryv; zemědělské plodiny; PRISMA; LANDSAT 9

Doporučené zdroje informací

- CAMPBELL, James B.; WYNNE, Randolph H. Introduction to remote sensing. Guilford Press, 2011. ISBN 16-091-8176-X
- HENNESSY, Andrew, Kenneth CLARKE a Megan LEWIS. Hyperspectral Classification of Plants: A Review of Waveband Selection Generalisability. Remote Sensing [online]. 2020, 12(1) [cit. 2023-02-21]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs12010113
- LILLESAND, Thomas M., Ralph W. KIEFER a Jonathan W. CHIPMAN. Remote sensing and image interpretation. 6th ed. Hoboken: John Wiley, c2008. ISBN 978-0-470-05245-7.
- LV, Wenjing a Xiaofei WANG. Overview of Hyperspectral Image Classification. Journal of Sensors [online]. 2020, 2020, 1-13 [cit. 2023-02-21]. ISSN 1687-725X. Dostupné z: doi:10.1155/2020/4817234
- MEHMOOD, Maryam, Ahsan SHAHZAD, Bushra ZAFAR, Amsa SHABBIR, Nouman ALI a Afaq AHMAD. Remote Sensing Image Classification: A Comprehensive Review and Applications. Mathematical Problems in Engineering [online]. 2022, 2022, 1-24 [cit. 2023-02-21]. ISSN 1563-5147. Dostupné z: doi:10.1155/2022/5880959
- Tempfli, K., Huurneman, G. C., Bakker, W. H., Janssen, L. L. F., Feringa, W. F., Gieske, A. S. M., Grabmaier, K. A., Hecker, C. A., Horn, J. A., Kerle, N., van der Meer, F. D., Parodi, G. N., Pohl, C., Reeves, C. V., van Ruitenbeek, F. J. A., Schetselaar, E. M., Weir, M. J. C., Westinga, E., & Woldai, T. (2009). Principles of remote sensing : an introductory textbook. (ITC Educational Textbook Series; Vol. 2). International Institute for Geo-Information Science and Earth Observation.
http://www.itc.nl/library/papers_2009/general/PrinciplesRemoteSensing.pdf
- WEISS, M., F. JACOB a G. DUVEILLER. Remote sensing for agricultural applications: A meta-review. Remote Sensing of Environment [online]. 2020, 236 [cit. 2023-02-21]. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2019.111402
- WILSON, Jeffrey, Chunhua ZHANG a John KOVACS. Separating Crop Species in Northeastern Ontario Using Hyperspectral Data. Remote Sensing [online]. 2014, 6(2), 925-945 [cit. 2023-02-21]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs6020925
-

Předběžný termín obhajoby

2022/23 LS – FŽP

Vedoucí práce

Ing. Tomáš Klouček, Ph.D.

Garantující pracoviště

Katedra prostorových věd

Elektronicky schváleno dne 28. 2. 2023

doc. Ing. Petra Šímová, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 1. 3. 2023

prof. RNDr. Vladimír Bejček, CSc.

Děkan

V Praze dne 30. 03. 2023

Prohlášení

Prohlašuji, že jsem bakalářskou práci na téma: Klasifikace vegetace z leteckých a družicových hyperspektrálních snímků vypracoval samostatně a citoval jsem všechny informační zdroje, které jsem v práci použil a které jsem rovněž uvedl na konci práce v seznamu použitých informačních zdrojů.

Jsem si vědom, že na moji diplomovou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů, ve znění pozdějších předpisů, především ustanovení § 35 odst. 3 tohoto zákona, tj. o užití tohoto díla.

Jsem si vědom, že odevzdáním bakalářské práce souhlasím s jejím zveřejněním podle zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů, ve znění pozdějších předpisů, a to i bez ohledu na výsledek její obhajoby.

Svým podpisem rovněž prohlašuji, že elektronická verze práce je totožná s verzí tištěnou a že s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR.

V Praze dne 31. 3. 2023

.....
Hošek Lukáš

Poděkování

Na tomto místě bych rád poděkoval vedoucímu své diplomové práce Ing. Tomášovi Kloučkovi, Ph.D., za cenné rady a odborné vedení mé práce.

Abstrakt

Pro monitoring životního prostředí je v dnešní době nenahraditelným zdrojem dálkový průzkum Země, pro nějž je v tuto chvíli zásadní rozvoj hyperspektrálních družicových senzorů umožňujících detailní zkoumání vybraných charakteristik zemského povrchu. Cílem diplomové práce bylo vyhodnotit věrohodnost klasifikace krajinného pokryvu s důrazem na druhy zemědělských plodin pomocí družicových hyperspektrálních (PRISMA) a multispektrálních (Landsat 9) snímků vysokého prostorového rozlišení. Pro obě skupiny snímků byly zvoleny klasifikační algoritmy Spectral Angle Mapper (SAM), Support Vector Machine (SVM), Neural Net (NN), Maximum Likelihood (ML) a Minimum Distance (MD). Zájmovým územím pro řešení závěrečné práce bylo širší okolí Školního zemědělského podniku Lány (tzv. Amálie). Z výsledků diplomové práce je zřejmé, že se jako nejvhodnější algoritmus pro klasifikaci vegetace na úrovni zemědělských plodin jeví klasifikátor Support Vector Machines, který dosáhl při využití hlavních komponent analýzy PCA vypočtených z hyperspektrálního snímku PRISMA celkové přesnosti 95,37 %. Vysoké celkové přesnosti výsledků dosáhl dále i klasifikátor Neural Net (92,74 %). Nejmenší přesnost byla dosažena u algoritmu Spectral Angle Mapper s hodnotou celkové přesnosti 84,13 %. U multispektrálního snímku Landsat 9 bylo dosaženo nejvyšší celkové přesnosti v případě klasifikačního algoritmu Maximum Likelihood (86,68 %). Nejnižší celkové přesnosti dosáhl klasifikátor Neural Net (49,75 %). Ze závěru práce vyplývá, že zejména snímky pořízené hyperspektrálními senzory s vysokým prostorovým rozlišením jsou vhodným nástrojem pro klasifikaci vegetace na úrovni zemědělských plodin.

Klíčová slova: dálkový průzkum Země; klasifikační algoritmy; krajinný pokryv; zemědělské plodiny; PRISMA; LANDSAT 9

Abstract:

Nowadays remote sensing is an irreplaceable resource for environmental monitoring, for which the development of hyperspectral satellite sensors enabling detailed examination of selected characteristics of the earth's surface is essential at the moment. The aim of the dissertation was to evaluate the reliability of land cover classification with an emphasis on types of agricultural crops using satellite hyperspectral (PRISMA) and multispectral (Landsat 9) images with high spatial resolution. The classification algorithms Spectral Angle Mapper (SAM), Support Vector Machine (SVM), Neural Net (NN), Maximum Likelihood (ML) and Minimum Distance (MD) were chosen for both groups of images. The area of interest of the final thesis was the wider surroundings of the Lány (so-called Amálie) agricultural school. It is evident from the results of the thesis that the Support Vector Machines classifier appears to be the most suitable algorithm for the classification of vegetation at the level of agricultural crops, which achieved an overall accuracy of 95.37 % using PCA principal components calculated from the PRISMA hyperspectral image. The Neural Net classifier also achieved a high overall accuracy of the results (92.74 %). The least accuracy was achieved with the Spectral Angle Mapper algorithm with an overall accuracy value of 84.13 %. For the Landsat 9 multispectral image, the highest overall accuracy was achieved in the case of the Maximum Likelihood classification algorithm (86.68 %). The lowest overall accuracy was achieved by the Neural Net classifier (49.75 %). The conclusion of the work shows that especially images taken by hyperspectral sensors with high spatial resolution are a suitable tool for the classification of vegetation at the level of agricultural crops. The conclusion of the work shows that especially images taken by hyperspectral sensors with high spatial resolution are a suitable tool for the classification of vegetation at the level of agricultural crops.

Keywords: remote sensing; classification algorithms; landscape cover; agricultural crops; PRISMA; LANDSAT 9


Obsah:

1. Úvod.....	1
2. Cíle práce.....	2
3. Rešerše literatury.....	3
3. 1 Spektrální chování objektů.....	3
3. 2 Hyperspektrální DPZ.....	4
3. 3 Předzpracování dat.....	5
3. 3. 1 Radiometrické korekce.....	5
3. 3. 2 Geometrická korekce.....	5
3. 3. 3 Atmosférická korekce.....	5
3. 4 Klasifikace obrazu.....	5
3. 4. 1 Klasifikace Per Pixel.....	6
3.4. 2 Algoritmy klasifikace.....	7
3. 5 Zhodnocení výsledků klasifikace.....	11
3. 6 Využitelný software.....	12
3. 7 Vesmírné mise poskytující hyperspektrální snímky.....	12
3.7. 1 EO-1.....	13
3.7. 2 PRISMA.....	13
3.7. 3 EnMAP.....	15
3.7. 4 HISUI.....	15
3.7. 5 HyspIRI.....	16
3.7. 6 CHIME.....	16
3.7. 7 PLANET.....	16
3. 8 Zhodnocení současného stavu poznání.....	16
4. Data a metodika.....	19
4. 1 Použitý software.....	19
4. 2 Použitá data.....	19
4. 3 Charakteristika zájmového území.....	20
4. 4 Tvorba legendy.....	20
4. 5 Metodika práce.....	23
4. 6 Úpravy snímků.....	24
4. 7 Klasifikace obrazu.....	26
4. 8 Post-processing snímků.....	27
4. 9 Hodnocení přesnosti.....	27

5. Výsledky	28
5.1 Porovnání výsledků klasifikace.....	32
6. Diskuse.....	33
7. Závěr.....	36
8. Seznam zdrojů informací	37
9. Seznam obrázků a tabulek.....	42
10. Seznam příloh	44

1. Úvod

Dálkový průzkum Země umožňuje získávání informací o pevnině a vodní hladině Země využitím snímků získaných z ptačí perspektivy, které v sobě implementují informaci o množství odraženého nebo emitovaného elektromagnetického záření v jedné nebo více oblastech elektromagnetického spektra (Campbell, Wynne 2011). Aplikovatelnost dálkového průzkumu Země pro monitorování různých úloh zaměřených na problematiku zemědělství již byla řešena z mnoha hledisek. Takovými specifickými aplikacemi jsou například predikce výnosů, detekce plevelů apod., které jsou důležité v tzv. precizním zemědělství. Data pro tyto aplikace poskytují různé platformy, jako jsou bezpilotní letecké prostředky (UAV), letadla či družice (Weiss et al. 2020). Technologický pokrok v optických senzorech nám v posledních letech roste rapidním způsobem a dochází tak čím dál tím více k využití hyperspektrálních senzorů. Tím se zvyšuje i dostupnost těchto dat pro koncové uživatele. Důkazem jsou i četné studie, které za poslední roky prokázaly, že právě hyperspektrální dálkový průzkum Země (DPZ) je stále žádanějším zdrojem dat nejen pro výzkum v oblasti zemědělství, ale i v analýzách zaměřených obecně na monitoring životního prostředí. A to především kvůli možnosti poskytovat souvislé a detailní údaje o spektrální odrazivosti, které umožňují sledovat i nepatrné změny vegetačního pokryvu (Wilson et al. 2014). Hyperspektrální DPZ zahrnuje získávání informací o objektech a jevech, které se nacházejí na zemském povrchu pomocí specializovaných senzorů umístěných na platformách operujících jak v zemské atmosféře (UAV, letadla), tak ve vesmíru (družice) (Campbell, Wynne 2011). Obecně je Hyperspektrální DPZ spojením moderního zobrazovacího systému a tradiční obrazové spektroskopie. Vývoj technologií UAV, leteckých i satelitních hyperspektrálních senzorů umožňující pořizování dat v úzkých spektrálních pásech ve viditelné (VIS), blízké infračervené (NIR), střední infračervené (MWIR) a krátkovlnné infračervené části (SWIR) elektromagnetického spektra, překonal dosavadní omezení multispektrálních senzorů. Hyperspektrální senzory tak umožňují shromažďovat informace ze stovek navazujících, a navíc velmi úzkých (například 10 nm) spektrálních pásem (Campbell, Wynne 2011). Informace ze stovek spektrálních pásem umožňuje konstrukci kontinuálních signatur spektrální odrazivosti, zatímco prvek úzké šířky pásma hyperspektrálních dat umožňuje hloubkové zkoumání charakteristik zemského povrchu, které by zmizely v relativně hrubých šířkách pásem získaných multispektrálními daty (Govender et al. 2019). Z těchto důvodů jsou hyperspektrální data obvykle zobrazována ve formě hyperkrychle (viz Obr. 1), která obsahuje dvě prostorové dimenze a jednu spektrální dimenzi. Pokud jde o samotné charakteristiky každého hyperspektrálního snímku, tak ten obsahuje na rozdíl od monochromatických, RGB, či multispektrálních snímků stovky vertikálně uspořádaných spektrálních kanálů umožňujících velmi přesné obrazové analýzy (Shaw, Burke 2003).



Obrázek 1: spektrální krychle (zdroj: NASA)

2. Cíle práce

Hlavním cílem diplomové práce je vyhodnotit věrohodnost klasifikace krajinného pokryvu (s důrazem na druhy zemědělských plodin) pomocí družicových hyperspektrálních a multispektrálních snímků vysokého prostorového rozlišení. Pro každou skupinu snímků budou dle dostupné literatury zvoleny potenciálně nejvhodnější klasifikační algoritmy. Tedy pro klasifikaci krajinného pokryvu na úrovni vegetace budou využity například klasifikační algoritmy Spectral Angle Mapper (SAM), Support Vector Machine (SVM), Neural Net (NN), Maximum Likelihood (ML) či Minimum Distance (MD). Zájmovým územím pro řešení závěrečné práce je širší okolí Školního zemědělského podniku Lány (tzv. Amálie).

Dílčí cíle práce souvisí s těmito výzkumnými otázkami:


- (a) Je možné pomocí družicových hyperspektrálních snímků klasifikovat jednotlivé druhy zemědělských plodin?
- (b) Jsou hyperspektrální snímky vhodnější variantou pro zjištění druhů zemědělských plodin v porovnání s volně dostupnými multispektrálními daty?
- (c) Jaký z vybraných algoritmů klasifikace je pro řešení této problematiky nejvhodnější a naopak?

3. Rešerše literatury

3. 1 Spektrální chování objektů

Základní předpoklad dálkového průzkumu Země je možnost dozvědět se o útvarech a objektech nacházejících se na zemském povrchu tím, že studujeme záření odražené nebo emitované těmito objekty. Jedná-li se o emitované záření, je zdrojem samotný objekt či útvar. V případě, že studujeme odražené záření, může být zdrojem Slunce, atmosféra nebo umělé záření (v případě aktivních sensorů). Tato pozorování tvoří vzor spektrální odezvy (spectral signature), někdy zvaný spektrální podpis objektů, díky čemuž umožňuje identifikaci zájmových prvků jako jsou různé druhy plodin, lesy nebo nerosty a tak dále (Campbell, Wynne 2011). Pomocí spektrální odrazivosti lze popsat množství odraženého záření. Můžeme tak pro daný objekt znázornit závislost mezi odrazivostí a vlnovou délkou. Graficky lze tuto závislost popsat spektrální křivkou odrazivosti. Pro dané povrchy a podmínky má křivka typický průběh. Na Obrázku 2 můžeme vidět typickou křivku pro vegetaci, holou půdu a vodu (Svatoňová et al. 2010).

