

Česká zemědělská univerzita v Praze

Fakulta agrobiologie, potravinových a přírodních zdrojů



**Rozlišování plevelů v porostu vojtěšky na základě
spektrálních vlastností**

Diplomová práce

Autor: Ing. Martin Divišek

Vedoucí práce: Ing. Pavel Hamouz, Ph.D.

© 2023 ČZU v Praze

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta agrobiologie, potravinových a přírodních zdrojů

ZADÁNÍ DIPLOMOVÉ PRÁCE

Ing. Martin Divišek

Zemědělství a rozvoj venkova
Hospodaření v zemědělství

Název práce

Rozlišování plevelů v porostu vojtěšky na základě spektrálních vlastností

Název anglicky

Discrimination of weeds in alfalfa canopy based on spectral properties

Cíle práce

Cílem práce je analyzovat spektrální vlastnosti vojtěšky seté a vybraných vytrvalých plevelů a identifikovat takové spektrální rozdíly, které bude možno využít pro rozlišení jednotlivých rostlinných druhů v porostech vojtěšky při cílené regulaci zaplevelení v systému precizního zemědělství. Vědecká hypotéza předpokládá, že mezi vojtěškou a některými druhy plevelů existují rozdíly ve spektrálních vlastnostech, které umožní jejich vzájemné odlišení.

Metodika

Pomocí přenosného spektrometru bude analyzována spektrální odrazivost vojtěšky a vybraných plevelů v různých růstových fázích. Budou identifikována spektrální pásma, která jsou charakteristická pro jednotlivé rostlinné druhy a jejich růstové fáze. Budou navrženy algoritmy vhodné pro rozpoznání jednotlivých rostlinných druhů. Spektrální měření budou probíhat při obrůstání porostů po sečích. V podzimním období budou data zpracována a analyzována. Prosinec až únor druhého ročníku bude vyhrazen pro kompletní diplomovou práci.

Doporučený rozsah práce

50 stran

Klíčová slova

spektrální analýza, plevele, vojtěška setá, vegetační indexy, cílená regulace zaplevelení, precizní zemědělství

Doporučené zdroje informací

- Borregaard T, Nielsen H, Nørgaard L, Have H. 2000. Crop-weed discrimination by line imaging spectroscopy. *Journal of Agricultural Engineering Research* 75:389-400.
- El-Faki, MS, Zhang N, Peterson, DE. 2000. Factors affecting color-based weed detection. *Transactions of the American Society of Agricultural Engineers* 43(4): 1001–1009.
- Hahn F, Muir, AY. 1993. Weed-crop discrimination by optical reflectance. In: *Proceedings of the IV International Symposium on Fruit, Nut, and Vegetable Production Engineering*, edited by F. Juste (Ministerio de Agricultura, Pesca y Alimentación, INIA, March 1993, Valencia-Zaragoza, Spain), p. 221–228.
- Shirzadifar A, Bajwa S, Mireei SA, Howatt K, Nowatzki J. 2018. Weed species discrimination based on SIMCA analysis of plant canopy spectral data. *Biosystems Engineering* 171:143-154.
- Vrindts E, De Baerdemaeker J, Ramon H. 2002. Weed Detection Using Canopy Reflection. *Precision Agriculture* 3:63-80.
- Zwiggelaar R. 1998. A review of spectral properties of plants and their potential use for crop/weed discrimination in row-crops. *Crop protection* 17:189-206.

Předběžný termín obhajoby

2022/23 LS – FAPPZ

Vedoucí práce

Ing. Pavel Hamouz, Ph.D.

Garantující pracoviště

Katedra agroekologie a rostlinné produkce

Elektronicky schváleno dne 21. 2. 2023

prof. Ing. Josef Soukup, CSc.

Vedoucí katedry

Elektronicky schváleno dne 21. 2. 2023

prof. Ing. Josef Soukup, CSc.

Děkan

V Praze dne 13. 04. 2023

Čestné prohlášení

Prohlašuji, že jsem svou diplomovou práci "Rozlišování plevelů v porostu vojtěšky na základě spektrálních vlastností" vypracoval samostatně pod vedením Ing. Pavla Hamouze a s použitím odborné literatury a dalších informačních zdrojů, které jsou citovány v práci a uvedeny v seznamu literatury na konci práce. Jako autor uvedené diplomové práce dále prohlašuji, že jsem si vědom, že zveřejněním bakalářské práce souhlasím s jejím zveřejněním dle zákona č. 111/1998 Sb. o vysokých školách v platném znění, a to bez ohledu na výsledek její obhajoby.

V Praze dne 13.04.2023

Ing. Martin Divišek

Poděkování

Rád bych touto cestou poděkoval Ing. Pavlu Hamouzovi, Ph.D za výtečné vedení a vstřícnost při konzultacích a zpracování diplomové práce. Dále bych rád poděkoval své rodině, přítelkyni, blízkým a přátelům.

Rozlišování plevelů v porostu vojtěšky na základě spektrálních vlastností

Abstrakt

V této diplomové práci bylo provedeno rozlišení plevelů - šťovíku tupolistého (*Rumex obtusifolius*) a pampelišky lékařské (*Taraxacum officinale*) v porostech vojtěšky seté (*Medicago sativa*) pomocí statistických přístupů na základě spektrálních dat získaných ručním měřením odrazivosti listových ploch rostlin pomocí spektrometru FieldSpec 4. Úpravou získaných dat v prostředí Microsoft Excel a následným zpracováním v statistickém prostředí Rstudio byla pomocí analýzy hlavních komponent (PCA) ověřena vhodnost sedmi vlnových pásem (430-450 nm, 540-560 nm, 720-730 nm, 765-785 nm, 1060-1080 nm, 1440-1460 nm, 1920-1940 nm), ve kterých všechny tři rostlinné druhy vykazovaly významně rozdílnou spektrální odrazivost. K provedení druhové klasifikace byla použita lineární diskriminační analýza (LDA). Model LDA však musel být nejprve na základě trénovacích dat (800 měření pro každý druh) natrénován tak, aby cílová proměnná, tedy druh, byla předpovězena na základě rozsahu sedmi stanovených vlnových pásem. Námí natrénovaný model LDA pak při klasifikaci validačních dat (400 měření pro každý druh) vykazoval celkovou úspěšnost klasifikace 95,58 %. Správně bylo klasifikováno 91 % pampelišek, 99 % šťovíků a 96,7 % vojtěšek. Korigovaná přesnost klasifikace byla pro všechny třídy vyšší než 95 %. Byl tak představen postup metodiky založený na hyperspektrálním snímkování, díky kterému je možné spolehlivě rozlišovat tyto rostlinné druhy.

Klíčová slova: Spektrální analýza plevelů, vojtěška setá, vegetační indexy, cílená regulace zaplevelení, precizní zemědělství

Discrimination of weeds in alfalfa canopy based on spektral properties

Abstract

This masters thesis aimed to distinguish between two weed species – *Rumex obtusifolius* and *Taraxacum officinale* – in *Medicago sativa* crops using statistical approaches based on spectral data obtained from manual measurements of the reflectance of leaf surfaces using a FieldSpec 4 spectrometer. The suitability of seven wavelength ranges (430-450 nm, 540-560 nm, 720-730 nm, 765-785 nm, 1060-1080 nm, 1440-1460 nm, 1920-1940 nm) was verified for all three plant species using principal component analysis (PCA) after processing the obtained data in Microsoft Excel and Rstudio statistical environment. The three plant species exhibited significantly different spectral reflectance in these wavelength ranges. Linear discriminant analysis (LDA) was used for species classification. However, the LDA model had to be first trained on the basis of training data (800 measurements for each species) to predict the target variable, i.e., species, based on the range of the seven specified wavelength ranges. Our trained LDA model achieved an overall classification accuracy of 95.58 % when classifying validation data (400 measurements for each species), with 91 % of *Taraxacum officinale*, 99 % of *Rumex obtusifolius*, and 96.7 % of *Medicago sativa* being correctly classified. The corrected classification accuracy was higher than 95% for all classes. Thus, a procedure based on hyperspectral imaging was presented, which can reliably distinguish these plant species.

Keywords: Spectral analysis of weeds, *Medicago sativa*, vegetation indices, targeted weed control, precision agriculture.

Obsah

1	ÚVOD	8
2	VĚDECKÁ HYPOTÉZA A CÍLE PRÁCE	9
3	LITERÁRNÍ REŠERŠE	10
3.1	ZÁKLADNÍ CHARAKTERISTIKA A PLATFORMY DÁLKOVÉHO PRŮZKUMU ZEMĚ	10
3.1.1	Precizní zemědělství (PZ), jeho přínosy, technologie a vlastnosti dat.....	12
3.2	ZÁKLADNÍ PRINCIPY DPZ.....	15
3.2.1	Dělení elektromagnetického spektra (Mason & Schmetz 1992)	16
3.2.2	Spektrální odrazivost	17
3.2.3	Spektrální odrazivost vegetace.....	18
3.3	VEGETAČNÍ INDEXY	21
3.3.1	Základní vegetační indexy	21
3.3.2	Vegetační index zohledňující atmosférické jevy	22
3.3.3	Vegetační indexy s korekcí půdy	23
3.3.4	Vegetační indexy odrážející status vegetace	24
3.4	TECHNOLOGIE HYPERSPEKTRÁLNÍHO A MULTISPEKTRÁLNÍHO ZOBRAZOVÁNÍ	25
3.4.1	Hyperspektrální senzor	26
3.4.2	Hyperspektrální kamera.....	26
3.5	ZPRACOVÁNÍ HYPERSPEKTRÁLNÍCH DAT (SENZORY).....	27
3.5.1	Selekce pomocí PCA	27
3.5.2	Klasifikace pomocí LDA	28
3.6	POKROČILÉ PŘÍSTUPY ZPRACOVÁNÍ HYPERSPEKTRÁLNÍCH DAT	28
3.7	PŘÍKLADY APLIKACE DPZ V ZEMĚDĚLSTVÍ	32
3.8	ROZLIŠOVÁNÍ PLEVELŮ PLODIN NA ZÁKLADĚ SPEKTRÁLNÍCH VLASTNOSTÍ	33
4	MATERIÁL A METODY	36
4.1	FILEDSPEC 4 SPEKTROMETR	36
4.2	SBĚR A ZPRACOVÁNÍ DAT	37
4.2.1	Zpracování dat Microsoft Excel	38
4.2.2	Zpracování dat v prostředí Rstudio	39
5	VÝSLEDKY	41
5.1	PCA.....	41
5.2	LDA	44
6	DISKUZE	47
7	ZÁVĚR	50
8	SEZNAM LITERATURY	52

Seznam obrázků, tabulek a grafů

Obrázky:

Obrázek 1: Rozdělení homogenního celku na menší celky (Žížala et al. 2021)	12
Obrázek 2: Elektromagnetické spektrum s umístěním slunečního záření.	16
Obrázek 3: Změna odrazivosti v jednotlivých pásmech při stresu nebo odumření vegetace (Antognelli 2018).....	20
Obrázek 4: Změny vegetace v letech 2000 - 2017 v lesích Miombo (Chiteculo et al. 2019)	22
Obrázek 5: Multi a hyperspektrální zobrazení (Adão et al. 2017)	25
Obrázek 6: Porovnání vrstev obrazů MSP a HPS zobrazování. (Edmunt Optics 2023)	26
Obrázek 7: Topografická reprezentace jedno pásmového obrazu (Tarabalka et al. 2010).	30
Obrázek 8: Příklad WS v 1D (Tarabalka et al. 2010)	30
Obrázek 9: Proces segmentace WS (Wang & Xu 2018).....	31
Obrázek 10: Klasifikace, detekce patogenu, segmentace (Boulent et al. 2019).....	31
Obrázek 11: FieldSpec 4 (foto autor).....	36

Tabulky:

Tabulka 1: Pigmentační absorpce vegetace (Zwiggelaar 1998)	18
Tabulka 2: Specifikace produktu FieldSpec 4 (Malvern Panalytical 2022)	37
Tabulka 3: Počty provedených spektrálních měření pro jednotlivé druhy rostlin.....	39
Tabulka 4: Spektrální pásma vybraná pro diskriminaci rostlinných druhů na základě vizuálního hodnocení spektrálních křivek.....	41
Tabulka 5: Významnost hlavních komponent	42
Tabulka 6: Tabulka zátěží pro původní proměnné (nm) vzhledem k hlavním komponentám	43
Tabulka 7: Průměrné hodnoty proměnných (nm) pro jednotlivé rostlinné druhy	44
Tabulka 8: Vypočtené koeficienty lineárních diskriminantů (LD)	44
Tabulka 9: Chybová matice pro trénovací data	45
Tabulka 10: Chybová matice pro validační data.....	45
Tabulka 11: Statistiky výkonosti modelu LDA pro validační data	46

Grafy:

Graf 1: Četnost článků dle síly důkazů pro ekonomické, agronomické a enviromentální hodnocení (Koutsos & Menexes 2019)	14
Graf 2: Křivky spektrální odrazivosti oblak, půdy, vegetace a vody (Žížala et al. 2021)	18
Graf 3: Spektrální odrazivost trav, břízy, borovice a jedle (Roy 1989).....	19
Graf 4: Porovnání průměrných hodnot odrazivosti pro jednotlivé rostlinné druhy.....	41
Graf 5: Biplot s pozicemi druhů vzhledem k PC1 a PC2 (P-pampeliška, S-Šťovík, VO-vojtěška).....	43

Seznam použitých zkratk a symbolů

- ARVI – Atmospherically Resistant Vegetation Index (Index vegetace odolný vůči atmosférickým vlivům)
- CWSI – Crop water stress index (Index vodního stresu)
- DPZ – Dálkový průzkum Země
- DVI – Difference vegetation index (Diferenční vegetační index)
- GIS – Geografický informační systém
- GNSS – Globální navigační satelitní systém
- GPS – Global positioning system (Globální navigační systém)
- HPS – Hyperspektrální
- IWS – Inverse watershed segmentation (Inverzní segmentace povodí)
- LDA – Linear discriminant analysis (Lineární diskriminační analýza)
- LiDAR – Light detection and ranging
- MSP – Multispektrální
- NDVI – Normalized difference vegetation index (Normalizovaný diferenční vegetační index)
- NIR – Near infrared (Blízké infračervené záření)
- PCA – Principal component analysis (Analýza hlavních komponent)
- PZ – Precizní zemědělství
- RGB – Red, green, blue (Červená, modrá zelená)
- RRI – Relative reflectivity index (index relativní odrazivosti)
- RVI – Ratio vegetation index (Poměrový vegetační index)
- SWIR – Short wave infrared (Krátkovlnné infračervené záření)
- TIR – Thermal infrared (Termální)
- UAV – Unmanned Aerial Vehicle (Bezpilotní letadlo)
- VI – Vegetation index (Vegetační index)
- VRT – Variable rate technology (Technologie proměnného dávkování)
- WS – Watershed segmentation (Segmentace povodí)

1 Úvod

V posledních desetiletích globální populace stále narůstá a s touto skutečností se tak zvyšuje poptávka po potravinách. To představuje výzvu pro zemědělský sektor, který musí produkovat více potravin na stále menší ploše zemědělské půdy. V současné době čelí globální zemědělství i mnoha dalším výzvám, jako je například klimatická změna, degradace půdy, nedostatek vody a pracovní síly (Novotný et al. 2017). V této situaci se tak moderní metody využívající nejnovější technologie stávají klíčovými nástroji pro dosažení efektivnějšího a udržitelného zemědělství (Gras & Cáceres 2020). Jednou z těchto metod je dálkový průzkum Země (DPZ), díky kterému mohou zemědělci získávat a využívat přesné informace o půdě a rostlinách ze všech obhospodařovaných pozemků najednou s aspektem nízké časové náročnosti. Mezi klíčové prvky DPZ se v tomto kontextu řadí principy vědního oboru spektroskopie a nejmodernější technologie hyperspektrálního či multispektrálního snímkování využívaných pro sběr a tvorbu obrazových dat. Proto i inovativní přístupy k regulaci plevelů, které mohou významně snížit výnosy a kvalitu plodin, sledují tyto trendy se snahou o aplikaci v praxi. (European Parliament 2016; Monteiro & Santos 2022).

Tato diplomová práce představuje přístup plevelné regulace na základě jejich rozlišování v polních porostech pomocí spektrálních vlastností, díky čemuž mohou být plevele identifikovány a odděleny od užitečných rostlin na základě jejich odlišných spektrálních charakteristik. Pokud budeme moci získávat přesné údaje o počtu a lokalizaci plevelů, mohl by být proces plánování a provedení jejich cílené regulace velmi usnadněn. V případě, že se v budoucích letech podaří tento proces i úspěšně zautomatizovat a zavést do praxe, může být dosaženo významných přínosů na poli globálního zemědělství, mezi které patří například minimalizace používání herbicidů. Zároveň by tak mohlo být docíleno zvýšení výnosů, a to vše za předpokladu nižších nákladů a zlepšení kvality půdy i vody.

V kontextu narůstajícího trendu populace a úbytku zemědělské půdy se tento koncept tak jeví jako velmi slibný pro zvýšení celkové efektivity a udržitelnosti zemědělské výroby (Thompson et al. 1991; Monteiro & Santos 2022).

2 Vědecká hypotéza a cíle práce

Cílem práce je vyjádřit a popsat spektrální vlastnosti vojtěšky seté (*Medicago sativa*) a vybraných vytrvalých plevelů šťovík tupolistý (*Rumex obtusifolius*) a pampeliška lékařská (*Taraxacum officinale*) na základě odrazivosti vlnových délek. Nejprve bylo třeba provést několik tisíc měření rostlin pro každý druh pomocí spektrometru FieldSpec 4 v rozsahu vlnových délek 350–2500 nm. Z těchto dat pak vyjádřit reprezentativní průměry v každé vlnové délce pro každý druh a vytvořit průběhy spektrálních křivek. Poté definovat pásma prokazatelných rozdílů pomocí optického zhodnocení. V prostředí Rstudio pak náš výběr pomocí analýzy hlavních komponent (PCA) potvrdit, či přehodnotit. Na závěr pomocí lineární diskriminační analýzy (LDA) provést automatickou klasifikaci na základě vybraných vlnových délek pro všechny tři rostlinné druhy a vyhodnotit míru její přesnosti. Vědecká hypotéza předpokládá, že mezi vojtěškou, šťovíkem a pampeliškou existují rozdíly ve spektrálních vlastnostech, které umožní jejich vzájemné odlišení.