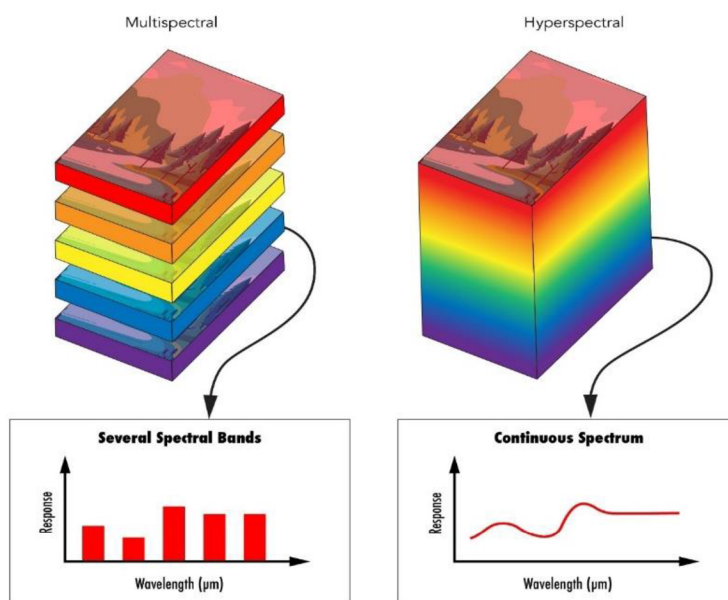
Počet informací ze spektrálních signatur roste s podrobností spektrální informace zaznamenané senzorem. U hyperspektrálních sensorů platí, že mají mnohem detailnější spektrální rozlišení než multispektrální senzory, a proto poskytují schopnost rozpoznávat jemnější rozdíly v pozemních a vodních prvcích (Mapasyst 2019).



Obrázek 2: Typická spektrální odrazivost (%) tří povrchů: vegetace, půda a voda (zdroj: Lillesand et al. 2004)

3. 2 Hyperspektrální DPZ

Hyperspektrální dálkový průzkum Země pořizuje a zpracovává informace v úzkých spektrálních pásmech ve viditelné (VIS), až krátkovlnné infračervené (SWIR) části elektromagnetického spektra s cílem získat spojitě spektrum pro každý pixel obrazu. Hyperspektrální DPZ díky této informaci umožňuje přesnou detekci objektů, identifikaci materiálu nebo monitoring různých přírodních i antropogenních procesů (Chang 2003). Hlavním rozdílem od multispektrálního zobrazování je tedy fakt, že hyperspektrální senzory zaznamenávají spektra v jemném rozlišení a pokrývají široký rozsah vlnových délek ve spojitěm spektrálním pásmu, zatímco multispektrální senzory měří nespojitá spektrální pásma rozložená nerovnoměrně napříč elektromagnetickým spektrem (Hagen, Kudenov 2013). Tento rozdíl je graficky znázorněn na obrázku č. 3. Jako každá technika nebo zařízení, lze u hyperspektrálního dálkového průzkumu Země také najít četná pozitiva i různá omezení. Mezi hlavní výhody patří jednoznačně vylepšené spektrální rozlišení poskytující podrobné informace o odrazivosti materiálů. Hyperspektrální data umožňují také detekci jemné změny ve zdravotním stavu vegetace, stresu a obsahu vody, a díky tomu poskytují unikátní pohled na dynamiku ekosystému. Tyto data taktéž umožňují zlepšit rozlišení prvků s podobnými spektrálními signatury, jako jsou různé druhy vegetace (Shukla, Kot 2016). Naopak mezi nevýhody hyperspektrálních dat patří především náklady na pořízení a vysoký objem dat, který sťažuje zpracování a ukládání. Dalším omezením je pak nižší prostorové rozlišení těchto dat, které na rozdíl od multispektrálních dat může vést ke snížení schopnosti zachytit jemné detaily (Lu et al. 2020).



Obrázek 3: Porovnání spektrálního rozlišení hyperspektrálních (vpravo) a multispektrálních (vlevo) dat. Osa x odpovídá vlnové délce (wavelength), osa y odpovídá odezvě povrchu (response). (zdroj: Drone sensors in the application of precision agriculture – Scientific Figure on ResearchGate. Dostupné z: https://www.researchgate.net/figure/Hyperspectral-and-Multispectral-sensors_fig3_351879840[cit.2022-12-29])

3. 3 Předzpracování dat

3. 3. 1 Radiometrické korekce

Jak uvádí Dobrovolný (2008), hlavním úkolem radiometrické korekce je úprava DN hodnot jednotlivých pixelů v obraze tak, aby co nejlépe odpovídaly skutečným zářivým a odrazovým vlastnostem objektů na Zemi. Tyto korekce jsou nutné kvůli vlivům atmosféry, výpadkům detektorů a dalším faktorům. V našem případě byly staženy snímky zpracované na úroveň 2 a tyto korekce jsou již provedené před poskytnutím snímku od poskytovatele dat.

3. 3. 2 Geometrická korekce

Pro eliminaci nepřesností způsobených zakřivením Země a kolísáním zdánlivé polohy objektů způsobené nadmořskou výškou se využívají geometrické korekce. Toho se dosahuje stanovením vztahu mezi systémem souřadnic obrazu a geografickým systémem souřadnic pomocí kalibračních dat snímače, naměřených údajů o poloze atd. (Lillesand et al. 2015). V našem případě není vzhledem k levelu zpracování dat tato korekce nutná, protože již je provedena poskytovatelem dat.

3. 3. 3 Atmosférická korekce

U satelitních snímků nastávají i chyby způsobené efekty atmosféry a u optického snímání mohou dramaticky změnit povahu záření a hodnoty pak neodpovídají skutečným vlastnostem snímkaných povrchů (Schowengerdt 2007). Atmosférická korekce proto slouží k přiblížení hodnot pixelů snímků ke skutečným hodnotám v momentě snímání (Dobrovolný 1998). Tato korekce již byla opět provedena před obdržetím snímků.

3. 4 Klasifikace obrazu

Množství a objem dat pořízených pomocí satelitů je v dnešní době enormní a stále exponenciálně roste. Z tohoto důvodu je třeba pro jejich efektivní zpracování mít dostupné účinné výpočetní přístupy umožňující získávání potřebných informací. Mezi těmito přístupy mají své důležité místo techniky klasifikace obrazu. Pomocí klasifikace snímků lze jednotlivé pixely (polo)automaticky zatřídit do předem stanovených sémantických kategorií. Klasifikací satelitních snímků se tedy rozumí víceúrovňový proces, který je zakončen přiřazením pixelů, případně předem vymezených objektů, do požadovaných kategorií. Tento postupný proces začíná návrhem schématu pro klasifikaci požadovaných snímků. Následně jsou snímky předzpracovány nástroji (tzv. pre-processing), které zahrnují například vylepšení obrazu, změnu měřítka atd. Další krok následně závisí na zvoleném klasifikačním přístupu, kdy se v případě řízené klasifikace vyberou požadované části snímku reprezentující tzv. trénovací data, případně vygeneruje požadovaný počet počátečních shluků představující spektrální třídy snímku (neřízená klasifikace). Poté se na snímek aplikuje vybraný klasifikační algoritmus, a tím

dochází k jeho samotné klasifikaci. Každá klasifikace může zahrnovat i následné post-klasifikační úpravy (tzv. post-processing). Posledním a velmi důležitým krokem klasifikace je výsledné posouzení její přesnosti (Mehmood et al. 2022).

Celý proces klasifikace lze provést několika přístupy či metodami. Jeden z nejpoužívanějších přístupů se nazývá tzv. klasifikace per pixel, kde jsou jednotlivé pixely klasifikovány do různých tříd krajinného pokryvu nebo využití území na základě jejich spektrálních vlastností. Druhou variantou je tzv. objektový přístup (per object), zahrnující segmentaci obrazu na objekty, které jsou následně klasifikovány na základě jejich spektrálních, prostorových a kontextových informací. V rámci klasifikace per pixel pak lze rozlišovat metody klasifikace podle využití dostupných tréninkových sad. Běžně používaná je tzv. klasifikace pod dohledem (řízená klasifikace). Zde je zahrnuto použití trénovací datové sady známých tříd krajinného pokryvu pro výuku klasifikačního algoritmu pro rozpoznávání a přiřazování pixelů do příslušných tříd (Al-Doski et al. 2013). Klasifikaci pod dohledem můžeme následně rozdělit na distribuované dělení a statistické učení, přičemž mezi typy distribuovaného učení lze zařadit metody jako logistická regrese, Support Vector Machine (SVM) a další. V případě statistických metod učení se ještě metody rozdělují na parametrické a neparametrické přístupy (Mehmood et al. 2022). Opakem je poté klasifikace bez dozoru, což je technika nevyžadující žádnou trénovací datovou sadu a místo toho seskupuje pixely na základě jejich spektrálních podobností pomocí shlukovacích algoritmů, jako jsou k-means nebo ISODATA. Dalším typem využívajícím se v dálkovém průzkumu Země je tzv. hybridní klasifikace, která kombinuje techniky klasifikace pod dohledem (řízená) a bez dozoru (neřízená), aby se využily jejich silné stránky a překonala jejich omezení. Hybridní přístup může například používat klasifikaci bez dozoru k identifikaci počátečních tříd, které se pak upřesňují pomocí přístupu klasifikace pod dohledem (Al-Doski et al. 2013). V následných kapitolách budou detailněji představeny pouze v práci použité přístupy.

3. 4. 1 Klasifikace Per Pixel

Klasifikace Per-Pixel, jinak také klasifikace po pixelech je jedna z nejpoužívanějších technik klasifikace. Jedná se o výkonnou techniku, kdy se převádějí spektrální třídy skupiny pixelů, které v příznakovém prostoru vykazují vysokou míru podobnosti na menší počet informačních tříd, které lze použít k odvození tematického popisu skutečných objektů na zemi (Dobrovolný 1998).

Řízená klasifikace:

Princip řízené klasifikace spočívá v tom, že analytik obrazu poskytuje počítači tzv. trénovací plochy. Tyto plochy jsou definovány uživatelem na základě jeho znalosti o daném povrchu/území. Na základě těchto vzorků dochází ke kalibraci klasifikačního algoritmu, který je pak aplikován na každý pixel ve snímku a dochází tak k vytvoření požadované mapy. Na úspěšnost klasifikace má zásadní vliv správné umístění, počet, i velikost trénovacích vzorků (Svatoňová et al. 2010).

Neřízená klasifikace:


Neřízená klasifikace neboli klasifikace bez dozoru funguje tak, že algoritmus automaticky rozděljuje pixely ve snímku do tzv. „přirozených shluků“. Dochází k tomu kombinací hodnot pásem, které se v obrázku běžně vyskytují. Ihned jak dojde k identifikaci těchto shluků, může je uživatel označit na základě vizuální analýzy. Tím se rozumí, že uživatel přidá jednotlivým klasifikačním třídám informační charakter na základě toho, kde se shluky na snímku nacházejí. Z velké části se jedná o automatický proces, avšak uživatel před spuštěním musí definovat několik vstupních parametrů jako je interval počtu tříd, maximální počet iterací či treshold (Knudby 2021).

3.4. 2 Algoritmy klasifikace

V této kapitole jsou popsány metody klasifikace aplikované na snímky použité v řešení této práce. Celkem bylo použito pět algoritmů klasifikace založených na přístupu per pixel. Postupně je zde představen algoritmus Spectral Angle Mapper (SAM), Neural Net (NN), Support Vector Machines (SVM), Maximum Likelihood (ML) a Minimum Distance (MD).

Spectral Angle Mapper (SAM):

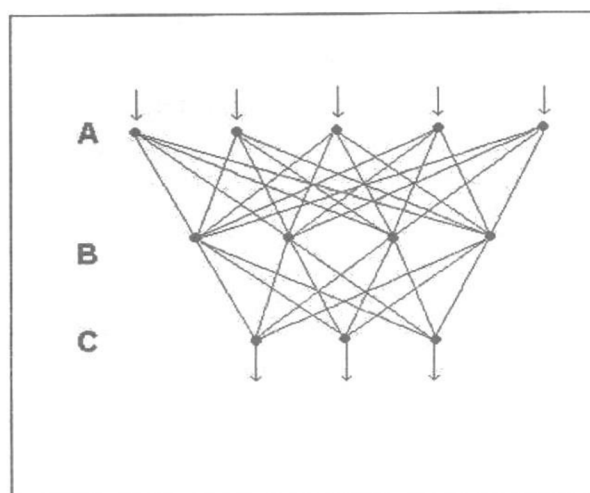
Jedná se o spektrální klasifikaci, která používá n -D úhel k přiřazení pixelů ke vzorovému spektru. Algoritmus vypočte úhel mezi spektry a nakládá s nimi jako s vektory s rozměrem rovným počtu pásem a tím určuje spektrální podobnost mezi dvěma spektry. Pokud používáme kalibrovaná data odrazivosti, je tato technika poměrně necitlivá na osvětlení a albedo efekty. Spektra koncových členů lze extrahovat přímo ze snímku jako střední spektra oblasti zájmu (Region Of Interest; ROI). Spectral Angle Mapper (SAM) porovnává úhel mezi vektorem spektra koncového členu a každým pixelovým vektorem n -D prostor (viz Obr. 4). Bližší shodu se vzorovým spektrem představují menší úhly. Do klasifikace nejsou zahrnuty pixely, které se nacházejí ve větší vzdálenosti, než je zadaný maximální úhel v radiánech (Kruce et al. 1993).



Obrázek 4: Spektrální úhel mezi dvěma materiály A a B v rámci dvou kanálů (zdroj: KRUCE et al. 1993 in LUMME, 2004)

Neural Net (NN):


Neuronové sítě jsou jednou z technik strojového učení a jsou inspirovány lidským mozkem. Jedná se o vrstvy uzlů obsahující vstupní vrstvu, několik skrytých vrstev a výstupní vrstvu (viz Obr. 5). Jednotlivé uzly se připojují k dalším a mají přidruženou váhu a práh. V případě přesažení zadané prahové hodnoty výstupem kteréhokoliv uzlu dochází k aktivaci a odeslání dat do další z vrstev sítě. Pokud není zadaná hodnota překročena, tak do další vrstvy nejsou předány žádná data. Pro naučení a zlepšení přesnosti v průběhu času se neuronové sítě spoléhají na trénovací data. V momentě, kdy jsou tyto učební algoritmy vyladěny, umožňují velmi přesnou a rychlou klasifikaci nejen dat DPZ. Klasifikace využívající neuronové sítě umožňují kombinaci různých typů vstupních dat (Dobrovolný 1998).



Obrázek 5: Schematizované uspořádání Neuronové sítě. Input – vstupní vrstva, Hidden – skrytá vrstva, Output – výstupní vrstva (Zdroj: Dobrovolný 1998)

Support Vector Machines (SVM):


Jedná se o metodu strojového učení, která je v poslední době považována za velmi zajímavou pro klasifikaci dat v dálkovém průzkumu Země. Tento algoritmus se snaží objevit ideální oddělovací nadrovinu mezi třídami tak, že se zaměřuje na tréninkové vzorky, které jsou umístěny na okraji označených tříd (viz Obr. 6). Tyto tréninkové vzorky se nazývají podpůrné vektory (tzv. support vectors). Tréninkové vzorky jiné než podpůrné vektory jsou vyřazeny z výpočtu, díky čemuž dochází k využití optimální nadroviny a také se efektivně použije méně tréninkových vzorků, čímž je dosaženo vysoké přesnosti klasifikace i s malým počtem trénovacích dat (Mercier, Lennon 2003). Zvláště pro datové sady použité k objektově založené analýze obrazu, kde bývá počet vzorků objektů menší než u metody per pixel, je využití algoritmu SVM velmi výhodné.



Obrázek 6: Princip vzniku možnosti lineárního oddělení dvou tříd s nelineárními hranicemi pomocí přidané dimenze (zdroj: SVM 2013)

Maximum Likelihood (ML):

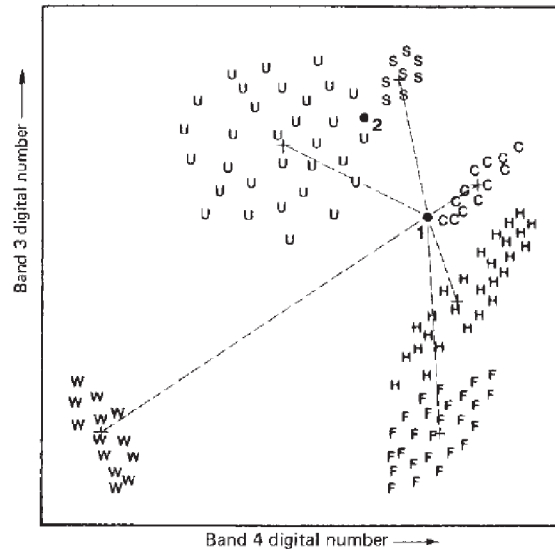
Klasifikátor Maximum Likelihood je založen na výpočtu pravděpodobnosti umožňující zařazení daného pixelu do určité třídy (viz Obr. 7). Tento klasifikátor vyžaduje, aby vstupní pásma měla normální rozložení a pravděpodobnosti zařazení pixelů byly stejné pro všechny třídy. Určovaný pixel je přiřazen třídě s nejvyšší pravděpodobností, pokud není definována žádná prahová hodnota. Pokud je prahová hodnota stanovena a nejvyšší pravděpodobnost je menší než tato hodnota, pixely se nezařadí (Koch 2011).



Obrázek 7: Schéma zařazování pixelů k jednotlivým spektrálním třídám pomocí klasifikátoru Maximum Likelihood (zdroj: Lillesand et al. 2015)

Minimum Distance (MD):

Tento klasifikátor pracuje se vzdálenostmi mezi středy shluků. Jedná se o jednoduchý algoritmus, který je méně citlivý na rozdílný rozptyl ve spektrálním prostoru. Funkčnost spočívá v porovnávání vzdáleností mezi centroidy (středy) jednotlivých shluků, což jsou vypočítané průměry spektrálních hodnot pro každou třídu a pásmo, a vzdáleností mezi zkoumaným pixelem (viz Obr. 8). Podle pravidla nejmenší vzdálenosti se pixel přiřadí ke shluku s nejbližším středem (Dobrovolný 1998).



Obrázek 8: Schéma zařazování pixelů k jednotlivým spektrálním třídám pomocí klasifikátoru Minimum Distance (zdroj: Lillesand et al. 2015)

3. 5 Zhodnocení výsledků klasifikace

Výsledkem klasifikace obrazu je rastrový soubor obsahující jednotlivé prvky rastru (pixely nebo objekty) reprezentující konkrétní třídu. Jelikož je klasifikace založená na vzorcích tříd, je vždy nutné přistoupit ke kontrole kvality výsledku. To se většinou provádí tak, že se vybrána skupina rastrových prvků z výsledné klasifikace porovnává se skutečností. Toto porovnání je reprezentováno pomocí chybové matice, ze které lze dopočítat různé míry přesnosti (Tempfli et al. 2009).

Pro ověření a vyhodnocení přesnosti klasifikace je klíčové mít k dispozici referenční data, s nimiž můžeme porovnávat výsledky. Referenční data lze získat prostřednictvím terénních měření v dané oblasti. Pokud však není možné získat dostatečné množství referenčních dat z terénu, lze vytvořit kontrolní data pomocí náhodně generovaných bodů, jimž je přiřazena kategorie podle předem určené legendy z větší kvalitativní úrovně než klasifikovaný snímek. K přidělení kategorií jednotlivým náhodným bodům se zpravidla využívá dostupné ortofoto. Existují různé metody generování náhodných kontrolních bodů pro kontrolu a vyhodnocení přesnosti klasifikace. Metoda "Simple random" generuje body náhodně po celé ploše snímku, ale může vést k nedostatečné reprezentaci kategorií s nízkou zastoupeností. Metoda "Simple systematic" vytváří body v pravidelné mřížce, což může vést k podobným nedostatkům. Nejvhodnější přístup pro naše účely je "Stratified random", který generuje kontrolní body pro každou kategorii legendy v poměru k jejímu zastoupení v daném území (Lillesand et al. 2008).

Pomocí tzv. chybové matice pak lze přistoupit k samotnému hodnocení výsledku klasifikace. Chybová matice má stejný počet řádků a sloupců jako je počet tříd v legendě. Jak uvádí Lillesand et al. (2008), chybová matice je klíčovým nástrojem pro hodnocení přesnosti klasifikace obrazu z náhodných kontrolních bodů. Tato matice

poskytuje užitečné informace o uživatelské přesnosti, což je pravděpodobnost, že pixel bude zařazen do správné třídy a tato třída bude odpovídat skutečnému pokryvu. Chybová matice také poskytuje zpracovatelskou přesnost, což je podíl správně klasifikovaných pixelů k počtu pixelů použitých pro danou třídu. Pro zjištění celkové přesnosti celé klasifikace je užití chybové matice stěžejním krokem (Lillesand et al. 2008).

Dobrovolný (1998) i Lillesand (2015) také upozorňují na důležitost tzv. Kappa koeficientu, jako ukazatele přesnosti klasifikace. Tento koeficient se zaměřuje na porovnání skutečné přesnosti klasifikace s přesností, která by byla dosažena čistě náhodným zařazením pixelů do kategorií. Kappa koeficient je číslo v rozsahu 0 až 1, kde vyšší hodnoty znamenají větší shodu mezi klasifikací a referenčními daty, zatímco nižší hodnoty naznačují menší shodu. O dobrém výsledku klasifikace lze mluvit, pokud kappa koeficient nabývá hodnot větších než 0,75.

3. 6 Využitelný software

Specializovaný DPZ software je možné využít ke zpracování a analýze dat pořízených různými platformami, jako jsou satelity, drony a letadla, tak na nich umístěnými senzory (RGB, multispektrální, hyperspektrální, termální atd.). Prostřednictvím takto nasnímaných dat spolu s vhodným softwarem lze získávat informace o vlastnostech objektů na zemského povrchu. Pro práci s daty dálkového průzkumu Země lze v současnosti využít nespočet programů. Dostupnost těchto programů je však různá. K zobrazení, úpravám a analýzám hyperspektrálních i multispektrálních snímků pořízených leteckými či družicovými prostředky jsou na trhu volně dostupné softwary, jako je například EnMAP-BOX (QGIS), SAGA GIS, ESA SNAP, LEOWorks či další. Existuje i ovšem mnoho komerčních programů pro práci s těmito daty. Mezi nejznámější a nejvyužívanější komerční programy v současnosti patří určitě ArcGIS Pro, či ENVI.

3. 7 Vesmírné mise poskytující hyperspektrální snímky

V posledních letech dochází k stále častějšímu využívání hyperspektrálních dat, a proto v současnosti roste i počet družic s hyperspektrální senzory. Níže jsou uvedeny hyperspektrální družice vypuštěné v minulých letech, současně aktivní družice i plánované mise do budoucna. Jedná se o mise EO-1, PRISMA, EnMAP, HISUI, HypsIRI či plánovaná mise CHIME (Sentinel 10), viz Tabulka 1.

Název mise	Začátek mise	Hyperspektrální senzor	Prostorové rozlišení [m]	Počet pásem
EO-1	23.11.2000	Hyperion	30	220
PRISMA	22.03.2019	HySPA	30	223
EnMAP	01.03.2022	HSI	30	244
HISUI	05.12.2019	TANSO-FTS	30	233
HyspIRI	2024	HyspIRI	60	224
CHIME	2028	HSI	30	> 200
PLANET	2023	--	30	400

Tabulka 1: Přehled hyperspektrálních družic (zdroj: autor)

3.7. 1 EO-1

EO-1 (Earth Observing-1) byl satelit vypuštěn NASA 21. listopadu 2000. Byl navržen k testování a demonstraci pokročilých technologií a strategií pro pozorování Země, včetně nových senzorů a zobrazovacích systémů. EO-1 byl vybaven třemi hlavními přístroji: Advanced Land Imager (ALI), zobrazovacím spektrometrem Hyperion a Atmospheric Corrector (AC). Přístroj ALI byl multispektrální zobrazovací systém, který dokázal zachytit data v 9 spektrálních pásmech s prostorovým rozlišením až 30 metrů. Zobrazovací spektrometr Hyperion byl hyperspektrální přístroj, který dokázal zachytit data ve 220 spektrálních pásmech s prostorovým rozlišením 30 metrů. Přístroj AC byl použit ke korekci atmosférického zkreslení a ke zlepšení kvality dat shromážděných ostatními přístroji. EO-1 byl také navržen tak, aby byl vysoce ovladatelný a flexibilní, se schopností změnit svou oběžnou dráhu a cílové oblasti zájmu v krátké době, což vědcům umožnilo testovat nové pozorovací strategie a rychle reagovat na přírodní katastrofy a další události. Co se týče provozu, tak satelit EO-1 zůstal aktivní přes 17 let, během kterých nashromáždil velké množství dat a pomohl pokročit v oblasti pozorování Země. V roce 2017 NASA oznámila, že družici vyřadí z provozu. K ukončení došlo tedy následně 30. března 2017. Data shromážděná EO-1 však zůstávají cenná a výzkumníci a vědci z celého světa je stále využívají pro různé aplikace, včetně monitorování životního prostředí, řízení přírodních zdrojů a reakce na katastrofy. Pořízené snímky jsou pro uživatele dostupné dodnes zdarma např. na USGS EarthExploreru (NASA 2023).


3.7. 2 PRISMA

PRISMA (PRecursores IperSpettrale della Missione Applicativa) je italská družice pro pozorování Země vyvinutá Italskou kosmickou agenturou (ASI). Vypuštěná byla 22. března 2019 a v současnosti je stále v provozu. Jde o hyperspektrální družici určenou k zachycování detailních informací o zemském povrchu v mnoha úzkých spektrálních pásmech (viz Obr. 9).



Obrázek 9: družice PRISMA (zdroj: ASI)

PRISMA je vybavena pokročilým hyperspektrálním senzorem s názvem Hyperspectral PRISMA Application (HySPA), který dokáže zachytit data až v 223 spektrálních pásmech s prostorovým rozlišením 30 m (Obr. 10). Toto vysoké spektrální rozlišení umožňuje shromažďovat podrobné informace o chemických a fyzikálních vlastnostech zemského povrchu, včetně vegetačního pokryvu, složení půdy a kvalitě vody. Jednou z jedinečných vlastností PRISMA je jeho schopnost zaměřit se na konkrétní oblasti zájmu na zemském povrchu pomocí ukazovacího systému, který umožňuje zachytit data z více úhlů. Díky této schopnosti je ideální pro aplikace, jako je průzkum nerostů, monitorování plodin a monitorování životního prostředí. PRISMA je také navržena tak, aby byla vysoce aktivní a flexibilní, se schopností rychle upravit svou orbitu a cílové oblasti zájmu. Tato flexibilita umožňuje rychle reagovat na přírodní katastrofy a další události a poskytuje cenná data pro podporu úsilí o reakci na katastrofy. Jeho vysoké spektrální rozlišení a flexibilní ukazovací systém z něj činí cenný nástroj pro řadu vědeckých a komerčních aplikací (ASI 2023).



Obrázek 10: Fotografie optické hlavy Hyp/Pan FM (Flight Model) přístroje PRISMA (zdroj: Selex ES)

3.7. 3 EnMAP

EnMAP (Environmental Mapping and Analysis Program) je německá družicová mise pro pozorování Země vyvinutá německým leteckým střediskem (DLR) a vypuštěná 1. dubna 2022. Jedná se o hyperspektrální družici navrženou pro sběr podrobných informací o zemském povrchu v širokém rozsahu spektrálních pásem. Tento satelit je vybavený hyperspektrálním senzorem (HSI), který dokáže zachytit data až ve 244 spektrálních pásmech s prostorovým rozlišením 30 m. Jednou z jedinečných vlastností EnMAP je jeho schopnost zachytit data v širokém rozsahu pozorovacích úhlů, což mu umožňuje generovat 3D mapy zemského povrchu. Díky této schopnosti je ideální pro aplikace, jako je průzkum nerostů, správa lesů a městské plánování. Opět je také navržen tak, aby byl vysoce flexibilní se schopností rychle upravit svou orbitu a cílové oblasti zájmu (EnMAP 2023).

3.7. 4 HISUI

HISUI (Hyper-spectral Imagery Suite) je japonská družice pro pozorování Země vyvinutá japonskou agenturou pro letectví a kosmonautiku (JAXA). Byla vypuštěná 5. prosince 2019. Jedná se o hyperspektrální družici, která je vybavena dvěma pokročilými senzory. První z nich je hyperspektrální senzor Thermal And Near-infrared Sensor for Carbon Observation-Fourier Transform Spectrometer (TANSO-FTS) a druhým je multispektrální senzor nazývaný TANSO-Cloud and Aerosol Imager (TANSO-CAI). Senzor TANSO-FTS dokáže zachytit data až ve 233 spektrálních pásmech s prostorovým rozlišením až 30 m, zatímco senzor TANSO-CAI dokáže zachytit data ve čtyřech multispektrálních pásmech s prostorovým rozlišením až 10 metrů.

3.7. 5 HypSIIRI

HypSIIRI (Hyperspectral Infrared Imager) je navrhovaná mise NASA pro pozorování Země, která je v současné době ve vývoji. Jedná se o hyperspektrální satelit navržený pro sběr dat ve viditelné až krátkovlnné infračervené (VSWIR) a termální infračervené (TIR) oblasti elektromagnetického spektra. Bude vybaven snímacím spektrometrem VSWIR, který bude získávat data až v 224 spektrálních pásmech s prostorovým rozlišením až 60 metrů, zatímco přístroj TIR bude snímat data až v 10 spektrálních pásmech s prostorovým rozlišením až 120 metrů. HypSIIRI je stále ve fázi vývoje, a ještě nebyl spuštěn (NASA 2023).

3.7. 6 CHIME

CHIME (Copernicus Hyperspectral Imaging Mission for the Environment), neboli Sentinel 10, je mise pro pozorování Země v rámci programu ESA Copernicus plánovaná na rok 2028. Bude složená ze dvou satelitů CHIME-A a CHIME-B. Každá družice ponese HyperSpectral Imager (HSI), což je pokročilý hyperspektrální senzor schopný zobrazovat více než 200 spektrálních pásem ve viditelném až krátkovlnném infračerveném spektru (VSWIR). Prostorové rozlišení bude mít 30 m pro šířku záběru 130 km. V rámci jeho využití jsou plánovány aplikace, které se týkají biologické rozmanitosti a udržitelnosti ekosystémů, hospodaření v lesích, zhoršování životního prostředí, jezerních/pobřežních ekosystémů, kvality vody a vlastností sněhu (ESA 2023).

3.7. 7 PLANET

Jedná se hyperspektrální konstelaci družic, vyvíjenou prostřednictvím partnerství veřejného a soukromého sektoru Carbon Mapper. V plánu je vypuštění prvních dvou hyperspektrálních satelitů v roce 2023 s cílem shromažďovat data ve 400 pásmech a 30 m prostorovém rozlišení. Zatímco Carbon Mapper Coalition bude veřejně sdílet data týkající se zdrojů metanu a oxidu uhličitého, společnost Planet spojí hyperspektrální data s elektrooptickými snímky získanými jejími satelitními flotilami Dove, Pelican a SkySat. Tyto informace a poznatky budou poskytovány vládním i komerčním zákazníkům (PLANET 2023).

3. 8 Zhodnocení současného stavu poznání

Přestože v současnosti jsou satelitní hyperspektrální data dostupná z několika družic, publikací zabývajících se tematikou precizního zemědělství využívajících právě data z hyperspektrálních družic není mnoho. Většina dostupných prací v této oblasti využívá hyperspektrálních senzorů umístěných na letadlech či na bezpilotních prostředcích, případně využívají data z přenosných spektrometrů.

Dostupné práce se obecně zabývají širokou škálou témat využívajících se v precizním zemědělství, jako je například studie publikovaná MIRZAEI et al. (2019), kteří v ní aplikovali pět ošetření stresu těžkými kovy (Cu, Zn, Pb, Cr a Cd) na semena vinné révy s využitím hyperspektrálních dat v rozsahu vlnových délek 350–2500 nm. Obsahy těžkých kovů byly shromážděny na základě terénních a laboratorních experimentů. Pro účely modelování byly použity metody Support Vector Machines (SVM) a vícenásobná lineární regrese. Pásma VIS a red edge byly v této studii shledány nejvhodnějšími pro odhad obsahu těžkých kovů. Autoři poukázali na to, že každý těžký kov má zvláštní účinek, který vede k odlišným reakcím v závislosti na rostlinném druhu (včetně změn barvy listů, chlorózy, nekrózy atd.).