3 Literární rešerše

Koncept předložené literární rešerše je navržen tak, aby čtenáře uvedl do základní problematiky DPZ včetně rozdělení platform, kterých se při jeho provádění využívá. V tomto kontextu je zahrnuta také souhrnná charakteristika PZ včetně jeho přínosů a technologií, které jsou v rámci PZ využívány. V další kapitole jsou rozebrány základní principy DPZ z hlediska vědního oboru spektroskopie jako rozdělení elektromagnetického spektra a spektrální odrazivost vegetace. Následná kapitola popisuje potřebnost a vlastnosti vegetačních indexů včetně jejich rozdělení. Z důvodu, že se pro sběr dat o spektrální odrazivosti vegetace využívá stále inovativnějších metod, jsou rozebrány i technologie hyperspektrálního a multispektrálního snímkování. Po samotném sběru dat vystává otázka, jaké budou postupy jejich zpracování. Proto jsou dále popsány základní metody zpracování hyperspektrálních dat získaných pomocí senzorů, které byly aplikovány i v metodickém postupu. Následně jsou rozebrány i pokročilé metody jako například neuronové sítě, které se používají zejména pro data získaných pomocí kamer. V závěru se pak čtenář dozví o příkladných studiích informujících o různých aplikacích DPZ v zemědělství. Věřím, že po prostudování informací v literární rešerši pak čtenář získá potřebné informace, díky kterým bude moci objektivně uchopit poslední kapitolu, která pojednává o samotném rozlišování plevelů plodin na základě spektrálních vlastností a uchopit tak nabyté znalosti pro další výzkum v této oblasti.

3.1 Základní charakteristika a platformy dálkového průzkumu Země

V knize autorů Campbell a Wynne (2011) se píše, že DPZ lze definovat jako nepřímý sběr informací o zemi a vodních plochách pomocí snímků získaných z nadzemní perspektivy. Využívá elektromagnetického záření v jednom nebo více intervalech spektra. Tato záření jsou pak zaznamenávána na příslušný senzor.

Tyto senzory lze rozdělit na aktivní a pasivní. Principem aktivních senzorů je vypouštění paprsků energie a zaznamenávání jejich zpětného odrazu od cíleného objektu. Řadí se sem například radary, laserové výškoměry nebo LiDAR. Pasivní senzory naopak zaznamenávají záření ve specifických spektrálních pásmech, které je přirozeně odraženo, či emitováno od cílových objektů. Důležitým vybavením jsou technické prostředky jako hardwarová a softwarová technika, díky kterým je možno přijímat, ukládat, zpracovávat a vyhodnocovat získané informace (Surový et al. 2019).

Samotné senzory pak mají své nosné platformy, které korespondují se třemi letovými hladinami. Těmi hladinami dle White et al. (2016) jsou.

Kosmická

Ta poskytují data s největším prostorovým rozsahem, ale nejnižším rozlišením. Data získaná z kosmických platform v současné době patří k běžným informačním zdrojům. Jsou významné z hlediska sběru plošných, prostorových i časových dat. Jejich výhoda spočívá v rychlosti a komplexnosti sběru dat z daného území. Mezi nevýhody patří vysoké investiční náklady, nemožnost sběru dat za určitého vlivu počasí (noc, vliv oblačnosti, dlouhá periodičita snímkování stejného území) (Pavelka 2010).

Vyšší letová (letadla)

Letadla se v této letové hladině pohybují v řádu stovek metrů až jednotek kilometrů nad zemí a lze s nimi pokrýt oblasti na úrovni regionů či celých států (Kuželka et al. 2020). Dle Neale et al. (2005) letecké platformy hrají významnou roli v DPZ. Z důvodu krátké doby sběru objemných dat z rozsáhlých ploch, či flexibilnímu harmonogramu akvizice mají své výhody oproti satelitům.

Nížší letová (UAV)

Při řešení DPZ se dnes stále častěji používají UAV (Unmanned Aerial Vehicles – bezpilotní letadla). Létání s nimi, se provádí v nízké letové hladině usazené v desítkách metrů nad zemí. Díky tomu poskytují ultra vysoké rozlišení sesbíraných dat, za krátký časový úsek. Jejich dalšími benefity jsou flexibilita, nižší pořizovací náklady a nezávislost provádění opakovaného sběru informací, což umožňuje pilotům získat vlastní dat. Tyto výhody však doprovází i negativa, a to sběr dat pouze v lokálním prostoru (Kuželka et al. 2020)

Pozemní

Dle Wójtowicz et al. (2016) se při provádění DPZ na pozemní hladině používají ručně nesené přístroje, ale mnohem užitečnější a běžně využívané jsou senzory přidělané na zemědělské technice. Tyto senzory jsou velmi užitečné při mapování v malém měřítku. Tato technologie představuje při srovnání se satelitním a leteckým DPZ lepší časové, spektrální a prostorové rozlišení. Limitujícími faktory jsou však nízká efektivita a vysoká časová náročnost sběru dat, kdy je sběr omezen na vyhodnocování malých ploch.

Technologie DPZ se stala světově využívanou metodou, jejíž využití stále rychle roste díky neustálému pokroku v oblasti kosmických družic, satelitů, letadel, pozemních senzorů a UAV z hlediska prostorového, časového, spektrálního a radiometrického

rozlišení. Proto je zde možné zmínit několik jeho jedinečných vlastností (Liaghat & Balasundram 2010).

- Systematické získávání dat na rozsáhlých územích
- Sběr dat z nepřístupných míst
- Možnost získávání vlastních dat
- Využití dat srze široké spektrum zájmových oblastí

Díky možnosti nedestruktivního způsobu systematicky opakovaného sběru dat je DPZ v současné době využívám jako základní nástroj na poli konvenčního a především precizního zemědělství (Weiss et al. 2020).

3.1.1 Precizní zemědělství (PZ), jeho přínosy, technologie a vlastnosti dat

Obecná charakteristika činnosti precizního zemědělství spočívá v konceptu, že oproti klasickému přístupu není nenakládáno s jednotlivými zemědělskými plochami jako s homogenními celky. Respektive, jeden velký homogenní celek, je rozdělen na menší, které mají rozdílné vlastnosti, jako např. úrodnost, retence vody, utužení či zásobu živin a organické hmoty (viz obr. č.1). PZ si klade za cíl provádět diferenciované pěstební operace v souladu se skutečnými potřebami plodin na malých plochách v rámci celého pozemku (celku). Pro tento proces se v zahraniční literatuře používá termín Variable rate technology (VRT), překládán jako aplikace s proměnlivou dávkou. Pro koncept precizního zemědělství je tak stěžejní mít dostatek podkladových dat, získaných právě z velké části pomocí DPZ (Žížala et al. 2021).



Obrázek 1: Rozdělení homogenního celku na menší celky (Žížala et al. 2021)

Přínosy precizního zemědělství

Využívání precizního zemědělství skýtá mnohé přínosy jak v ekonomické a agronomické, z hlediska nižších výrobních nákladů a vyšší efektivity hospodaření tak enviromentální rovině, jako snížení negativních vlivů na životní prostředí (Koutsos & Menexes 2019).

Ekonomické a agronomické přínosy

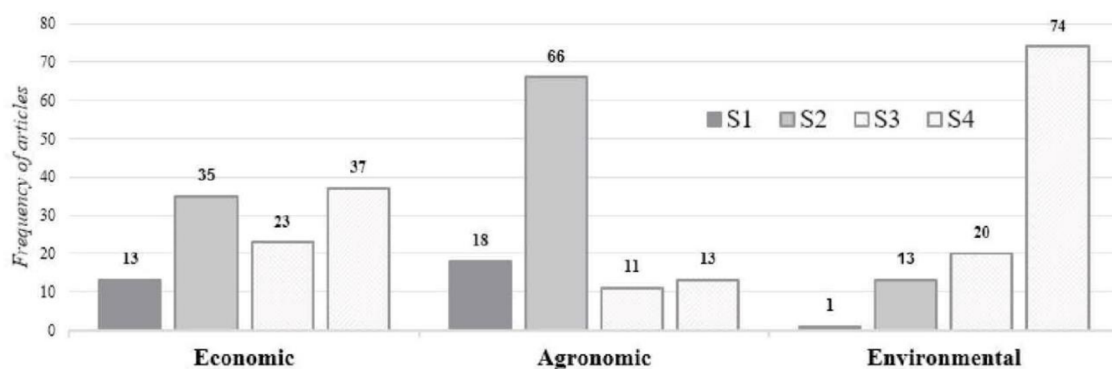
Plynou z optimalizace vstupů do rostlinné, ale i živočišné produkce. Mezi potenciální ekonomické přínosy PZ patří snížení nákladů například tím, že se hnojiva aplikují pouze tam, kde jsou potřebná, a to na základě odběrů půdních vzorků a analýzy údajů o výnosech, či zlepšení hospodaření s vodními zdroji (Mintert et al. 2016). Z hlediska optimalizace lze uvažovat i snížení spotřeby pohonných hmot, která je dána zefektivněním provozu strojů pomocí navigačních systémů korigující pojezdy s ohledem na reliéf a tvar pozemku, pracovní operace, parametry mechanizační soupravy a konkrétní podmínky na stanovišti (utužení půdy, erozní ohroženost apod.). Kromě optimalizace pracovních operací je možné úspory dosáhnout také efektivním řízením dopravy. V neposlední řadě může mít precizní zemědělství pozitivní vliv v oblasti lidských zdrojů, kdy se automatizací zjednoduší řada pracovních operací (Žížala et al. 2021). V konečném důsledku tak tyto aspekty mohou vést k zvýšení výnosových hladin pěstovaných plodin v rámci zemědělského podniku.