Ve svém článku Yan et al. (2019) prozkoumali použití bezpilotních leteckých prostředků (UAV) a více úhlového (multi-angle) hyperspektrálního dálkového průzkumu pro precizní klasifikaci vegetace. Aby toho dosáhli, zkombinovali model obousměrné distribuční funkce reflektance (BRDF) s objektově orientovanými klasifikačními technikami. Jejich zjištění odhalila, že určité spektrální pásy, jako je modré pásmo (466 nm–492 nm), zelené pásmo (494 nm–570 nm), červené pásmo (642 nm–690 nm), pásmo red edge (694 nm–774 nm) a blízké infračervené pásmo (810 nm–882 nm), byly zvláště důležité pro přesnou klasifikaci různých typů vegetace. Podrobně také diskutovali o důležitosti charakteristických parametrů BRDF. Celkově výzkum naznačuje, že více úhlovou technologii dálkového průzkumu lze efektivně použít pro extrakci informací o vegetaci. Výsledky mají důležité teoretické a praktické důsledky pro vegetační a ekologický monitoring, a to jak v regionálním, tak v globálním měřítku.

Hyperspektrální data z bezpilotních prostředků bylo například využito i v práci Papp et al. (2021), která se zabývá problematikou invazivních druhů na území Maďarska. Cílem této studie tak bylo pomocí hyperspektrálních UAV snímků zmapování a sledování šíření klejichy obecné, která je jedním z nejběžnějších invazivních druhů rostlin v Evropě. Samotná detekce klejichy obecné byla založena na kombinaci dat získaných terénním měřením s hyperspektrálními UAV snímky. Pro odlišení jednotlivých exemplářů klejichy obecné od jiných invazivních druhů byly využity klasifikační algoritmy Support Vector Machines (SVM) a Neural Net (NN). Algoritmus SVM dosáhl celkové přesnosti 92,95 % a model NN celkové přesnosti 99,61 %. Navržený přístup byl následně ověřen provedením dvou experimentálních testů, které dokázaly rozlišit jednotlivé exempláře klejichy obecné na studijní ploše 2 ha s vysokou mírou přesnosti, a to na základě hyperspektrálních UAV snímků s centimetrovým prostorovým rozlišením.

Umělé neuronové sítě (ANN) k hodnocení hyperspektrální odezvy salátu (*Lactuca sativa* L.) vyvolaného vodním stresem využili ve své studii Osco et al. (2019). Hyperspektrální odezva byla měřena pomocí ručního spektrometru ASD Fieldspec HandHeld čtyřikrát po dobu 14 dnů a byla provedena měření jak odraznosti, tak absorbance. Mimo ně, studie dále hodnotila různé biofyzikální parametry. Úspěšnost ANN byla porovnána s jinými algoritmy strojového učení. Výsledky studie ukázaly, že přístup založený na ANN dokázal rozlišit mezi vodou stresovanými a nestresovanými skupinami salátů až s 80 % přesností. Dále bylo zjištěno, že údaje o absorbanci jsou pro modelování vodního stresu přínosnější než údaje o odrazivosti.

Další z výzkumníků využívajících přenosný spektrometr ASD FieldSpec byli například Wilson et al. (2014), kteří ve své studii prozkoumávali schopnosti úzkých pasem v rozsahu 400–900 nm (NIR) pro rozlišení 5 plodin běžně pěstovaných v Ontariu, Kanada. K analýze dat přistoupili s použitím diskriminační analýzy a došli k závěru, že plodiny v severovýchodním Ontariu lze rozlišit pomocí hyperspektrálních dat zachycených ručním přenosným spektrometrem s relativně vysokým stupněm přesnosti a spolehlivosti.

Tvrzení, že využití hyperspektrálních dat v oboru dálkového průzkumu Země neustále roste, potvrzují ve své rešeršní studii zaměřené na klasifikaci rostlin Hennessy et al. (2020). Ve studii autoři přezkoumali za posledních 22 let publikovanou literaturu o klasifikaci vegetace z hyperspektrálních snímků. Ze studie například vyplývá, že nejpoužívanějšími klasifikačními přístupy v této problematice jsou postupná diskriminační analýza (SDA), Support Vector Machines (SVM) a Random Forest (RF). Závěry práce dále potvrzují, že úspěšnost klasifikace mimo samotného algoritmu ovlivňuje i volba vhodného spektrálního pásma.

Sabat-Tomala et al. (2020) provedli studii s cílem porovnat výkon dvou algoritmů strojového učení – Support Vector Machines (SVM) a Random Forest (RF) při klasifikaci invazivních a expanzivních druhů rostlin pomocí hyperspektrálních dat získaných z leteckých skenerů. Invazivní a expanzivní druhy jsou hrozbou pro biologickou rozmanitost kvůli své přizpůsobivosti a schopnosti prospívat v různých stanovištích. Studie vytvořila mapy prostorového rozšíření analyzovaných druhů a klasifikátory SVM i RF dosáhly vysoké úrovně přesnosti pro všechny soubory dat. Výzkumníci konkrétně zkoumali, zda invazivní/expanzivní druhy (*Rubus spp.*, *Calamagrostis epigejos* a *Solidago spp.*) měly specifické spektrální vlastnosti, které je mohly odlišit od okolní vegetace, která často vytvářela smíšené a nejasné vzory. Kromě toho výzkumníci analyzovali dopad počtu pixelů v trénovací datové sadě na přesnost klasifikace. Ze závěrů studie vyplývá, že letecká hyperspektrální data dokážou s dostatečnou přesností identifikovat invazivní a expanzivní druhy rostlin, a to i v heterogenních stanovištích.

Taktéž Wenjing, Xiaofei (2020) ve svém článku porovnávají použití jednotlivých klasifikačních algoritmů pro hyperspektrální data včetně klasifikace pod dohledem a bez dozoru a klasifikace s polodozorem. V závěru uvádí, že ačkoliv metody pod dozorem i bez dozoru mají značné výhody, je třeba počítat i s existujícími omezeními při aplikaci různých klasifikačních metod. Uvádí, že například řízená klasifikace vyžaduje definovat určitý počet vstupních podmínek a samotné výsledky klasifikace může významně ovlivňovat lidský faktor. Proto je vhodné k získání kvalitnějšího výsledku přistoupit ke kombinaci více metod.

Zajímavou studií, zkoumající potenciál tepelných infračervených spekter hyperspektrální emisivity, která využívá 3456 spektrálních pásem mezi 2,5 až 14,0 μm pro klasifikaci třinácti různých druhů rostlin je práce Hasan et al. (2019). Použití této technologie pro identifikaci vegetace je svým způsobem unikátní. K samotné klasifikaci byly použity tři metody strojového učení – Support Vector Machine (SVM), Artificial Neural Network (ANN) a Convolutional Neural Network (CNN). Algoritmus CNN dosáhl celkové přesnosti 99 %, ANN 94 % a SVM 91 %. Ze závěru studie tak jasně vyplývá, že tepelné infračervené hyperspektrální snímky

v kombinaci s pokročilými metodami strojového a hlubokého učení umožňují velmi přesnou identifikaci druhů vegetace.

Problematikou hyperspektrálního snímkování se nezabývají jen odborné vědecké studie, ale lze nalézt i několik závěrečných prací. Namátkou můžeme jmenovat diplomovou práci od Bc. Marty Andrštové z roku 2014, která se věnuje využití hyperspektrálních dat pro klasifikaci vegetace v Krkonoších. Tato práce srovnává několik algoritmů, které jsou vhodné pro klasifikaci vegetace v alpínském bezlesí v Krkonoších pomocí snímků pořízených senzory AISA DUAL a APEX, které jsou nesené letadlem. Nejlepších výsledků dosáhl algoritmus Neural Net s celkovou přesností 96 % pro data APEX a u AISA DUAL 90 %.

4. Data a metodika

4. 1 Použitý software

K řešení této práce byl použitý komerční program ENVI 5.6., který obsahuje veškeré nástroje k úpravě, zpracování a analýze hyperspektrálních i multispektrálních dat. Taktéž obsahuje pestrou nabídku klasifikačních algoritmů, které jsou v této práci využité. K identifikaci a úpravě kontrolních bodů nad dostupným ortofotem a vizualizaci finálových výstupů jednotlivých klasifikací byl použit program ArcGIS Pro. Pro tvorbu tabulek byl využíván Microsoft Excel.

4. 2 Použitá data

Pro potřeby této práce bylo využito snímků ze dvou družic. Hyperspektrální snímek byl nasnímán družicí PRISMA a pochází z 21. června 2022. Výsledný produkt obdrženy od italské kosmické agentury (ASI) byl předzpracovaný na úroveň 2D (Level-2D), takže nebylo třeba dělat žádné atmosférické, geometrické ani radiometrické korekce. Jako druhý datový vstup byl stažený multispektrální snímek z družice Landsat 9. Zde se podařilo sehnat snímek časově blízký snímku z PRISMA, což eliminuje nesrovnalosti způsobené růstem vegetace během letních měsíců. Konkrétně se jedná o snímek pořízený 17.6.2022 (viz Obr. 11). Úroveň zpracování je opět level 2 a není tak nutné dělat žádné korekce.



Obrázek 11: Výřez zájmové oblasti na multispektrálním snímku Landsat 9 (vlevo) a hyperspektrálním snímku PRISMA (vpravo) v RGB barvách (zdroj: autor)

4. 3 Charakteristika zájmového území

Zájmové území se nachází na Rakovnicku. Konkrétně se jedná o Amálii – školní zemědělský podnik Lány patřící České zemědělské univerzitě v Praze a rozloha činí přibližně 500 hektarů (viz Obr. 12). V současnosti zde probíhá realizace opatření, která by měla být základem pro ”chytrou krajinu”. Průběžně probíhá monitoring lokality s využitím bezpilotních letounů a dalších metod dálkového průzkumu Země. Celá lokalita je také osázena senzory, které umožňují vyhodnocování realizovaných opatření a jejich dlouhodobý dopad na krajinu. Využívají se zde agrotechnická opatření, aplikace půdních aditiv, mobilní protierozní opatření. Budují se zde retenční nádrže a mokřady (ČZU 2023).



Obrázek 12: Zájmové území zobrazené nad ortofotem – vlevo (zdroj: autor, ortofoto: ČÚZK) a zájmové území v kontextu celé ČR – vpravo (zdroj: ČZU)

4. 4 Tvorba legendy

Na základě podkladů získaných terénním měřením byla klasifikační legenda rozdělena na 6 povrchů zastupující aktuální vegetační pokryv v zájmovém území. Těmito povrchy je vojtěška, řepa, ječmen, pšenice, strniště a les. Jednotlivé kategorie jsou vizuálně znázorněny na Obr. 13–18 ve formě

reprezentující fotografie a výřezem ze snímku PRISMA reprezentujícím daný povrch. Také jsou tyto kategorie slovně popsány v příslušných odstavcích této kapitoly.

Vojtěška

Vojtěška (Obr. 13) je kvetoucí rostlina fialové až modrofialové barvy a náleží do čeledi bobovité. Jedná se o významnou pícninu. Významnou roli hraje v zemědělství jako krmivo. Používá se jako objemné krmivo čerstvá nebo sušená (seno) i jako jaderné krmivo coby součást různých směsí a granulí (Deyl, Hísek 2001).



Obrázek 13: Vojtěška – vlevo (zdroj: pixabay.com), ukázka povrchu na snímku PRISMA – vpravo. (zdroj: autor)

Řepa

Řepa (Obr. 14) je rostlina s větvenou lodyhou, která může být jednoletá nebo trvalá. Její listy jsou velké a střídavé, nejsou dělené, a květy jsou oboupohlavní, vyskytují se jednotlivě nebo v klubíčkách, uspořádaných v přetrhovaných latách. Okvětí tvoří bledé, občas nažloutlé lístky, srostlé v češuli u báze, blizny jsou trojklané a nažky bývají uzavřené, někdy opadávají spolu s celým klubíčkem. Červená řepa je jedním z mnoha poddruhů, odrůd a variet řepy, která je botanicky známá jako *Beta vulgaris, subspecies vulgaris*. Na rozdíl od klasické řepy cukrové má kulovitý, karmínově rudý kořen a řapíky listů téže barvy (Atlas Rostlin 2023).



Obrázek 14: Řepa – vlevo (zdroj: uroda.cz), ukázka povrchu na snímku PRISMA – vpravo (zdroj: autor)

Les


Jedná se o místa (viz Obr. 15), kde jsou smíchány jehličnaté dřeviny s listnatými a jejich výška je menší než 5-7 m a uzavřenost koruny je kolem 30 % (Corine Land Cover 2018).



Obrázek 15: Les – vlevo (zdroj: ortofoto ČÚZK), ukázka povrchu na snímku PRISMA – vpravo (zdroj: autor)

Strniště


Strniště (Obr. 16) je plocha pole po žních. Jedná se o zbytky stébel obilovin, které zůstávají na poli po sklizni. Výška strniště je závislá na výšce sekání. V případě, že je porost poléhavý, seká se nízko u země. Pokud není potřeba slámy, seká se vysoko nebo je sláma rozdrčena drtiči zabudovanými přímo v kombajnu (ČSN EN 15436-1).



Obrázek 16: Strniště – vlevo (zdroj: pixabay.com), ukázka povrchu na snímku PRISMA – vpravo (zdroj: autor)

Pšenice


Pšenice (Obr. 17) je rod jednoděložných rostlin z čeledi lipnicovitých s přibližně 20 druhy. Zahrnuje jak šlechtěné, tak planě rostoucí druhy. Pšenice jsou jedny z nejstarších kulturních rostlin, pocházejí z jihozápadní Asie. Hlavní jsou dva druhy: pšenice obecná (respektive obyčejná) a pšenice tvrdá (ŠPALDON et al. 1982).



Obrázek 17: Pšenice – vlevo (zdroj: pixabay.com), ukázka povrchu na snímku PRISMA – vpravo (zdroj: autor)

Ječmen

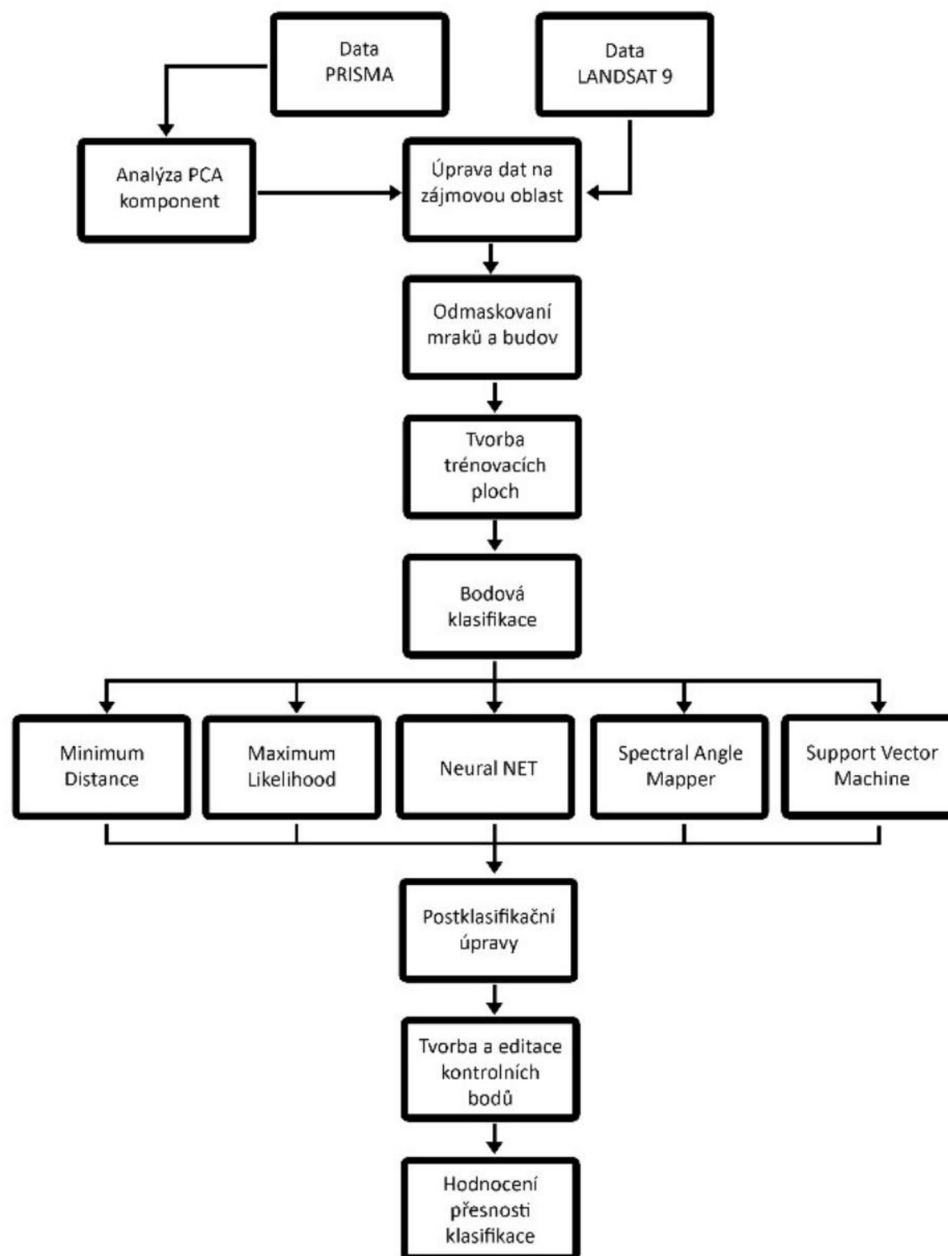
Ječmen (Obr. 18) je rod čeledi lipnicovitých. Zahrnuje 25 druhů planého ječmene a jeden druh kulturní: ječmen setý, který patří k hospodářsky nejvýznamnějším rostlinám. Kulturní ječmen je jednoletá jarní nebo ozimá obilnina. Některé plané druhy jsou víceleté (Naučný slovník zemědělský 1968).



Obrázek 18: Ječmen – vlevo (zdroj: uroda.cz), ukázka povrchu na snímku PRISMA – vpravo (zdroj: autor)

4. 5 Metodika práce

Metodika práce je složena z několika kroků. Nejprve se oba snímky upravily na zájmovou oblast, poté bylo přistoupeno k odmaskování mraků a budov, které byly zastoupeny jen malým množstvím pixelů a v klasifikaci vegetace nejsou příliš potřeba. Následovala tvorba trénovacích ploch a na základě těchto referenčních dat bylo přistoupeno ke klasifikaci upravených snímků. Nakonec byly všechny snímky upraveny pomocí post klasifikačních úprav, vytvořeny kontrolní body a každý výsledek klasifikace byl nakonec zhodnocený. Shrnutí metodiky je znázorněno na schématu níže (Obr. 19).



Obrázek 19: Schéma metodiky (zdroj: autor)

4. 6 Úpravy snímků

I přes pořízení snímků na dostačující úrovni zpracování bylo nutné přistoupit k dalším úpravám snímku. Nejprve bylo přistoupeno k oříznutí snímku na zájmovou oblast zemědělského podniku Lány a přilehlého okolí. Jelikož i po oříznutí se na hyperspektrálním i multispektrálním snímku nacházely malé mraky, bylo nutné přistoupit k jejich odstranění. To bylo provedeno funkcí *built mask*, která slouží k vytvoření masky mraků, která byla následně aplikována na daný snímek pomocí *apply mask*. Vzhledem k prostorovému rozlišení snímků (30 m) a reálné ploše zastoupených budov, která je na území velmi malá, bylo přistoupeno také k odmaskování veškerých budov z obou snímků. Navíc cíle závěrečné práce jsou zaměřeny primárně na klasifikaci vegetace s

důrazem na zemědělské plodiny. U hyperspektrálních dat byla následně použita tzv. MNF Transformace, která odstraní šum a nadbytečné informace o dimenzionalitě dat. V rámci této transformace byly analýzou hlavních komponent (PCA) spočteny a následně vybrány pouze hlavní komponenty nesoucí velké množství informace (PC 1-7). Ostatní hlavní komponenty s malou informační hodnotou představovaly převážně šum, a proto nebyly zahrnuty do dalšího zpracování. Z výstupu MNF tak bylo vybráno 7 hlavních komponent PCA analýzy.

Po oříznutí snímků na zájmovou oblast, odmaskování mraků a budov bylo třeba vytvořit tzv. referenční data. Jak píše Dobrovolný (1998), v případě, že používáme řízenou klasifikaci, je naprostou nutností předem definovat trénovací plochy, které jsou typické a reprezentativní pro správné rozlišení povrchu. Tyto tréninkové vzorky slouží jako vstup do klasifikačních algoritmů a ovlivňují konečný výsledek. Referenční data byla vytvořena v ArcGIS Pro v podobě shapefile souborů pro jednotlivé kategorie legendy na základě dostupného terénního měření a rozložení polí nad ortofotem. Tyto shapefile pak byly vyexportovány a nahrány do softwaru ENVI 5.6. pomocí nástroje ROI (Region Of Interest), kde byly případně dopraveny, aby odpovídaly většímu počtu trénovacích pixelů. V nástroji ROI byla dále vytvořena ještě jedna kategorie zastupující okolí zájmového území. Celkově tak vzniklo 7 kategorií trénovacích ploch. Zastoupení jednotlivých kategorií pro hyperspektrální i multispektrální snímky jsou znázorněny v Tabulce 2.

Zastoupení trénovacích ploch v pixelech		
Kategorie	PRISMA(PCA)	Landsat 9
Vojtěška	62	55
Řepa	42	38
Ječmen	23	21
Pšenice	29	30
Les	23	22
Strniště	51	47
Okolí	541	635

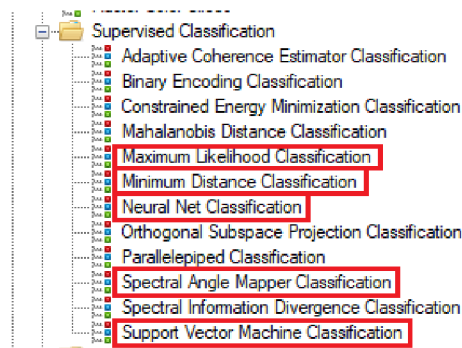
Tabulka 2: Počty trénovacích ploch pro jednotlivé kategorie legendy (zdroj: autor)

Před spuštěním samotné klasifikace byla zkontrolována spektrální oddělitelnost (separabilita) trénovacích ploch. Pro výpočet separability v příznakovém prostoru byla použita funkce "Compute ROI separability" v nástroji ROI tool v programu ENVI. Tato funkce vyhodnocuje vzdálenosti mezi třídami v příznakovém prostoru pomocí dvou algoritmů. Jedním z nich je Jeffries-Matusita a druhý algoritmus se nazývá Transformed Divergence. Výsledky separability trénovacích ploch u obou algoritmů se pohybují v rozmezí od 0 do 2, kde vyšší hodnota znamená větší odlišnost od ostatních ploch. V případě, že se hodnoty pohybují okolo 1, je vhodné promyslet, zda by se neměly dané třídy sloučit v jednu (Richards 1999; Jeffreys 1946). Na základě výstupů z funkce „Compute ROI separability“, kdy hodnoty pro naši

práci překračovaly číslo 1,9, což indikuje dobrou oddělitelnost dat (ENVI Help 2023), bylo přistoupeno k procesu klasifikace.

4. 7 Klasifikace obrazu

Pro samotnou klasifikaci obrazu bylo vybráno několik algoritmů obsažených v ENVI 5.6. Konkrétně byl využitý klasifikátor Minimum Distance (MD), Maximum Likelihood (ML), Neural Net (NN), Spectral Angle Mapper (SAM) a Support Vector Machine (SVM), viz Obrázek 20. Jako vstup do těchto algoritmů byl vždy použitý výstup z PCA analýzy tvořený 7 hlavními komponentami vypočtenými ze snímku PRISMA a pro porovnání i multispektrální snímek z družice Landsat 9, který obsahuje 7 spektrálních pásem. V odstavcích níže jsou popsány nastavené parametry jednotlivých klasifikačních algoritmů použitých v této práci.



Obrázek 20: Vyznačené použité klasifikátory v ENVI toolboxu (zdroj: autor)

Minimum Distance (MD): Tento klasifikátor je obsažen v menu nástrojů v podsložce řízených klasifikací. U tohoto algoritmu byly vybrány trénovací plochy na základě předem stanovené legendy, které byly nahrané ve formě ROI (Region Of Interest). Kromě trénovacích vzorků si lze volitelně upravit hodnotu v poli „Threshold Maximum Distance“, která představuje práh vzdáleností. Čím nižší tento práh je, tím více pixelů není klasifikováno (ENVI Help 2023). Stejně tak lze nastavit počet směrodatných odchylek od průměru, které se mají použít okolo průměru pro každou třídu. Opět platí, že čím nižší hodnota je nastavená, tím více pixelů se neklasifikuje (ENVI Help 2023). V našem případě byly použity přednastavené (defaultní) hodnoty. Mapový výstup této klasifikační metody je zobrazený v Příloze 7.

Maximum Likelihood (ML): Jedná se o další dostupný klasifikátor v menu nástrojů pro řízenou klasifikaci. Stejně jako u předchozí klasifikace zde byly vybrány všechny trénovací plochy v podobě ROI. Dále zde jde zvolit parametr „Set Probably Threshold“ od 0 do 1. Pokud má pixel nižší hodnotu než práh, který představuje minimální pravděpodobnost pro zařazení do třídy, nebude klasifikován. V našem případě byl tento parametr nastavený na „Single Value“. Ostatní necháno defaultně. Mapový výstup této klasifikační metody je zobrazený v Příloze 6.

Neural Net (NN): Po otevření uživatelského rozhraní je opět nejprve potřeba vybrat tréninkové vzorky a pak nastavit příslušné parametry. „Training Threshold

Contribution“ se nastavuje v rozmezí od 0 do 1 a jeho zvětšení může vést k přesnější klasifikaci. Hodnota „Training Threshold Contribution“ byla tedy nastavena na 0,9. Dalším parametrem je „Training Rate“, který byl nastaven na výchozí hodnotu 0 a „Training Momentum“ nastavený na 0,9. Tyto parametry zrychlují trénovací proces. Další parametr „Training RMS Exit Criteria“ nám udává, při jaké hodnotě RMSE (Root Mean Square Error) bude trénování ukončeno a byl nastavený na 0,1. Následně se musí nastavit počet iterací, který byl v našem případě zvětšen na 3000 a nijak zvlášť neovlivnil dobu výpočtu. Výsledky byly znatelně lepší, než při nastavení původních 1000 iterací. Mapový výstup této klasifikační metody je zobrazený v Příloze 8.

Spectral Angle Mapper (SAM): Nástroj umožňuje nahrát trénovací vzorky z místa na disku, případně z nahrané ROI v programu a podle těchto referenčních dat opět daný snímek klasifikuje. Jednou z možností volitelných parametrů je také definovat maximální prahovou hodnotu v radiánech, která představuje maximální přijatelný úhel mezi vektorem koncového členu a vektorem pixelu ve vícerozměrném prostoru odpovídajícímu počtu vstupních pásem snímku. Pixel se nebude klasifikovat v případě překročení této hodnoty. V našem případě nastaveno na 1 rad. Mapový výstup této klasifikační metody je zobrazený v Příloze 9.

Support Vector Machine (SVM): Nejprve je nutné opět vybrat snímek pro klasifikaci, poté vybrat trénovací data a nastavit parametry. Vybrat zde jde ze tří funkcí pro zařazení pixelu do dané třídy. Lze si zvolit lineární, polynomická nebo RBF (Radial Basis Function). V našem případě bylo provedenou pilotní analýzou zjištěno, že nejlepších výsledků dosahuje funkce RBF (Radial Basis Function), proto byla použita pro finální klasifikaci. Dále zde byl zvolen parametr „Gamma in Kernel Function“, kde byla nastavena hodnota na 0,143. U ostatních parametrů bylo vše ponecháno defaultně. Mapový výstup této klasifikační metody je zobrazený v Příloze 10.

4. 8 Post-processing snímků

V bodové klasifikaci se často setkáváme s efektem označovaným jako "salt and pepper effect". Tento efekt způsobuje zařazení jednoho pixelu do jiné třídy, než je třída jeho okolních pixelů. K odstranění tohoto problému lze použít nízkofrekvenční filtr. V aplikaci ENVI je k tomuto účelu k dispozici nástroj Majority/Minority Analysis. V našem případě byly vybrány všechny kategorie legendy, zvolená metoda Majority, Kernel size 3x3 a center pixel weight nastaven na hodnotu 1.

4. 9 Hodnocení přesnosti

Hodnocení přesnosti je nedílnou součástí klasifikace a bez něj nelze považovat proces za dokončený. Pokud chceme zhodnotit výsledek klasifikace je nutné porovnávat výsledek nad celým zájmovým územím. K vygenerování náhodných bodů, které po editaci fungují jako kontrolní, byla použita funkce „Generate Random Sample Using Ground Truth Image“, která

nám vytvořila náhodné body zastupující poměrově všechny kategorie legendy ve schématu „Stratified random“, jak jsou zastoupené v zájmovém území. Tyto body byly vyexportovány a otevřeny v ArcGIS Pro, kde byla každému bodu přiřazená třída, kterou ve skutečnosti zastupuje, včetně příslušného ID odpovídajícího dané kategorii. Pokud se bod nacházel na nejasném rozhraní, byl buď odstraněn, nebo přesunut. Celkem bylo tedy vytvořeno 100 kontrolních bodů pro ověření přesnosti klasifikace. Tyto body byly editovány a poté nahrány zpět do programu ENVI 5.6., kde pomocí nástroje "Confusion Matrix Using Ground Truth ROIs" byla získána chybová matice, celková přesnost a Kappa koeficient. Výsledky byly následně zaznamenány v tabulkách v Microsoft Excel.

5. Výsledky

Kapitola výsledky představuje zhodnocení a interpretace jednotlivých klasifikačních algoritmů provedených v rámci metodiky. Cílem práce bylo najít nejvhodnější algoritmus pro klasifikaci hyperspektrálních dat na úrovni vegetace. V rámci lepší přehlednosti jsou chybové matice uvedeny v tabulkách, ze kterých můžeme vyčíst několik přesností. Jedná se o celkovou přesnost, která je vždy v pravém dolním rohu spolu s Kappa koeficientem. Dále vidíme zpracovatelskou přesnost na posledním řádku a v posledním sloupci můžeme vidět přesnost uživatelskou.

Chybové matice pro komponentní hyperpektrální snímek jsou uvedeny v Tabulkách 3–7. Chybové matice pro porovnávací snímek Landsat 9 jsou uvedeny v Přílohách 1–5 a všechny vizuální výsledky jsou uvedeny v Přílohách 6–15.

chybová matice – Maximum Likelihood – PCA PRISMA								
kategorie	Vojtěška	Řepa	Les	Ječmen	Strniště	Pšenice	Celkem	uživatelská přesnost [%]
Vojtěška	104	0	0	21	0	0	125	83,20
Řepa	0	48	0	7	0	0	55	87,27
Les	0	0	48	0	0	0	48	100,00
Ječmen	0	0	0	36	0	0	36	100,00
Strniště	4	0	0	4	59	0	67	88,06
Pšenice	0	0	0	0	0	68	68	100,00
Celkem	108	48	48	68	59	68	399	--
zpracovatelská přesnost [%]	96,3	100	100	52,94	100	100	--	90,98
								0,89

Tabulka 3: Chybová matice Maximum Likelihood pro komponentní PCA snímek PRISMA (zdroj: autor)

Kontrolních pixelů u klasifikace Maximum Likelihood bylo celkem 399. Celková přesnost klasifikace dosáhla 90,98 % (Tabulka 3). Kappa index dosahuje 0,89. V rámci uživatelské přesnosti byl nejlépe klasifikován les, ječmen a pšenice. Tyto tři kategorie dosahují uživatelské přesnosti 100 %. Nejhorší uživatelská přesnost je v případě klasifikace Maximum Likelihood u vojtěšky, avšak stále dosahuje poměrně vysokého výsledku, který činí 83,20 %. V případě posouzení zpracovatelské přesnosti si lze všimnout, že nejlepších čísel dosahuje pro kategorii řepa, les, strniště a pšenice. Naopak nejhorší zpracovatelskou přesnost lze vidět v kategorii ječmen, která je rovna necelým 53 %.

chybová matice – Minimum Distance – PCA PRISMA								
kategorie	Vojtěška	Řepa	Les	Ječmen	Strniště	Pšenice	Celkem	uživatelská přesnost [%]
Vojtěška	80	0	0	0	0	0	80	100,00
Řepa	0	40	0	0	0	0	40	100,00
Les	0	0	48	1	8	0	57	84,21
Ječmen	24	8	0	43	0	0	75	57,33
Strniště	0	0	0	0	51	4	55	92,73
Pšenice	0	0	0	0	0	63	63	100,00
Celkem	104	48	48	44	59	67	370	--
zpracovatelská přesnost [%]	76,92	83,33	100	97,73	86,44	94,03	--	87,83
								0,85