Enviromentální přínosy

Je patrné, že úspory v ekonomické sféře přesahují i do snížení enviromentálního zatížení. Například omezení přehnojování půdy díky aplikování přesných a plně využitelných dávek minerálních či statkových hnojiv zajišťuje snížení uniku nitrátů z orné půdy do vodních toků. Stejně tak i cílené používání přípravků na ochranu rostlin vede ke snižování jejich spotřeby a tím pádem i k redukci zatížení kontaminace environmentu jejich rezidui. Mezi další přínosy se může dále řadit omezení eroze půdy, eutrofizace vod a snížení spotřeby pohonných hmot či redukci utužení půd snížením počtu přejezdů zemědělské techniky přes pozemek. Je třeba si však uvědomit, že enviromentální přínosy jsou komplexní záležitostí, a proto je obtížné, jakkoliv odhadnout či vyjádřit (Koutsos & Menexes 2019; Žížala et al. 2021).

Souhrnné zhodnocení PZ

Detailní analýzou hodnocení ekonomických, enviromentálních a agronomických přínosů plynoucí z PZ se zabývala studie (Koutsos & Menexes 2019). Autoři této studie provedli systematický přehled, jenž analyzoval literaturu na toto téma za poslední desetiletí. Na základě stanovených kritérií bylo prozkoumáno 108 relevantních studií. Souhrnné rozdělení četnosti článků dle síly důkazu, kde (S1) jsou pádné důkazy, (S2) mírné důkazy, (S3) slabé důkazy a (S4) žádné, lze vidět na grafu č.1.



Graf 1: Četnost článků dle síly důkazů pro ekonomické, agronomické a enviromentální hodnocení (Koutsos & Menexes 2019)

Technologie precizního zemědělství

Technologie využívané v precizním zemědělství lze rozdělit do dvou kategorií na hardware a software. Obě kategorie však sledují moderní trendy. Zejména globálních navigačních satelitních systémů, globálních informačních systémů a komunikačních technologií. Dále pak senzorové či nano senzorové a multimediální techniky pro DPZ (Cisternas et al. 2020).

(Globální navigační satelitní systémy – GNSS) Jedná se o dálkoměrný systém, kdy síť satelitů neustále přenáší zakódované informace, díky kterým lze skrze propojení přes radiové přijímače přesně vypočítat stávající polohu na Zemi, a to s přesností od desítek metrů až po jednotky centimetrů (Bhatta 2010). V současnosti spadají pod GNSS – GPS (Global Positioning System), GLONASS (Globalnaja Navigacionalnaja Sputnikovaja Sistema), Galileo, COMPASS a BeiDou (Láska et al. 2010; Jin et al. 2022).

Senzorové technologie se rozdělují na aktivní a pasivní viz (Surový et al. 2019) a jsou dle (Liaghat & Balasundram 2010) klíčovým prvkem v precizním zemědělství, protože umožňují zemědělcům získat přesné informace o růstu rostlin a půdních podmínkách

a optimalizovat využití zdrojů. Řadí se sem například Sensory pro měření půdní vlhkosti, teploty půdy, množství dusíku v půdě, fotosyntetické aktivity rostlin apod. Do pasivních spadají například určité typy Yara-N-Senzorů pro hodnocení spektrálních vlastností porostů cílené pro určení výživného stavu dusíkem. Nicméně Yara má i aktivní N-senzory.

(Geografické informační systémy– GIS) V těchto systémech probíhá zpracování prostorových dat. Jedná se počítačové, mobilní či cloudové aplikace, které umožňují provádět zpracování, analýzy a exporty dvou základních typů dat – vektorů a rastrů. Vektorová data reprezentují body, linie a polygony. Rastry jsou pak obrazovými daty s definovanou nejmenší jednotkou – pixelem. Záznamy pojezdů strojů, vymezení hranic pozemků, mapy zásobenosti půdy živinami nebo výnosové mapy – to vše jsou prostorová data, která jsou vytvářena a zobrazována pomocí GIS. Zřejmě pro zemědělce nejznámější GIS aplikací je webové rozhraní LPIS (Česká technologická platforma pro zemědělství 2022). Výstupem z LPIS jsou pak například aplikační mapy, které umožňují plynulou změnu dávky hnojiva nebo postřiku, či automatickou navigaci mechanizace po pozemku.

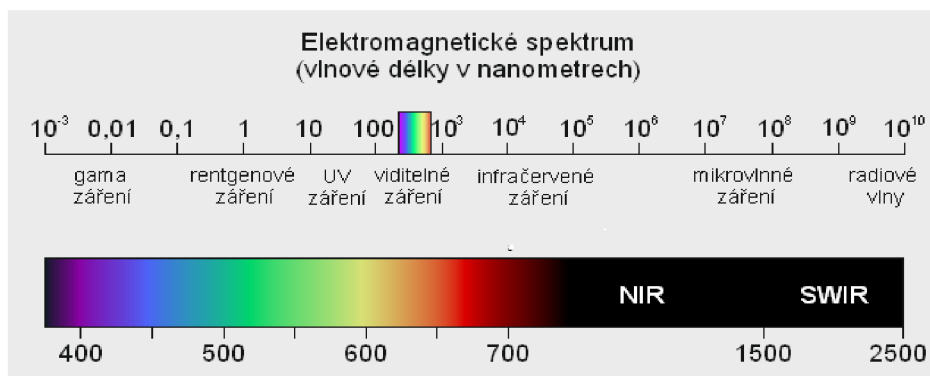
Vlastnosti dat DPZ v PZ

Mezi základní charakteristiky dat se řadí prostorové rozlišení, které označuje rozměr plochy reprezentované jedním konkrétním pixelem. Například 10 metrů znamená, že jeden pixel na obrázku odpovídá čtverci 10 x 10 metrů na zemi. (Čím vyšší prostorové rozlišení je, tím více se rozměr pixelu zmenšuje). Dále pak časové rozlišení, které označuje, jak často senzor monitoruje a zaznamenává data. Je to možnost získávání opakovaných snímků (Vysoudil 1993). Třetí klíčovou vlastností je spektrální rozlišení, které vyjadřuje schopnost senzoru detekovat změny spektrální křivky objektů v různých částech elektromagnetického spektra.

3.2 Základní principy DPZ

Charakteristika spektrálních dat je závislá na rozsahu a počtu spektrálních pásem, ve kterých je sběr prováděn za pomoci příslušného senzoru, a také na tom, jakou má cílený objekt absorpci, reflektanci či transmissi. To má vliv na kvalitativní a kvantitativní parametry získaných spektrálních dat o cílených předmětech (Milton et al. 2009).

V rámci DPZ je využíváno elektromagnetické záření, na které nahlíženo jako na vlnění o určité frekvenci a vlnové délce v rámci elektromagnetického spektra (viz obr. č. 2).



Obrázek 2: Elektromagnetické spektrum s umístěním slunečního záření.

Dle autorů Mason a Schmetz (1992) se záření elektromagnetické energie definuje v souladu s vlnovou teorií. Dle této teorie se EM. energie pohybuje rychlostí světla harmonickým sinusovým způsobem. Částicí elektromagnetického vlnění je foton. Energie se vyjadřuje jako

$$Q = \frac{hc}{\lambda}$$

Kde

h = Planckova konstanta

c = rychlost světla

λ = vlnová délka

Vzhledem k tématu této diplomové jsou v následující kapitole rozebrány charakteristiky jednotlivých vlnových délek.

3.2.1 Dělení elektromagnetického spektra (Mason & Schmetz 1992)

Gama záření je enormně energetické elektromagnetické záření vznikající v jádře atomu. Používá se například při průzkumech vesmíru, kde poskytuje cenné informace.

Rentgenové záření bývá obecně známo z lékařského prostředí při vyšetřeních, v optice, chemii či opět pro astronomická pozorování.

Ultrafialové záření (UV). Tato oblast se nachází za fialovou částí viditelné vlnové délky a odtud pochází i její název. UV záření je však z velké části rozptýleno zemskou atmosférou, a proto se v oblasti DPZ také nepoužívá.