Tabulka 4: Chybová matice Minimum Distance pro komponentní PCA snímek PRISMA (zdroj: autor)

Pro kontrolu klasifikátoru Minimum Distance bylo využito celkem 370 pixelů, při čemž bylo dosaženo výsledku o celkové přesnosti 84,83 % (Tabulka 4). Kappa koeficient dosahuje 0,85, což je pořád poměrně kvalitní výsledek. Zde byly nejlépe v uživatelské přesnosti rozlišeny plodiny jako vojtěška, řepa, či pšenice. Nejhorší uživatelská přesnost je pozorovatelná u ječmene, kde dosáhla 57,33 %. V rámci zpracovatelské přesnosti je dosaženo 100 % pouze u kategorie les a nejméně dosáhla kategorie vojtěšky. V tomto klasifikátoru byly nejčastěji zaměněné pixely vojtěšky s ječmenem, nicméně pořád se celková přesnost pohybuje v okruhu 90 %.

chybová matice – Neural Net – PCA PRISMA								
kategorie	Vojtěška	Řepa	Les	Ječmen	Strniště	Pšenice	Celkem	uživatelská přesnost [%]
Vojtěška	101	0	0	4	0	0	105	96,19
Řepa	0	44	0	0	0	0	44	100,00
Les	1	2	48	3	7	0	61	78,69
Ječmen	3	2	0	37	0	0	42	88,10
Strniště	0	0	0	0	51	4	55	92,73
Pšenice	0	0	0	0	1	64	65	98,46
Celkem	105	48	48	44	59	68	372	--
zpracovatelská přesnost [%]	96,19	91,67	100	84,09	86,44	94,12	--	92,74
							kappa	0,91

Tabulka 5: Chybová matice Neural Net pro komponentní PCA snímek PRISMA (zdroj: autor)

U klasifikačního algoritmu Neural Net v rámci snímků vytvořeného PCA transformací bylo dosaženo celkové přesnosti 92,74 % za použití 372 kontrolních pixelů. V Tabulce 5 můžeme vidět i vysoký Kappa koeficient, který zde dosahuje 0,91. Dále se zde objevuje uživatelská přesnost rovna 100 % u řepy. Nejhorší uživatelská přesnost je v kategorii les s hodnotou 78,69 %. U zpracovatelské přesnosti se ve všech třídách pohybujeme ve vysokých číslech, kde procentuální hodnota neklesne po 84 % a nejlépe je zde zařazen les se 100 %.

chybová matice - Spectral Angle Mapper - PCA PRISMA								
kategorie	Vojtěška	Řepa	Les	Ječmen	Strniště	Pšenice	Celkem	uživatelská přesnost [%]
neklasifikováno	8	0	0	24	0	3	35	--
Vojtěška	86	0	0	0	0	0	86	100,00
Řepa	0	45	0	0	0	0	45	100,00
Les	0	0	48	1	8	0	57	84,21
Ječmen	13	2	0	43	0	0	58	74,14
Strniště	0	0	0	0	51	4	55	92,73
Pšenice	0	0	0	0	0	61	61	100,00
Celkem	107	47	48	68	59	68	397	--
zpracovatelská přesnost [%]	80,37	95,74	100	63,24	86,44	89,71	--	84,13
							kappa	0,81

Tabulka 6: Chybová matice Spectral Angle Mapper pro komponentní PCA snímek PRISMA (zdroj: autor)

V Tabulce 6 můžeme vidět výslednou chybovou matici pro obraz tvořený PCA komponenty z hyperspektrálního snímku PRISMA v případě použití metody Spectral Angle Mapper (SAM). V případě tohoto snímku dosahuje tento algoritmus nejméně uspokojivých výsledků ze všech použitých klasifikátorů. Celková přesnost nepřesáhla 85 % a Kappa koeficient se ustálil na 0,81. V tomto případě bylo pro kontrolu využito 397 pixelů. I přes horší celkovou přesnost lze ale vidět, že uživatelská přesnost je opět 100 % u kategorie vojtěšky, řepy a pšenice. Zpracovatelská přesnost je zde nejlepší pro kategorii les (100 %) a nejhůrší pro ječmen.

chybová matice – Support Vector Machine – PCA PRISMA								
kategorie	Vojtěška	Řepa	Les	Ječmen	Strniště	Pšenice	Celkem	uživatelská přesnost [%]
Vojtěška	93	0	0	4	0	0	97	95,88
Řepa	0	44	0	0	0	0	44	100,00
Les	4	0	48	1	0	0	53	90,57
Ječmen	4	3	0	38	0	0	45	84,44
Strniště	0	0	0	1	59	0	60	98,33
Pšenice	0	0	0	0	0	68	68	100,00
Celkem	101	47	48	44	59	68	367	--
zpracovatelská přesnost [%]	92,08	93,62	100	86,36	100	100	--	95,37
								0,94

Tabulka 7: Chybová matice Support Vector Machines pro komponentní PCA snímek PRISMA (zdroj: autor)

Nejlepších výsledků pro komponentní PCA snímek ze satelitu PRISMA dosáhla klasifikace Support Vector Machine. Chybovou matici lze vidět v Tabulce 7. V tomto případě celková přesnost vychází na 95,37 % a co se týče Kappa koeficientu, ten dosahuje 0,94. Celkové výsledky potvrzuje i zařazení pixelů do správných tříd. To lze vidět v uživatelské i zpracovatelské přesnosti, kde není nižší hodnoty než 86 % v případě zpracovatelské přesnosti a méně než 84 % v přesnosti uživatelské. Dle těchto výsledků se jeví jako nejvhodnější algoritmus pro klasifikaci na úrovni zemědělských plodin právě Support Vector Machine.

5.1 Porovnání výsledků klasifikace

V této části jsou shrnuté jednotlivé výsledky celkové přesnosti všech použitých klasifikačních metod. Všechny klasifikační metody proběhly se stejně volenými parametry, stejnými trénovacími plochami i kontrolními body u snímku vytvořeného pomocí PCA transformace i u snímku z Landsat 9. Pro přehlednost jsou všechny algoritmy spolu s výsledkem celkové přesnosti uvedeny v Tabulce 8.

CELKOVÁ PŘESNOST KLASIFIKACE			
PCA PRISMA	přesnost	LANDSAT 9	přesnost
MD	87,83%	MD	65,90%
ML	90,97%	ML	86,68%
NN	92,74%	NN	49,75%
SAM	84,13%	SAM	63,48%
SVM	95,37%	SVM	74,06%

Tabulka 8: Porovnání celkových přesností využitých algoritmů (zdroj: autor)

V Tabulce 8 můžeme na první pohled vidět, že výsledky klasifikací ze snímku vytvořeného PCA transformací z hyperspektrálních dat PRISMA dosahují vyšší celkové přesnosti, než klasifikace plodin z multispektrálního satelitního snímku pořízeného Landsat 9. Proto lze tvrdit, že pro klasifikaci vegetace na úrovni plodin jsou hyperspektrální snímky vhodnějším zdrojem vstupních dat, než snímky multispektrální. Největší přesnosti bylo dosaženo u algoritmu bodové klasifikace Support Vector Machine (SVM), která překonala hranici 95 % u snímku vzniklého PCA transformací PRISMA. Uspokojivých výsledků dosáhl i klasifikátor Neural Net s přesností 92,74 %. Co se týče vyhodnocení multispektrálního snímku, můžeme vidět, že nejlépe zafungoval algoritmus Maximum Likelihood, který dosahuje celkové přesnosti necelých 87 %.

6. Diskuse

Dálkový průzkum Země se v posledních letech dostává do podvědomí všech možných odvětví a umožňuje nám rychle a efektivně získávat informaci o Zemi (Svatoňová et al. 2010). V současnosti není problém sehnat kvalitní satelitní data k jakémukoli datu kdekoli na světě. Tato data jsou však ve většině případů multispektrální a neobsahují tak souvislý pás spektrálních informací. Tato data jsou dostupná volně ke stažení i za finanční obnos. Záleží na mnoha faktorech jako je prostorové rozlišení, časový interval snímání, či počet spektrálních pásem (Lillesand et al. 2015). Právě na velkém počtu spektrálních pásem je založené hyperspektrální snímání. Proto je v současné době v oblasti dálkového průzkumu Země a geoinformačních systémů kladen čím dál tím větší důraz na využívání a vývoj zařízení nesoucí hyperspektrální senzor a mít tak možnost získat data se souvislou spektrální informací v rámci několika stovek na sebe navazujících pásem ve viditelné, blízké infračervené, střední infračervené a krátkovlnné infračervené části elektromagnetického spektra. Díky tomu nám hyperspektrální snímání umožňuje detailní zkoumání charakteristik zemského povrchu. Zatímco ještě nedávno bylo hlavní nevýhodou nízké časové rozlišení družic s hyperspektrálním senzorem, které se pohybovalo v rámci týdnů, s postupným vývojem a rozvojem těchto družic je dneska situace výrazně lepší a můžeme sehnat snímky v rámci jednotlivých dnů (Yuzhen et al. 2020).

V současnosti můžeme čerpat data z řady družic nesoucí hyperspektrální senzor jako je družice PRISMA od italské kosmické agentury (ASI), od německého projektu EnMAP a dalších. V této práci byly využity právě data z italské PRISMA, o které bylo v rámci řešení této práce požádáno přes licenční formulář a žádosti o přístup do archivu snímků pro studijní účely a této žádosti bylo ze strany italské kosmické agentury (ASI) vyhověno. Byla tak získána vlastní hyperspektrální data s malým procentem oblačnosti pokrývající zájmové území. Pořízený snímek pochází z 21. června 2022. S ohledem na cíle práce proto bylo důležité získat volně dostupná multispektrální data (zejména snímky Landsat 8/9 a Sentinel 2) k porovnání klasifikačních metod v podobném časovém období. Důvodem tohoto metodického kroku byla eliminace potenciálních nesrovnalostí způsobených růstem vegetace v

jiném ročním obdobím či zcela jiném roce, které by tak mohly mít podstatný vliv na přesnost dosažených výsledků klasifikace. Datumově blízký volený snímek k porovnávání byl požadován také z důvodu výsadby zemědělských plodin, která se může v závislosti na vegetačním období a plodině měnit v průběhu roku. Pro účely porovnání zvolených algoritmů byl stažen multispektrální snímek z družice Landsat 9. Tento snímek pochází ze 17. června 2022. Tedy je pořízen pouze 4 dny před hyperspektrálním snímkem PRISMA, což je dostatečně časově blízko na to, aby byly výsledky klasifikací obou snímků vzájemně porovnatelné.

Pro potřeby klasifikace vegetace na úrovni zemědělských plodin v oblasti zemědělského podniku Lány (tzv. Amálie) byl vytvořen z hyperspektrálního snímku obraz pomocí PCA transformace obsahující 7 hlavních komponent a pro něj se nejlépe ukázala klasifikační metoda založená na bodovém přístupu zvaná Support Vector Machine (SVM). Využití PCA je již víceméně běžným přístupem pro redukci spektrální dimenze hyperspektrálních dat (Rodarmel, Shan 2002). Dále jsem se snažil co nejpřesněji vytvořit trénovací vzorky vycházející ze zvolené legendy na základě podpůrných dat z probíhajících výzkumů na lokalitě Amálie a eliminovat prvky, které by ve výsledné klasifikaci vegetace mohly způsobovat komplikace. Proto jsem přistoupil k odmaskování budov, kterých je na zájmové lokalitě opravdu málo a vzhledem k prostorovému rozlišení obou snímků nebyly jasně rozeznatelné. Navíc největší zástavba v areálu byla u snímku z PRISMY zastíněná mrakem, takže zbyly pouze menší budovy na jižní straně zájmové oblasti. Ke spuštění samotné klasifikace jsem přistoupil až po zhodnocení oddělitelnosti trénovacích vzorků, která se pohybovala ve vysokých číslech v rozmezí 1,99 až 2. Proto si trůfám říct, že výsledky jsou poměrně věrohodné a celkové přesnosti vybraných algoritmů dosahují podobných hodnot jako již řešené studie s podobnou tematikou, jako například v případě práce Bc. Martiny Andrštové (2014), která sice používala data pořízená letecky s lepším prostorovým rozlišením k odlišení pestřejší škály vegetace na mnohem větším území, ale vycházela také ze snímků vytvořených z PCA analýzy hlavních komponent, kde zúžila počet původních spektrálních pásem pouze na ty, které nesou nějakou informaci o odrazivosti a redukovala tak navíc i šum. Tento krok byl provedený i v mé práci a umožnil tak urychlit a vylepšit výsledky jednotlivých klasifikátorů. Andrštová (2014) taktéž používá pro klasifikaci obrazu Neural Net, Maximum Likelihood, Spectral Angle Mapper či Support Vector Machines. U těchto algoritmů použitých na datech ze dvou senzorů (APEX, AISA DUAL) dosahuje také velmi dobrých výsledků přesahujících 90 % celkové přesnosti. U algoritmu Neural Net jí vyšel nejlepší výsledek v případě dat APEX s celkovou přesností 96 % a u dat AISA DUAL vyšla celková přesnost 90 %. Co se týče výsledků naší práce, tak klasifikátor Neural Net sice nedosáhl nejlepších výsledků, ale s celkovou přesností 92,74 % se jedná o druhý nejlepší výsledek klasifikace v naší práci při použití dat vytvořených z PRISMA pomocí PCA komponent s prostorovým rozlišením 30 m. Proto lze tvrdit, že je klasifikátor Neural Net vhodný pro klasifikaci vegetace na úrovni jednotlivých druhů. Největší rozdíl mezi prací Andrštové (2014) a mou prací je u klasifikátoru Support Vector Machine, který v našem případě dosahuje nejlepších výsledků s celkovou přesností 95,37 % a lze tedy tvrdit, že je nejvhodnějším algoritmem pro tuto problematiku, ale podle výsledku práce Andrštové (2014) se jedná o nejméně vhodný klasifikační algoritmus na úrovni rozlišení druhu vegetace. Jedním z možných důvodů může být také použití klasifikátoru na různých lokalitách s výrazně jinou

strukturou vegetace. Protože v našem případě máme malé území, kde jsou jednotlivé plodiny zastoupeny poměrně velkými a souvislými plochami, zatímco u práce Andrštové (2014) se jedná o rozptýlenou vegetaci napříč velkým územím, a proto dle mého názoru může pravděpodobněji nastat situace, kdy kontrolní bod je na hraně dvou různých ploch a ve výsledku je přiřazen jiné třídě, což v chybové matici ubírá na celkové přesnosti.

Obecně napříč literaturou uvedenou v kapitole „3.7 Zhodnocení současného stavu poznání“ se výsledky klasifikátoru liší právě v závislosti na prostorovém rozlišení, způsobu pořízení a typu analýzy prováděné na datech. Každopádně většina prací využívající klasifikátor Support Vector Machines a nebo Neural Net, jako jsou např. práce Papp et al. (2021), Hasan et al. (2019), Wenjing, Xiaofei (2020) nebo Osco et al. (2019), dosahují dobrých výsledků a potvrzují tak tvrzení, že i přes to, že posuzovat jednotlivé druhy vegetace vzhledem k blízkým spektrálním projevům může být složité, hyperspektrální snímky nám to s dostatečnou přesností umožňují, a to s prokazatelně vyšší úspěšností klasifikace, než je tomu v případě snímků multispektrálních.

7. Závěr

Hlavním cílem diplomové práce bylo vyhodnotit věrohodnost klasifikace krajinného pokryvu s důrazem na druhy zemědělských plodin pomocí družicových hyperspektrálních a multispektrálních snímků vysokého prostorového rozlišení. Dílčí cíle zahrnovaly tvorbu a editaci referenčních dat, tvorbu legendy, výběr klasifikátorů a následné zhodnocení přesnosti jednotlivých klasifikačních metod. Pro klasifikaci krajinného pokryvu na úrovni vegetace byly využity klasifikační algoritmy Spectral Angle Mapper (SAM), Support Vector Machine (SVM), Neural Net (NN), Maximum Likelihood (ML) a Minimum Distance (MD). Zájmovým územím pro řešení závěrečné práce bylo širší okolí Školního zemědělského podniku Lány (tzv. Amálie). Pro výslednou klasifikaci byl použit obraz vytvořený pomocí PCA transformace hyperspektrálního snímku družice PRISMA, který obsahoval 7 hlavních komponent. Naproti tomu byl využit snímek z multispektrální družice Landsat 9. Výsledky u obrazu tvořeného z PCA transformace dosahovaly vysoké celkové přesnosti a neklesly pod 84 %. Nejlépe klasifikoval hyperspektrální snímek klasifikátor Support Vector Machine s celkovou přesností 95,37 %. Velmi vysoké celkové přesnosti dosáhl i algoritmus Neural Net (92,74 %). Co se týče multispektrálních dat, zde jsou dosažené celkové přesnosti klasifikace nižší než v případě hyperspektrálního snímku. Nejvyšší celkové přesnosti dosáhl klasifikátor Maximum Likelihood (86,68 %).

Dílčím cílem závěrečné práce pak bylo i zodpovězení výzkumných otázek stanovených v zadání. Tedy, že využitím hyperspektrálních snímků lze dobře klasifikovat druhy zemědělských plodin. Výsledky se nicméně mohou lišit podle použitých algoritmů a je vhodné je doplnit terénním měřením pomocí spektrometru. Vhodnost hyperspektrálních snímků pro rozlišení zemědělských plodin potvrzují i doposud publikované studie zabývající se touto tematikou (výzkumná otázka A). Dále, že dle získaných výsledků se jeví hyperspektrální snímky jako vhodnější varianta při rozpoznávání jednotlivých zemědělských plodin metodami DPZ než varianta s využitím multispektrálních dat (výzkumná otázka B). A také tyto výsledky ukazují že nevhodnějšími algoritmy pro klasifikaci vegetace na úrovni zemědělských plodin jsou klasifikátory SVM dosahující přesnosti 95,37 % a NN 92,74 % u obrazu vzniklým PCA transformací hyperspektrálního snímku. Naopak nejnižší přesnosti v tomto případě dosáhl klasifikační algoritmus SAM (84,13 %). V rámci klasifikace multispektrálního snímku se jeví jako nejvíce vhodný algoritmus ML, který dosáhl 86,68 % a nejméně vhodným je klasifikátor NN s přesností necelých 50 % (výzkumná otázka C).

8. Seznam zdrojů informací

1. AL-DOSKI, JWAN; MANSORL, SHATTRI B.; SHAFRI, HELMI ZULHAIDI MOHD. Image classification in remote sensing. Department of Civil Engineering, Faculty of Engineering, University Putra, Malaysia, 2013, 3.10.
2. ANDRŠTOVÁ, Martina. VYUŽITÍ HYPERSEKTRÁLNÍCH DAT KE KLASIFIKACI VEGETACE ALPÍNSKÉHO BEZLESÍ V KRKONOŠÍCH. Praha, 2014. Diplomová práce. UNIVERZITA KARLOVA V PRAZE., Přírodovědecká fakulta, Katedra aplikované geoinformatiky a kartografie. Vedoucí práce RNDr. Lucie Kupková, Ph.D.
3. ASI (2023): Agenzia Spaziale Italiana. ASI | Agenzia Spaziale Italiana [online]. Copyright © 2019 [cit. 14.03.2023]. Dostupné z: <https://www.asi.it/scienze-della-terra/prisma/>
4. ATLAS ROSTLIN, 2023: Řepa červená (online) [cit.2012.04.20], Dostupné z: <https://www.atlasrostlin.cz/bylinky/repa-cervena>
5. CAMPBELL, JAMES B.; WYNNE, RANDOLPH H. Introduction to remote sensing. Guilford Press, 2011. ISBN 16-091-8176-X
6. CLASSIFICATION – REMOTE SENSING. Open Library Publishing Platform – Pressbooks for Ontario's Postsecondary Educators [online]. [cit. 2023-03-13]. Dostupné z: <https://ecampusontario.pressbooks.pub/remotesensing/chapter/chapter-6-classification/>
7. ČSN EN 15436-1. Zařízení pro údržbu servisních a provozních prostor silnic – Část 1: Terminologie. 2009.
8. ČZU (2023): Amálie – Školní zemědělský podnik Lány – Fakulta životního prostředí ČZU v Praze. [online]. Copyright © 2021 Česká zemědělská univerzita v Praze [cit. 14.03.2023]. Dostupné z: <https://www.fzp.czu.cz/cs/r-6899-projekty-a-spoluprace-s-praxi/r-6923-projekty/r-13951-swamp/r-15801-projektove-lokality/r-15802-amalie-skolni-zemedelsky-podnik-lany>
9. DATA PRISMA (2023): "Project carried out using ORIGINAL PRISMA Products - © Italian Space Agency (ASI); the Products have been delivered under an ASI License to Use".
10. DEYL, MILOŠ, SKOČDOPOLOVÁ-DEYLOVÁ, BLANKA, ed. Naše květiny. Ilustroval Květoslav HÍSEK. Praha: Academia, 2001. ISBN isbn80-200-0940-x.
11. DOBROVOLNÝ, P. 1998. Dálkový průzkum Země, Digitální zpracování obrazu. 1. vyd. Brno: Masarykova univerzita v Brně, 1998. 210 s. ISBN: 80-210-1812-7
12. Drone sensors in the application of precision agriculture – Scientific Figure on ResearchGate. Dostupné z: https://www.researchgate.net/figure/Hyperspectral-and-Multispectral-sensors_fig3_351879840 [cit. 2022-12-29]
13. ENMAP (2023): Mission - EnMAP. EnMAP [online]. Copyright © 2012 [cit. 14.03.2023]. Dostupné z: <https://www.enmap.org/mission/>
14. ENVI HELP (2023): Compute ROI separability – L3Harris Geospatial - Help Forums -. Geospatial Solutions & Analytics | Remote Sensing

- Technology [online]. Copyright © 2004 [cit. 28.12.2022]. Dostupné z: <https://www.l3harrisgeospatial.com/Support/Forums/aft/2839>
15. ENVI HELP (2023): Minimum Distance. Geospatial Solutions & Analytics | Remote Sensing Technology [online]. Copyright © 2022 L3Harris Geospatial Solutions, Inc. [cit. 15.03.2023]. Dostupné z: <https://www.l3harrisgeospatial.com/docs/minimumdistance.html>
 16. ESA (2023): Going hyperspectral for CHIME. European Space Agency [online]. Dostupné z: https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Going_hyperspectral_for_CHIME
 17. EUROPEAN UNION ©, Copernicus Land Monitoring Service, European Environment Agency (EEA)", f.ex. in 2018: "© European Union, Copernicus Land Monitoring Service 2018, European Environment Agency (EEA)" dostupné z: <https://land.copernicus.eu/user-corner/technicallibrary/corine-land-cover-nomenclature-guidelines/html/index.html>
 18. FOTOGRAFIE OPTICKÉ HLAVY HYP/PAN FM PRISMA. In: EoPortal [online]. Itálie [cit. 2023-02-15]. Dostupné z: https://www.eoportal.org/api/cms/documents/163813/4999117/Prismahyp_AutoE.jpeg
 19. GOVENDER, M, K CHETTY, V NAIKEN a H BULCOCK. A comparison of satellite hyperspectral and multispectral remote sensing imagery for improved classification and mapping of vegetation. *Water SA* [online]. 2019, 34(2), 147-154 [cit. 2023-03-15]. ISSN 0378-4738. Dostupné z: doi:10.4314/wsa.v34i2.183634
 20. HAGEN, NATHAN; KUDENOV, MICHAEL W. (2013). "Review of snapshot spectral imaging technologies" (PDF). *Optical Engineering*. 52 (9): 090901. Bibcode:2013OptEn.52i0901H. doi:10.1117/1.OE.52.9.090901. S2C ID 215807781.
 21. HASAN, M., S. ULLAH, M. J. KHAN a K. KHURSHID. COMPARATIVE ANALYSIS OF SVM, ANN AND CNN FOR CLASSIFYING VEGETATION SPECIES USING HYPERSPECTRAL THERMAL INFRARED DATA. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* [online]. 2019, XLII-2/W13, 1861-1868 [cit. 2023-03-14]. ISSN 2194-9034. Dostupné z: doi:10.5194/isprs-archives-XLII-2W13-1861-2019
 22. HENNESSY, ANDREW, KENNETH CLARKE A MEGAN LEWIS. Hyperspectral Classification of Plants: A Review of Waveband Selection Generalisability. *Remote Sensing* [online]. 2020, 12(1) [cit. 2023-03-15]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs12010113
 23. HISUI (2023): Satellite System and Earth Observation | Japan Space Systems. 一般財団法人宇宙システム開発利用推進機構 [online]. Copyright © 2021 Japan Space Systems. All Rights Reserved. [cit. 14.03.2023]. Dostupné z: <https://www.jspacesystems.or.jp/en/project/observation/hisui/>
 24. CHEIN-I CHANG (31 July 2003). *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*. Springer Science & Business Media. ISBN 978-0-306-47483-5.
 25. JEFFREYS, H. An invariant form for the prior probability in estimation problems. *Proceedings of the Royal Society of London. Series A*.

- Mathematical and Physical Sciences [online]. 1946, 186(1007), 453-461 [cit. 2021-03-16]. ISSN 0080-4630. Dostupné z: doi:10.1098/rspa.1946.0056
26. KNUDBY, A., 2021: Remote sensing (online) [cit. 2023.02.18], dostupné z: <https://ecampusontario.pressbooks.pub/remotesensing/front-matter/welcome-to-remote-sensing/>
 27. KOCH, M. (1990). Computer processing of remotely-sensed images: An introduction. *Earth-Science Reviews*.
 28. KRUCE et al.1993 in Lumme J. H. 2004. Classification of vegetation and soil using imaging spectrometer data [online]. Helsinki, Finland, 2004. 5 s. [cit. 2013-7-16]. Dostupný z <https://www.cartesia.org/geodoc/isprs2004/comm7/papers/16.pdf>
 29. LILLESAND, THOMAS M., RALPH W. KIEFER A JONATHAN W. CHIPMAN. Remote sensing and image interpretation. 5th ed. Hoboken, N.J.: John Wiley & Sons, 2004. xiv, 763. ISBN 0471152277
 30. LILLESAND, THOMAS M., RALPH W. KIEFER A JONATHAN W. CHIPMAN. Remote sensing and image interpretation. 6th ed. Hoboken: John Wiley, c2008. ISBN 978-0-470-05245-7.
 31. LILLESAND, THOMAS MARTIN, RALPH W. KIEFER A JONATHAN W. CHIPMAN. Remote Sensing and Image Interpretation. 7th edition. Hoboken: John Wiley, 2015. ISBN 978-1-118-34328-9.
 32. LU, BING, PHUONG DAO, JIANGUI LIU, YUHONG HE A JIALI SHANG. Recent Advances of Hyperspectral Imaging Technology and Applications in Agriculture. *Remote Sensing* [online]. 2020, 12(16) [cit. 2023-03-21]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs12162659
 33. LU, YUZHEN, WOUTER SAEYS, MOON KIM, YANKUN PENG A RENFU LU. Hyperspectral imaging technology for quality and safety evaluation of horticultural products: A review and celebration of the past 20-year progress. *Postharvest Biology and Technology* [online]. 2020, 170 [cit. 2023-03-20]. ISSN 09255214. Dostupné z: doi:10.1016/j.postharvbio.2020.111318
 34. LV, WENJING A XIAOFEI WANG. Overview of Hyperspectral Image Classification. *Journal of Sensors* [online]. 2020, 2020, 1-13 [cit. 2023-03-15]. ISSN 1687725X. Dostupné z: doi:10.1155/2020/4817234
 35. MAPASYST (2019): What is a spectral signature in remote sensing? – Geospatial Technology. *Geospatial Technology* [online]. Copyright © [cit. 15.03.2023]. Dostupné z: <https://mapasyst.extension.org/what-is-a-spectral-signature-in-remote-sensing/>
 36. MEHMOOD, MARYAM, AHSAN SHAHZAD, BUSHRA ZAFAR, AMSA SHABBIR, NOUMAN ALI A AFAQ AHMAD. Remote Sensing Image Classification: A Comprehensive Review and Applications. *Mathematical Problems in Engineering* [online]. 2022, 2022, 1-24 [cit. 2023-03-15]. ISSN 1563-5147. Dostupné z: doi:10.1155/2022/5880959
 37. MERCIER, G., & LENNON, M. (2003). Support vector machines for hyperspectral image classification with spectral-based kernels. *IGARSS 2003. 2003 IEEE International Geoscience and Remote Sensing Symposium. Proceedings (IEEE Cat. No.03CH37477)*, 1, 288-290 vol.1.
 38. MIRZAEI, VERRELST, MAROFI, ABBASI a AZADI. Eco-Friendly Estimation of Heavy Metal Contents in Grapevine Foliage Using In-Field Hyperspectral

- Data and Multivariate Analysis. Remote Sensing [online]. 2019, 11(23) [cit. 2023-03-14]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs11232731
39. NASA (2023): EARTH OBSERVING-1 (EO-1). NASA's Earth Observing System [online]. [cit. 2023-03-14]. Dostupné z: <https://eosps.nasa.gov/missions/earth-observing-1>
 40. NASA (2023): Welcome to HypSPiRI Mission Study Website — Hyperspectral Infrared Imager. Welcome to HypSPiRI Mission Study Website — Hyperspectral Infrared Imager [online]. Copyright © [cit. 14.03.2023]. Dostupné z: <https://hypspiri.jpl.nasa.gov/>
 41. NAUČNÝ SLOVNÍK ZEMĚDĚLSKÝ. 2, E-J / hlavní redakční rada Václav Stehlík. První vydání. Praha: Státní zemědělské nakladatelství, 1968. 1218 stran, 64 stran obrazových příloh: ilustrace (některé barevné)
 42. OSCO, LUCAS PRADO, ANA PAULA MARQUES RAMOS, ÉRIKA AKEMI SAITO MORIYA, et al. Modeling Hyperspectral Response of Water-Stress Induced Lettuce Plants Using Artificial Neural Networks. Remote Sensing [online]. 2019, 11(23) [cit. 2023-03-14]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs11232797
 43. PAPP, LEVENTE, BOUDEWIJN VAN LEEUWEN, PÉTER SZILASSI, ZALÁN TOBAK, JÓZSEF SZATMÁRI, MÁTYÁS ÁRVAI, JÁNOS MÉSZÁROS A LÁSZLÓ PÁSZTOR. Monitoring Invasive Plant Species Using Hyperspectral Remote Sensing Data. Land [online]. 2021, 10(1) [cit. 2023-03-14]. ISSN 2073445X. Dostupné z: doi:10.3390/land10010029
 44. PLANET (2023): Planet's Visionary Hyperspectral Mission. Planet Labs PBC [online]. Dostupné z: <https://www.planet.com/products/hyperspectral/>
 45. RICHARDS, John A. a Xiuping JIA. Remote Sensing Digital Image Analysis [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 1999 [cit. 2021-03-16]. ISBN 978-3-662-03980-9. Dostupné z: doi:10.1007/978-3-662-03978-6
 46. RODARMEL, CRAIG; SHAN, JIE. Principal component analysis for hyperspectral image classification. Surveying and Land Information Science, 2002, 62.2: 115-122.
 47. SABAT-TOMALA, ANITA, EDWIN RACZKO A BOGDAN ZAGAJEWSKI. Comparison of Support Vector Machine and Random Forest Algorithms for Invasive and Expansive Species Classification Using Airborne Hyperspectral Data. Remote Sensing [online]. 2020, 12(3) [cit. 2023-03-14]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs12030516
 48. SHAW, GARY L, III. "Spectral Imaging for Remote Sensing." Lincoln Laboratory Journal, 2003.
 49. SHUKLA, ALPANA A RAJSI KOT. An Overview of Hyperspectral Remote Sensing and its applications in various Disciplines. IRA-International Journal of Applied Sciences (ISSN 2455-4499) [online]. 2016, 5(2), 85-90 [cit. 2023-03-21]. ISSN 2455-4499. Dostupné z: doi:10.21013/jas.v5.n2.p4
 50. SCHOWENGERDT, ROBERT (2007). Remote Sensing: Models and Methods for Image Processing. Elsevier Inc. p. 337. ISBN 0-12-369407-8.
 51. SVATOŇOVÁ, HANA A LUBOMÍR LAUERMANN. Dálkový průzkum Země – aktuální zdroj geografických informací. Brno: Masarykova univerzita, 2010. ISBN 978-80-210-5162-1.