Viditelné záření jsou barvy jako fialová, modrá, zelená, žlutá, oranžová a červená. Toto je světlo, které lidské oko dokáže registrovat a pojmenovat ho barvou. Barva předmětu je tak definována vlnovou délkou, kterou předmět odráží.

Infračervené záření. Tímto jsou označeny vlnové délky delší než červená část viditelného spektra. Tuto oblast lze rozdělit do tří částí. Tou první je blízké infračervené záření (Near-infrared NIR) o vlnové délce 760 až 1400 nm. Druhé je krátkovlnné infračervené záření (Short-wave infrared SWIR) o vlnové délce 1400 až 3000 nm. Třetí je LWIR – dlouhovlnné infračervené (tepelné) záření. Všechny tři se používají pro

Mikrovlnné záření. Jedná se o nejdelší vlnovou délku používanou v DPZ. Stěžejní výhodou tohoto spektra je, že dokáže proniknout skrze oblačnost, mlhu či prach.

Radiové vlny. Toto je nejdelší část spektra, která se většinou používá pro přenos signálu a meteorologii.

3.2.2 Spektrální odrazivost

Dle Mason a Schmetz (1992) a Nanni a Demattê (2006) je spektrální odrazivost definována jako poměr odražené energie k dopadající energii v závislosti na vlnové délce. V oblasti viditelného záření je odrazivost zodpovědná za barvu objektu. A protože různé materiály zemského povrchu mají různé charakteristiky spektrální odrazivosti, mají i různou barvu. Například stromy a rostliny vypadají zeleně, jelikož odrážejí více světla ve vlnových délkách odpovídajících zelené barvě (viz graf č. 2 a 3). Hodnoty spektrální odrazivosti objektů v různých a přesně definovaných intervalech vlnových délek tvoří spektrální signaturu objektů, dle kterých je lze barevně rozlišit. Spektrální odrazivost dána vztahem.

$$\rho(\lambda) = [E_R(\lambda) / E_I(\lambda)] \times 100$$

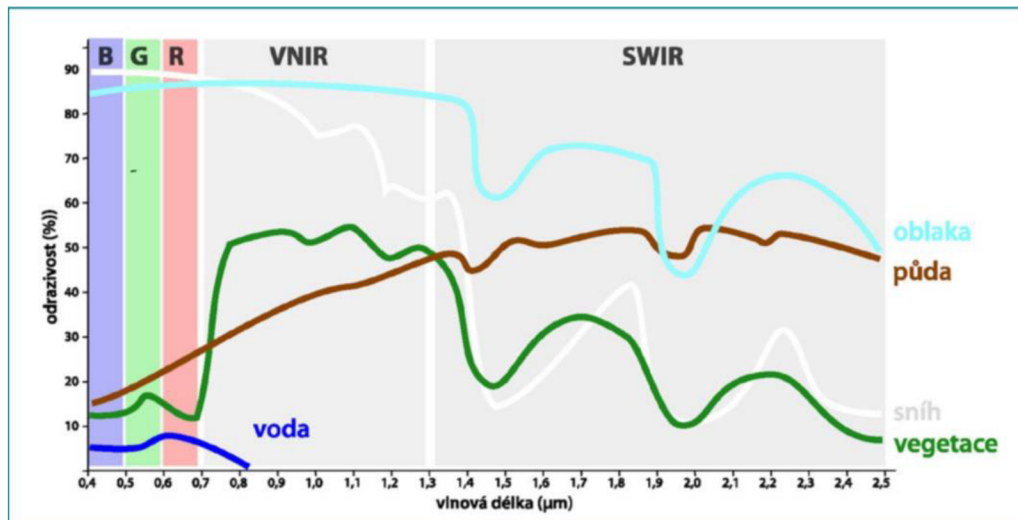
Kde

$\rho(\lambda)$ = Spektrální odrazivost při určité vlnové délce

$E_R(\lambda)$ = Energie vlnové délky odražené od objektu

$E_I(\lambda)$ = Energie vlnové délky dopadající na objekt

Graf č. 2 popisuje vztah mezi $\rho(\lambda)$ a λ v rozmezí 400 nm až 2500 nm a nazývá se obecně jako křivka spektrální odrazivosti. Křivky se u různých objektu mění s proměnlivostí jejich chemického (obsah živin) a fyzikálního složení (obsah vody), což vede k diferenciaci a odrazivosti a vlnové délky. Tento graf tak ukazuje typické křivky odrazivosti pro čtyři základní typy prvků na zemi. Jsou to oblaka, půda, zdravá vegetace a voda.



Graf 2: Křivky spektrální odrazivosti oblak, půdy, vegetace a vody (Žížala et al. 2021)

Tyto spektrální křivky odrazivosti zaujímají důležitou roli v interpretaci stavu porostů v PZ. Pokud lze rozpoznat rozdíl mezi spektrálním odrazem v určitých vlnových délkách u různých rostlin, mohlo by to být využito k rozlišení mezi plevelem a plodinami (Zwiggelaar 1998). V závislosti tématu této diplomové práce se tak nyní zaměřím pouze na spektrální odrazivost vegetace.

3.2.3 Spektrální odrazivost vegetace

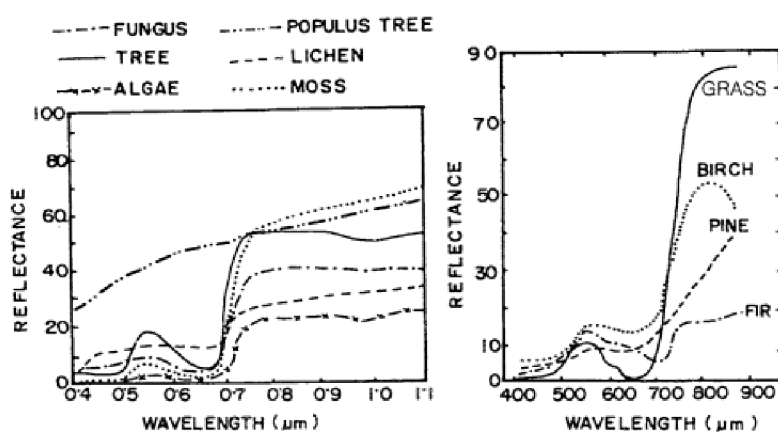
Pro pochopení spektrální odrazivosti vegetace, je důležité si nejprve uvědomit, že přímo souvisí s pigmentační absorpcí vegetace (Zwiggelaar 1998). Nejdůležitější absorpční pigmenty (s vlnovými pásmy/délky) jsou uvedeny v tab. č.1.

Tabulka 1: Pigmentační absorpce vegetace (Zwiggelaar 1998)

Absorpční pigmenty	Vlnová pásma/délky (nm)
chlorofyl a	435, 670-680, 740
chlorofyl b	480, 650
α -karotenoid	420, 440, 470
β -karotenoid	425, 450, 480
antokyan	400-550
lutein	425, 445, 475
viloxantin	425, 450, 475
voda	970, 1450, 1944

Protože většina vegetace obsahuje kombinaci uvedených pigmentů, je zřejmé, že výsledné absorpční spektrum nemá ostře ohraničené vrcholy. Některé absorpční vrcholy jsou zobrazeny na (grafu č. 2.) zelenou křivkou, která představuje typickou spektrální odrazivost a propustnost vegetace.

Absorpce v infračervené oblasti je v listech velmi nízká, proto v tomto spektru dosahuje spektrální křivka vegetace nejvyšších hodnot, a tudíž z této oblasti lze co nejpřesněji odečítat vlastnosti vegetace. Navíc je vysoká odrazivost v této části spektra pro rostliny důležitá, neboť absorpce by je mohla poškodit, či úplně zahubit (Zwiggelaar 1998). Kromě spektrální absorpce, je spektrální odrazivost ovlivněna mnoha dalšími faktory, jako například výška rostlin, počet, rozmístění a struktura listů, jejich velikost a postavení, zralost, sluneční expozice, obsah vody, chlorofylu, stav výživy, choroby a buněčná či rostlinná struktura (Roy 1989). Je třeba brát v úvahu, že různé druhy vegetace mají odlišné spektrální vlastnosti (viz graf. č. 3).



Graf 3: Spektrální odrazivost trav, břízy, borovice a jedle (Roy 1989).

Tyto spektrální vlastnosti jsou však v průběhu vegetace flexibilní. Zde tak hovoříme o časovém aspektu, který je obzvláště důležitý. To z toho důvodu, že rozlišení porostu od plevelů, a jeho následné ošetření by mělo probíhat v určitém časovém období, zpravidla v tom, ve kterém je porost nejvíce ohrožen. Ve většině případů se jedná o počátek vegetačního období, kdy je rychlost změn spektrální odrazivosti rostlin nejvyšší. Při dozrávání se odrazivost mění zásadním způsobem také. Ve zralém stavu se spektrální odrazivost výrazně nemění a vliv stresových faktorů, jako třeba nedostatek vody, napadení škůdci či nutriční nedostatek v pozdější fázi stárnutí, také nemá vliv na změny spektrální odrazivosti, jelikož rostliny jsou odumřelé (Zwiggelaar 1998). Změnu

reflektance v jednotlivých pásmech při stresu či odumření vegetace lze spatřit na obrázku č. 3.