52. SVM, 2013. Support Vector Machines – algoritmy podpůrných vektorů [online]. [cit. 2023-03-13]. Dostupné z: https://is.muni.cz/el/1433/podzim2006/PA034/09_SVM.pdf
53. ŠPALDON, E. a kol. (1982): Rastlinná výroba, Příroda, Bratislava, 628 s.
54. TEMPFLI, K., HUURNEMAN, G. C., BAKKER, W. H., JANSSEN, L. L. F., FERINGA, W. F., GIESKE, A. S. M., GRABMAIER, K. A., HECKER, C. A., HORN, J. A., KERLE, N., VAN DER MEER, F. D., PARODI, G. N., POHL, C., REEVES, C. V., VAN RUITENBEEK, F. J. A., SCHETSELAAR, E. M., WEIR, M. J. C., WESTINGA, E., & WOLDAI, T. (2009). Principles of remote sensing: an introductory textbook. (ITC Educational Textbook Series; Vol. 2). International Institute for Geo-Information Science and Earth Observation. Dostupné z: http://www.itc.nl/library/papers_2009/general/PrinciplesRemoteSensing.pdf
55. WEISS, M., F. JACOB a G. DUVEILLER. Remote sensing for agricultural applications: A meta-review. Remote Sensing of Environment [online]. 2020, 236 [cit. 2023-03-15]. ISSN 00344257. Dostupné z: doi: 10.1016/j.rse.2019.111402
56. WILSON, JEFFREY, CHUNHUA ZHANG A JOHN KOVACS. Separating Crop Species in Northeastern Ontario Using Hyperspectral Data. Remote Sensing [online]. 2014, 6(2), 925-945 [cit. 2023-03-15]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs6020925
57. YAN, DENG, LIU a ZHU. Application of UAV-Based Multi-Angle Hyperspectral Remote Sensing in Fine Vegetation Classification. Remote Sensing [online]. 2019, 11(23) [cit. 2023-03-14]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs11232753

9. Seznam obrázků a tabulek

Obrázek 1: spektrální krychle (zdroj: NASA)

Obrázek 2: Typická spektrální odrazivost (%) tří povrchů: vegetace, půda a voda (Zdroj: Lillesand et al. 2004)

Obrázek 3: Porovnání spektrálního rozlišení hyperspektrálních (vpravo) a multispektrálních (vlevo) dat. Osa x odpovídá vlnové délce (wavelength), osa y odpovídá odezvě povrchu (response). (zdroj: Drone sensors in the application of precision agriculture – Scientific Figure on ResearchGate. Dostupné z: https://www.researchgate.net/figure/Hyperspectral-and-Multispectral-sensors_fig3_351879840 [cit. 2022-12-29])

Obrázek 4: Spektrální úhel mezi dvěma materiály A a B v rámci dvou kanálů (Zdroj: KRUCÉ et al. 1993 in LUMME, 2004)

Obrázek 5: Schematizované uspořádání Neuronové sítě. Input – vstupní vrstva, Hidden – skrytá vrstva, Output – výstupní vrstva (Zdroj: Dobrovolný 1998)

Obrázek 6: Princip vzniku možnosti lineárního oddělení dvou tříd s nelineárními hranicemi pomocí přidání dimenze (zdroj: SVM 2013)

Obrázek 7: Schéma zařazování pixelů k jednotlivým spektrálním třídám pomocí klasifikátoru Maximum Likelihood (zdroj: Lillesand et al. 2015)

Obrázek 8: Schéma zařazování pixelů k jednotlivým spektrálním třídám pomocí klasifikátoru Minimum Distance (zdroj: Lillesand et al. 2015)

Obrázek 9: Družice PRISMA (zdroj: ASI)

Obrázek 10: Fotografie optické hlavy Hyp/Pan FM (Flight Model) přístroje PRISMA (zdroj: Selex ES)

Obrázek 11: Výřez zájmové oblasti na multispektrálním snímku Landsat 9 (vlevo) a hyperspektrálním snímku PRISMA (vpravo) v RGB barvách (zdroj: autor)

Obrázek 12: Zájmové území zobrazené nad ortofotem – vlevo (zdroj: autor, ortofoto: ČÚZK) a zájmové území v kontextu celé ČR – vpravo (zdroj: ČZU)

Obrázek 13: Vojtěška – vlevo (zdroj: pixabay.com), ukázka povrchu na snímku PRISMA – vpravo. (zdroj: autor)

Obrázek 14: Louky a pastviny – vlevo (zdroj: uroda.cz), ukázka povrchu na snímku PRISMA – vpravo (zdroj: autor)

Obrázek 15: Les – vlevo (zdroj: ortofoto ČÚZK), ukázka povrchu na snímku PRISMA – vpravo (zdroj: autor)

Obrázek 16: Strniště – vlevo (zdroj: pixabay.com), ukázka povrchu na snímku PRISMA – vpravo (zdroj: autor)

Obrázek 17: Pšenice – vlevo (zdroj: pixabay.com), ukázka povrchu na snímku PRISMA – vpravo (zdroj: autor)

Obrázek 18: Ječmen – vlevo (zdroj: uroda.cz), ukázka povrchu na snímku PRISMA – vpravo (zdroj: autor)

Obrázek 19: Schéma metodiky (zdroj: autor)

Obrázek 20: Vyznačené použité klasifikátory v ENVI toolboxu (zdroj: autor)

Tabulka 1: Přehled hyperspektrálních družic (zdroj: autor)

Tabulka 2: Počty trénovacích ploch pro jednotlivé kategorie legendy (zdroj: autor)

Tabulka 3: Chybová matice Maximum Likelihood pro komponentní PCA snímek PRISMA (zdroj: autor)

Tabulka 4: Chybová matice Minimum Distance pro komponentní PCA snímek PRISMA (zdroj: autor)

Tabulka 5: Chybová matice Neural Net pro komponentní PCA snímek PRISMA (zdroj: autor)

Tabulka 6: Chybová matice Spectral Angle Mapper pro komponentní PCA snímek PRISMA (zdroj: autor)

Tabulka 7: Chybová matice Support Vector Machines pro komponentní PCA snímek PRISMA (zdroj: autor)

Tabulka 8: Porovnání celkových přesností využitých algoritmů (zdroj: autor)

10. Seznam příloh

Chybové matice:

Příloha 1: Chybová matice klasifikátoru Maximum Likelihood pro snímek Landsat 9

Příloha 2: Chybová matice klasifikátoru Minimum Distance pro snímek Landsat 9

Příloha 3: Chybová matice klasifikátoru Neural Net pro snímek Landsat 9

Příloha 4: Chybová matice klasifikátoru Spectral Angle Mapper pro snímek Landsat 9

Příloha 5: Chybová matice klasifikátoru Support Vector Machine pro snímek Landsat 9

Mapové výstupy:

Příloha 6: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek PRISMA (PCA komponenty) – klasifikace ML

Příloha 7: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek PRISMA (PCA komponenty) – klasifikace MD

Příloha 8: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek PRISMA (PCA komponenty) – klasifikace NN

Příloha 9: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek PRISMA (PCA komponenty) – klasifikace SAM

Příloha 10: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek PRISMA (PCA komponenty) – klasifikace SVM

Příloha 11: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek LANDSAT 9 – klasifikace ML

Příloha 12: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek LANDSAT 9 – klasifikace MD

Příloha 13: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek LANDSAT 9 – klasifikace NN

Příloha 14: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek LANDSAT 9 – klasifikace SAM

Příloha 15: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek LANDSAT 9 – klasifikace SVM

Příloha 1: Chybová matice klasifikátoru Maximum Likelihood pro snímek Landsat 9

chybová matice – Maximum Likelihood - Landsat 9								
kategorie	Vojtěška	Řepa	Les	Ječmen	Strniště	Pšenice	Celkem	užívateľská přesnost [%]
Vojtěška	108	0	5	27	6	0	146	73,97
Řepa	0	43	0	5	0	2	50	86,00
Les	0	0	45	0	0	0	45	100,00
Ječmen	0	0	0	32	0	0	32	100,00
Strniště	0	0	0	4	53	2	59	89,83
Pšenice	0	2	0	0	0	64	66	96,97
Celkem	108	45	50	68	59	68	398	--
zpracovatelská přesnost [%]	100	95,56	90	47,06	89,83	94,12	--	86,68%
							kappa	0,84

Příloha 2: Chybová matice klasifikátoru Minimum Distance pro snímek Landsat 9

chybová matice – Minimum Distance – Landsat 9								
kategorie	Vojtěška	Řepa	Les	Ječmen	Strniště	Pšenice	Celkem	užívateľská přesnost [%]
Vojtěška	62	0	0	16	8	0	86	72,09
Řepa	0	0	0	0	0	0	0	0,00
Les	0	1	41	0	0	0	42	97,62
Ječmen	46	0	9	44	5	0	104	42,31
Strniště	0	0	0	8	46	0	54	85,19
Pšenice	0	42	0	0	0	68	110	61,82
Celkem	108	43	50	68	59	68	396	--
zpracovatelská přesnost [%]	57,41	0	82	64,71	77,97	100	--	65,91%
							kappa	0,58

Příloha 3: Chybová matice klasifikátoru Neural Net pro snímek Landsat 9

chybová matice – Neural Net – Landsat 9								
kategorie	Vojtěška	Řepa	Les	Ječmen	Strniště	Pšenice	Celkem	uživatelská přesnost [%]
Vojtěška	106	0	2	14	8	0	130	81,54
Řepa	0	45	1	0	19	68	133	33,83
Les	0	0	47	29	32	0	108	43,52
Ječmen	0	0	0	0	0	0	0	0,00
Strniště	2	0	0	25	0	0	27	0,00
Pšenice	0	0	0	0	0	0	0	0,00
Celkem	108	45	50	68	59	68	398	--
zpracovatelská přesnost [%]	98,15	100,00	94,00	0,00	0,00	0,00	--	49,75 %
							kappa	0,39

Příloha 4: Chybová matice klasifikátoru Spectral Angle Mapper pro snímek Landsat 9

chybová matice – Spectral Angle Mapper – Landsat 9								
kategorie	Vojtěška	Řepa	Les	Ječmen	Strniště	Pšenice	Celkem	uživatelská přesnost [%]
Vojtěška	66	0	3	22	12	0	103	61,11
Řepa	0	0	0	0	0	0	0	0,00
Les	8	1	40	0	11	4	64	80,00
Ječmen	34	0	6	46	0	0	86	67,65
Strniště	0	0	0	0	36	0	36	61,02
Pšenice	0	43	1	0	0	64	108	94,12
Celkem	108	44	50	68	59	68	397	--
zpracovatelská přesnost [%]	61,11	0,00	80,00	67,65	61,02	94,12	--	63,48 %
							kappa	0,55



Příloha 5: Chybová matice klasifikátoru Support Vector Machine pro snímek Landsat 9

chybová matice – Support Vector Machine – Landsat 9								
kategorie	Vojtěška	Řepa	Les	Ječmen	Střišťe	Pšenice	Celkem	užívateľská přesnost [%]
Vojtěška	105	0	3	16	8	0	132	79,55
Řepa	0	0	0	0	0	0	0	0,00
Les	0	0	36	0	0	0	36	100,00
Ječmen	3	0	7	43	5	0	58	74,14
Střišťe	0	0	1	9	46	4	60	76,67
Pšenice	0	44	3	0	0	64	111	57,66
Celkem	108	44	50	68	59	68	397	--
zpracovatelská přesnost [%]	97,22	0,00	72,00	63,24	77,97	94,12	--	74,06 %
							kappa	0,68

Příloha 6: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek PRISMA (PCA komponenty) – klasifikace ML

Klasifikace Maximum Likelihood PRISMA (PCA)



školní zemědělský podnik Lány (Amálie) - červen 2022



Autor: Bc. Lukáš HOŠEK
V Praze dne 14.3.2023
Souřadnicový systém: WGS 1984 UTM Zone 33N
Projekt uskutečněn pomocí ORIGINALNÍCH produktů
PRISMA - © Italská kosmická agentura (ASI);
produkty byly dodány na základě licence ASI k použití.

Klasifikace Minimum Distance PRISMA (PCA)

školní zemědělský podnik Lány (Amálie) - červen 2022





Autor: Bc. Lukáš HOŠEK
V Praze dne 14.3.2023
Souřadnicový systém: WGS 1984 UTM Zone 33N
Projekt uskutečněn pomocí ORIGINALNÍCH produktů
PRISMA - © Italská kosmická agentura (ASI);
produkty byly dodány na základě licence ASI k použití.

Příloha 8: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek PRISMA (PCA komponenty) – klasifikace NN

Klasifikace Neural Net PRISMA (PCA)



školní zemědělský podnik Lány (Amálie) - červen 2022



Autor: Bc. Lukáš HOŠEK
V Praze dne 14.3.2023
Souřadnicový systém: WGS 1984 UTM Zone 33N
Projekt uskutečněn pomocí ORIGINALNÍCH produktů
PRISMA - © Italská kosmická agentura (ASI);
produkty byly dodány na základě licence ASI k použití.

Klasifikace Spectral Angle Mapper PRISMA (PCA)

školní zemědělský podnik Lány (Amálie) - červen 2022





Autor: Bc. Lukáš HOŠEK
V Praze dne 14.3.2023
Souřadnicový systém: WGS 1984 UTM Zone 33N
Projekt uskutečněn pomocí ORIGINALNÍCH produktů
PRISMA - © Italská kosmická agentura (ASI);
produkty byly dodány na základě licence ASI k použití.

Příloha 10: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek PRISMA (PCA komponenty) – klasifikace SVM

Klasifikace Support Vectore Machines PRISMA (PCA)

školní zemědělský podnik Lány (Amálie) - červen 2022





Autor: Bc. Lukáš HOŠEK
V Praze dne 14.3.2023
Souřadnicový systém: WGS 1984 UTM Zone 33N
Projekt uskutečněn pomocí ORIGINALNÍCH produktů
PRISMA - © Italská kosmická agentura (ASI);
produkty byly dodány na základě licence ASI k použití.

Příloha 11: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek LANDSAT 9 – klasifikace ML

Klasifikace Maximum Likelihood LANDSAT 9

školní zemědělský podnik Lány (Amálie) - červen 2022





Autor: Bc. Lukáš HOŠEK
V Praze dne 14.3.2023
Souřadnicový systém: WGS 1984 UTM Zone 33N
Zdroj dat: <https://earthexplorer.usgs.gov/>

Příloha 12: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek LANDSAT 9 – klasifikace MD

Klasifikace Minimum Distance LANDSAT 9

školní zemědělský podnik Lány (Amálie) - červen 2022





Autor: Bc. Lukáš HOŠEK
V Praze dne 14.3.2023
Souřadnicový systém: WGS 1984 UTM Zone 33N
Zdroj dat: <https://earthexplorer.usgs.gov/>

Příloha 13: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek LANDSAT 9 – klasifikace NN

Klasifikace Neural Net LANDSAT 9

školní zemědělský podnik Lány (Amálie) - červen 2022





Autor: Bc. Lukáš HOŠEK
V Praze dne 14.3.2023
Souřadnicový systém: WGS 1984 UTM Zone 33N
Zdroj dat: <https://earthexplorer.usgs.gov/>

Příloha 14: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek LANDSAT 9 – klasifikace SAM

Klasifikace Spectral Angle Mapper LANDSAT 9

školní zemědělský podnik Lány (Amálie) - červen 2022





Autor: Bc. Lukáš HOŠEK
V Praze dne 14.3.2023
Souřadnicový systém: WGS 1984 UTM Zone 33N
Zdroj dat: <https://earthexplorer.usgs.gov/>

Příloha 15: Výsledná klasifikace zemědělského podniku Lány (Amálie) pro snímek LANDSAT 9 – klasifikace SVM

Klasifikace Support Vectore Machines LANDSAT 9

školní zemědělský podnik Lány (Amálie) - červen 2022



Autor: Bc. Lukáš HOŠEK
V Praze dne 14.3.2023
Souřadnicový systém: WGS 1984 UTM Zone 33N
Zdroj dat: <https://earthexplorer.usgs.gov/>