Obrázek 3: Změna odrazivosti v jednotlivých pásmech při stresu nebo odumření vegetace (Antognelli 2018).

Ke stavu výživy dusíkem studie autora Roy (1989) říká, že s nárůstem nedostatku N se odrazivost rostlin zvyšuje ve spektru 500 až 1300 nm, ale ve spektru 1500 až 2500 nm klesá. Zvýšení odrazivosti je způsobeno tím, že absorpce v této spektrální oblasti je značně ovlivněna koncentrací pigmentů, která závisí na koncentraci N. Snížením obsahu N tedy vede ke snížení obsahu chlorofylů, což následně sníží absorpci záření (tedy zvýší se odrazivost). K poklesu odrazivosti dochází s větším obsahem vody v listech (Kauth 1976). Ke stavu výživy draslíkem studie provedená autory Al-Abbas et al. (1972) říká, že se jeho nedostatek projevuje menší tloušťkou listů a nízkým obsahem vody v listech. Rostliny tak vykazují nejvyšší odrazivost ve spektru od 750 do 1300 nm. Dalším příkladem vlivu průběhu vegetace na změny spektrální vlastností, je nárůst počtu listů. Více vrstev listů totiž dle (Roy 1989) způsobuje vyšší odrazivost v NIR. Vysvětleno je to tím, že energie prošla první (nejsvrchnější) vrstvou listů a odražená od druhé, třetí a dalších spodnějších vrstev se částečně vrací zpět přes první vrstvu. Rozdíl odrazivosti v NIR mezi počtem listů (1 až 4) dosahuje téměř 40 %. Průběh spektrální křivky odrazivosti zpravidla tak napovídá o aktuálním stavu porostu, který však v celé vlnové délce nemůže být lidským okem zaznamenán (Ehleringer & Forseth 1980; Mason & Schmetz 1992).

Jak bylo zmíněno, snímky rostlin zobrazených pouze ve viditelné části spektra však poskytují pouze omezené informace o aktuálním stavu vegetace. V případě přechodu na vlnové délky infračerveného záření, konkrétně NIR a SWIR však povrch rostlin vykazuje značně odlišné odezvy. Trendem vědy a výzkumu proto tedy je využívat rozdíly infračerveného spektra k získání celoplošných cenných informací o rostlinách. Tyto rozdíly se vyjadřují pomocí vegetačních indexů (Surový et al. 2019).

3.3 Vegetační indexy

Jak bylo zmíněno, pro kvantitativní a kvalitativní hodnocení vegetačního pokryvu, jeho vitality a dynamiky růstu na základě spektrálních vlastností se používají vegetační indexy, překládané jako (Vegetation Indices – VI). Ty lze chápat jako poměrně jednoduché a účinné algoritmy, či jako bez jednotkové radiometrické míry. Vypočítávají se jako poměry nebo rozdíly dvou či více pásem ve vlnových délkách VIS, NIR A SWIR (Wójtowicz et al. 2016). Vegetační indexy se rozdělují na širokopásmové a úzkopásmové. Aplikace těchto indexů je v současné době široce implementována v aplikacích DPZ. Kvůli různorodosti světelných zdrojů a počtů možných kombinací světelných spekter, kdy každý objekt vegetace má jiné vlastnosti neexistuje jednotný matematický výraz, který by definoval všechny VI. Z toho důvodu, jsou stále vyvíjeny algoritmy, které jsou testovány při různých aplikacích dle specifických matematických výrazů, které kombinují viditelné a infračervené oblasti spektra k získání kvantifikovatelných údajů o povrchu vegetace. VI se v praktickém použití obvykle optimalizují, aby odpovídaly specifickým požadavkům aplikace a metodikám v terénu (Xue & Su 2017).

3.3.1 Základní vegetační indexy

Jedním z prvních VI, který navrhl Jordan (1969) je Ratio Vegetation Index (RVI). Ten je založen na principu vyšší absorpce červeného než infračerveného světla. Matematicky se dá vyjádřit jako

$$RVI = \frac{NIR}{R}$$

kde NIR představuje odrazivost v blízkém infračerveném pásmu a R (odrazivost v červeném pásmu). Index RVI se široce používá pro odhad a monitoring vegetace. Nevýhodou je, že s rostoucí řídkostí vegetace (více jak 50%) klesá jeho rozlišovací schopnost (Xue & Su 2017).

Později byl navržen Difference Vegetation Index (DVI) (Richardson & Wiegand 1977).

$$DVI = NIR - R$$

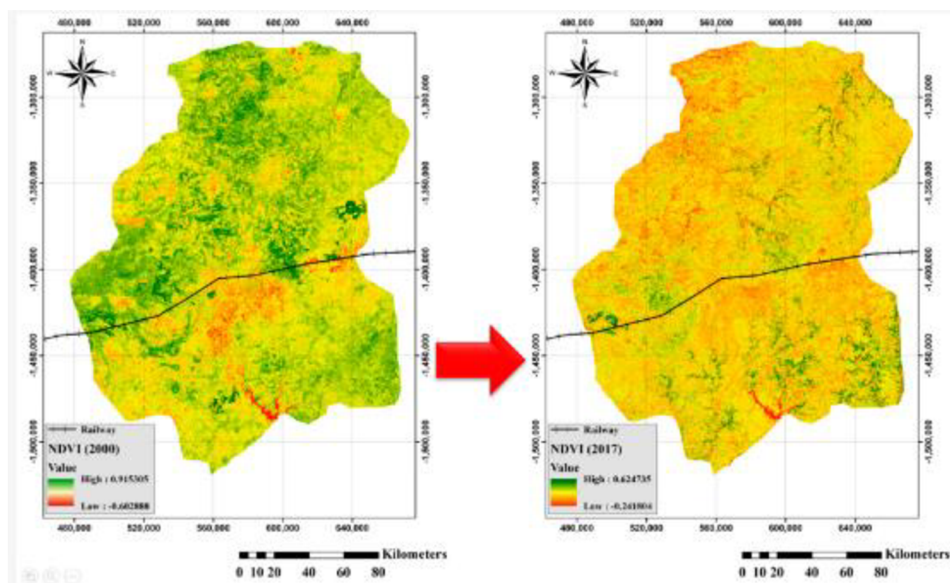
Těž jej lze využít pro monitoring vegetace.

Nejpoužívanějším VI je Normalizovaný Diferenční Vegetační Index (NDVI). NDVI používá rozdíl v odrazivosti vegetačního povrchu v červených a NIR pásmech pro detekci a studium oblasti vegetace. Popisuje úroveň vitality plodiny a vypočítává se jako poměr

mezi rozdílem a součtem lomených paprsků v červeném pásmu a NIR (Surový et al. 2019).

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

Výklad absolutní hodnoty NDVI je spíše informativní, jelikož umožňuje okamžité rozpoznání změny vegetace ve studované oblasti, ať už na polích, či lesích. To dokládá obrázek č. 4 ze studie autorů Chiteculo et al. (2019), ve které byl NDVI použit pro definici míry změny vegetace v Miombo lesech. Výsledky studie dokázaly, že NDVI je spolehlivým parametrem, který lze využít pro modelování změn vegetačního pokryvu.



Obrázek 4: Změny vegetace v letech 2000 - 2017 v lesích Miombo (Chiteculo et al. 2019)

Hodnoty NDVI se pohybují v rozmezí -1 a 1. Záporné hodnoty odpovídají vodě, hodnoty blízké nule sněhu, písčitém či neúrodným oblastem apod. (Antognelli 2018).

Nevýhodou však je vyšší citlivost na vliv jasu a barvu půdy, atmosféru, oblačnost či zastínění korun listů.

3.3.2 Vegetační index zohledňující atmosférické jevy

Vzhledem k omezením NDVI v důsledku atmosférických jevů navrhli autoři Kaufman et al. (1992) Atmospherically Resistant Vegetation Index (ARVI). Tento index je založen na znalosti, že atmosférické jevy do značné míry, ve srovnání s NIR ovlivňují R. Autoři proto upravili hodnotu záření R o rozdíl mezi modrou B a R. Z toho důvodu byla snížena vliv atmosférických jevů na tento VI, který lze takto vyjádřit.

$$ARVI = \frac{(NIR - RED - y * (RED - BLUE))}{(NIR + RED - y * (RED - BLUE))}$$

3.3.3 Vegetační indexy s korekcí půdy

Odlišení vegetace od půdního pozadí původně navrhli autoři Richardson a Wiegand (1977) a to na základě lineárního vztahu hodnot půdní spektrální odrazivosti mezi NIR a R. Autor Huete (1988) pak stanovil soil-adjusted vegetation index (SAVI).

$$SAVI = \frac{(NIR - RED)}{(NIR + L + RED)} (1 + L)$$

Tento VI byl vyvinut za účelem zlepšení citlivosti NDVI na půdní pozadí, pro přesnější odhad vegetačního pokryvu „L“ je konstanta půdní podmíněnosti, kterou lze libovolně nastavit tak, aby lépe korespondovala s měřením vegetace (typicky se používá hodnota 0,5). Tyto hodnoty se v praxi určují dle konkrétních podmínek na stanovišti. Ideální podmínky jsou při plném pokryvu vegetace, ale tento druh podmínek se však vyskytuje zřídka, a to navíc pouze v případech velké hustoty zápoje v lesních porostech.

Z důvodu potřeby nastavovat konstantu L, byl VI SAVI modifikován jako Modified Soil Adjusted Vegetation Index (MSAVI). U tohoto indexu je konstanta L v SAVI nahrazena funkcí L, proto aby mohl být vypočten bez nutnosti stanovení konstanty L. Tímto způsobem MSAVI snižuje vliv pozadí holé půdy, čímž maximalizuje citlivost na vegetaci (Qi et al. 1994). Vyjadřuje se takto.

$$MSAVI = 0,5 * (2 * NIR + 1 - \sqrt{(2 * NIR + 1)^2 - 8 * (NIR - R)}) / 2$$

Na základě implementace MSAVI autoři Richardson a Wiegand (1977) modifikovali tento VI jako MSAVI2. Tento se vyznačuje jednodušším algoritmem a jeho uplatnění lze využít při analýze růstu rostlin, sucha, erozí a odhadu výnosů. Mezi další vegetační indexy s korekcí půdního profilu patří například Optimized Soil-Adjusted Vegetation Index (OSAVI), či Transformed Soil-Adjusted Vegetation Index (TSAVI).

$$OSAVI = \frac{(1 + 0,16)(R_{800} - R_{670})}{(R_{800} + R_{670} + 0,16)}$$

3.3.4 Vegetační indexy odrážející status vegetace

Protože se obsah chlorofylu v listech mění, autoři Moon et al. (1994) vyvinuli Chlorophyll Absorption Ratio Index (CARI), který se používá k monitoringu chlorofylového obsahu v rostlinách, například pro odhad jejich zdravotního stavu.

$$CARI = CAR * \frac{R_{700}}{R_{600}}$$

Později byl tento VI modifikován jako MCARI, který je ještě citlivější na stanovení koncentrace chlorofylu v listech.

$$MCARI = ((R_{700} - R_{670}) - 0,2(R_{700} - R_{550})) * \frac{R_{700}}{R_{670}}$$

Důležitým faktorem v zemědělství je stav zásobenosti vodou a stavem vody v rostlinách. Z toho důvodu, je velmi důležité vyhodnocovat stav vody v plodinách včas a přesně. S rozvojem infračerveného termálního DPZ se rozvinula i možnost detekce změn teplot v korunách rostlinných populacích. Tyto změny souvisejí s rychlostí transpirace rostlin. K sledování stavu vody v plodinách byl stanoven Crop Water Stress Index (CWSI) na základě teploty listového zápoje (Xue & Su 2017).

$$CWSI = \frac{(T_{canopy} - T_{nws})}{(T_{dry} - T_{nws})}$$

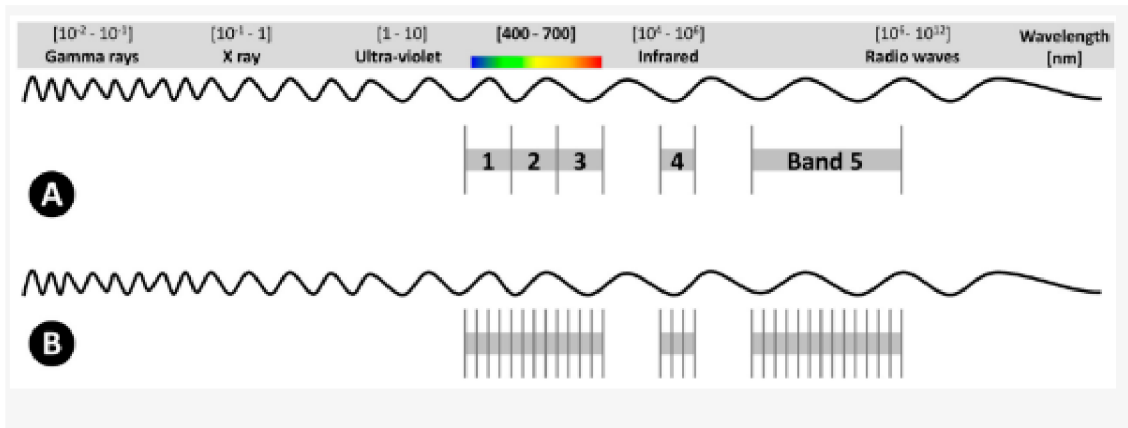
Kde T_{canopy} je teplota plně osluněného zápoje, T_{nws} je teplota plně osluněných listů, když je plodina pozitivně hydratovaná. T_{dry} je teplota plně osluněných listů, kdy je plodina silně zatížená nedostatkem vody. T_{dry} a T_{nws} se používají k normalizaci CWSI (Xue & Su 2017).

Kromě použití infračerveného termálního záření, lze pro včasnou detekci vodního stresu rostlin využít i viditelnou část spektra. K tomu se využívají indexy zaměřené na specifické vlnové délky, kde jsou fotosyntetické pigmenty jako je chlorofyl, ovlivněny vodním stresem. Na tomto principu byl vyvinut stresový index Photochemical Reflectance Index (PRI), který lze vyjádřit takto (Xue & Su 2017).

$$PRI = \frac{(R_{531} - R_{570})}{(R_{531} + R_{570})}$$

3.4 Technologie hyperspektrálního a multispektrálního zobrazování

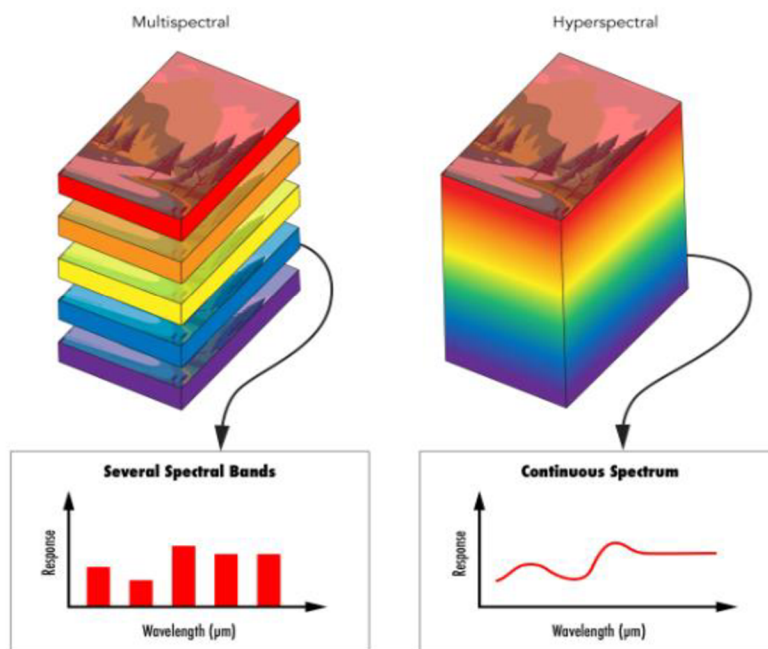
EM záření lze zaznamenat fotograficky či elektronicky. Hyperspektrální a multispektrální zobrazování jsou technologie, které v posledních dvou desetiletích nabývají na významu a užitečnosti. Obě technologie mají výhody oproti běžným zobrazovacím metodám, které využívají světlo z viditelného spektra – RGB (400-700 nm). Hlavním rozdílem mezi nimi, je počet a šířka pásem. Zatímco multispektrální snímky se pohybují od 5 do 12 pásem, které jsou reprezentovány pixely, hyperspektrální snímky sestávají z mnohem vyššího počtu pásem, kdy jich jsou obvykle stovky s šířkou 5-20 nm. Obrázek č. 5 znázorňuje rozdíly mezi multispektrálním (A) a hyperspektrálním zobrazením (B) (Adão et al. 2017).



Obrázek 5: Multi a hyperspektrální zobrazení (Adão et al. 2017)

Dalším rozdílem je kontinuita dat uložených v doméně vlnových délek. Zatímco hyperspektrální technika zobrazování propojuje velké množství úzkých pásem, obsahují tyto snímky mnohem větší množství spektrálních dat. Multispektrální technika získává snímky v omezeném počtu širokopásmových vlnových délek. Data jsou obvykle rozložena na několik spektrálních pásem, která se mohou překrývat. Údaje v každém pásmu jsou zpravidla zprůměrována do jedné hodnoty, což vede ke ztrátě informace o spektrální kontinuitě. Z každého pixelu hyperspektrálního snímku tak lze získat spektrální křivku, kdežto multispektrální snímky tvoří sadu izolovaných datových bodů pro každý pixel, díky odděleným vlnovým pásmům uloženým v datové sadě. V porovnání s hyperspektrálními snímky by se dalo tvrdit, že jsou velmi hrubé (Qin et al. 2013) (viz obr. č. 6).

MULTISPECTRAL/ HYPERSPETRAL COMPARISON



Obrázek 6: Porovnání vrstev obrazů MSP a HPS zobrazování. (Edmund Optics 2023)

Zjednodušeně řečeno, hyperspektrální či multispektrální zobrazování nám umožňuje pozorovat svět v mnohem širším EM spektru.

Je třeba dodat, že k zaznamenání hyperspektrálních dat se využívá v zásadě dvou typů zařízení, a to senzorů a kamer.

3.4.1 Hyperspektrální senzor

Je v zásadě implementován jako jeden či více spektrometrů, díky kterým lze získat jednotlivé hodnoty spektrálních informací z měřené plochy pro každé měřené pásmo. Tímto způsobem může hyperspektrální senzor poskytnout velmi podrobné informace o spektrálním složení povrchových materiálů a případných změnách v jejich vlastnostech. Příklad takového senzoru lze spatřit v kapitole 4.1 (Yue et al. 2018).

3.4.2 Hyperspektrální kamera

Je zařízení, které využívá optické soustavy, čoček a senzorů ke snímání obrazů scény v různých vlnových délkách. Každý pixel obrazu reprezentuje informace o spektrální odezvě daného místa scény. Následně jsou tyto informace zpracovány tak, aby vytvořili takzvanou hyperspektrální krychli (Yue et al. 2018).

Základní rozdíl mezi nimi spočívá v tom, jakým způsobem získávají hyperspektrální data. Z důvodu, že pro účely této práce byl sběr dat proveden pomocí hyperspektrálního senzoru se následující kapitola zaměřuje na trendy zpracování dat získaných pomocí této technologie.

3.5 Zpracování hyperspektrálních dat (senzory)

K současné době je to už 50 let výzkumu na poli hyperspektrálního DPZ, cíleného na monitorování, modelování a mapování vegetace a zemědělských plodin pomocí pozemních, mobilních, leteckých, bezpilotních a kosmických platform nesoucí hyperspektrální kamery či senzory. Teprve však v posledních letech začali lidé získávat hyperspektrální snímky ve vysokém prostorovém a spektrálním rozlišení, což znamená i objemné datové soubory (Thenkabail et al. 2014). Z důvodu vysokého spektrálního rozlišení byly vytvořeny nové, či modifikovány původní vegetační indexy, které lze obecně charakterizovat jako úzkopásmové. Rozsah hodnot odrazivosti použitých v rovnicích těchto indexů je zpřesněn natolik, aby byly využity i ty nejjemnější spektrální detaily hyperspektrálních dat (Thorp et al. 2004). Objemné množství dat tvořených spektrálními pásmy zapříčiňuje i různé problémy spojené s jejich zpracováním, které musejí být řešeny v rámci specifických matematicko-statistických metod. Efektivní redukce množství příslušných dat či výběr relevantních pásem je tak stěžejním úkolem pro analýzu hyperspektrálních snímků (Richards 2022). Pro toto předzpracování dat, určené k selekci nejrelevantnějších vlnových délek pro jejich následnou klasifikaci se používá celá řada přístupů. Jedním z nejrozšířenějších je analýza hlavních prvků (Principal component analysis – PCA)

3.5.1 Selekcce pomocí PCA

Vychází ze skutečnosti, že sousední pásma hyperspektrálních snímků jsou vysoce korelována a o objektu sdělují téměř shodné informace. Analýza se používá k transformaci původních dat tak, aby se odstranila korelace mezi pásmy. Při tomto procesu se identifikuje optimální lineární kombinace původních pásem, která zohledňuje variabilitu hodnot pixelů v obraze. Využívání statistických vlastností hyperspektrálních pásem ke zkoumání závislosti či korelace je založeno na matematickém principu rozkladu vlastních čísel kovariační matice analyzovaných pásem hyperspektrálního obrazu (Rodarmel & Shan 2002). Primárním cílem je zjednodušení interpretace skupin vzájemně

korelovaných znaků a vytvoření nových – tedy hlavních prvků. Primární charakteristikou těchto hlavních prvků je míra variability (rozptyl), jenž udává významnost řazení prvků a to sestupně (Sebera 2012). Tím je umožněna snadnější interpretace dat a umožňuje to uživatelům lépe porozumět vztahům mezi různými proměnnými a trendům v datech.

Následujícím krokem po selekci dat, přichází na řadu jejich klasifikace. Klasifikace dat byla v metodické části této diplomové práce provedena pomocí lineární diskriminační analýzy (linear discriminant analysis – LDA), která je v současné době velmi rozšířená (Rodarmel & Shan 2002).

3.5.2 Klasifikace pomocí LDA

Statistická technika, která se používá k redukci dimenzionality dat a klasifikaci datových souborů z důvodu své schopnosti extrahovat diskriminační informace z datové sady. Cílem je nalézt lineární transformaci datové sady tak, aby byla zachována co největší míra rozdílnosti mezi třídami dat a zároveň co nejmenší variabilita v rámci jednotlivých tříd. LDA hledá lineární kombinace proměnných, které nejlépe rozlišují různé třídy dat a umožňují vytvoření projekce do nového souřadnicového systému s nižší dimenzionalitou. Tato projekce může být použita pro klasifikaci nových datových vzorků do jedné z tříd (Rodarmel & Shan 2002).

Trend poslední doby sleduje stále častější využívání stále dokonalejších hyperspektrálních kamer či senzorů. To sebou však přináší pokročilejší a náročnější metody zpracování, klasifikace a segmentace dat. Následující kapitola přináší stručný přehled o pokročilých a moderních metodách zpracování dat.

3.6 Pokročilé přístupy zpracování hyperspektrálních dat

K tomu jak data získaných z hyperspektrálních kamer/senzorů zpracovávat a klasifikovat, se používá různých metod, založených na přístupech strojového učení (ML – Machine Learning) jako support-vector machines (SVM) (Tarabalka et al. 2010) nebo random forest (RF) (Guimarães et al. 2020), ale i řada dalších na základě statistických metod (Patočka 2016) jako zobecněný lineární model (GLM) (Kučelka et al. 2020), či metoda neuronových sítí (Neural network) (O’Shea & Nash 2015).

Klasifikace

SVM

Algoritmus SVM je lineární binární klasifikátor, který přiřazuje danému vzorku jednu třídu z možných dvou. Instancí vzorku je individuální pixel odvozený z hyperspektrálního odrazu (Mountrakis et al. 2011). Stěžejním principem, který zvýhodňuje SVM, je proces učení, který vede k minimalizaci rizik strukturalizace. Dle tohoto schématu SVM minimalizují chyby klasifikace na neznámých vzorcích (Mantero et al. 2005)

Neuronová síť

Je řada algoritmů, které detekují základní vztahy v datovém souboru skrze proces podobný procesu lidského mozku. Tento koncept má kořeny v umělé inteligenci. Primární jednotkou sítě je neuron. Ve své podstatě je to matematická funkce, která shromažďuje a třídí informace dle předem definované architektury. Propojením neuronů vzniká několikavrstvá síť propojených uzlů. Stěžejní vrstvy jsou dvě, a to vstupní, potřebná pro zadání dat a výstupní, která provádí klasifikaci a tvoří výsledek. Mezi nimi se vyskytují „skryté“ vrstvy. Z důvodu, že dnešní snímky mají vysoké rozlišení, je nemožné na kódovat pro každý neuron jeden pixel, proto se v případě tvorby této sítě používá konvoluční neuronová síť. Touto metodou dojde k sjednocení a přepočítání hodnot několika okolních pixelů dohromady, dle předem daného filtru. Takovéto filtrování se nazývá Sobel operator a používá se pro detekování hran objektů (O’Shea & Nash 2015).


I když neuronové sítě mohou být trénovány a použity k analýze dat bez segmentace, může být tento proces stále užitečný pro zlepšení přesnosti a interpretaci výsledků. Proto je vhodné, když jsou hyperspektrální data podrobena i procesu segmentace, ať je cíl sběru dat jakýkoliv, například rozlišení polních plodin od plevelů.

Segmentace


Procesem segmentace je rozdělení snímku na několik částí, dle podobnosti vizuálních charakteristik pixelů. Cílem je zmenšení, či zjednodušení vlastností obrázků pro jejich další analýzu. Homogenita pixelů pak umožňuje definovat, zdali se jedná například o travnaté porosty, lesy, vodní plochy či polní plodiny apod. Je to jeden z stěžejních úkonů pro rozpoznání zkoumaných vlastností snímků (Kornilov & Safonov 2018). Běžně používanou metodou pro segmentaci hyperspektrálních snímků je takzvaná segmentace povodí (WS - Watershed Segmentation) (Noyel et al. 2007).

WS

Dle (Noyel et al. 2007) je WS výborný matematicko-morfologický algoritmus pro segmentaci obrazu. Název watershed metaforicky odkazuje na odtokové rozvodí, které odděluje sousední povodí. Princip dle (Tarabalka et al. 2010) spočívá v tom, že WS považuje dvourozměrný obraz v každém jednom konkrétním pásmu za topografický reliéf, kdy hodnota jasu „h“ každého pixelu znamená jeho nadmořskou výšku. Čáry rozvodí rozdělují obraz na jednotlivá povodí, takže každé povodí je spojeno s jedním minimem v obraze (viz obr. č. 7.). Segmentace je obvykle aplikována na gradientní funkci obrazu. Gradient definuje přechody mezi oblastmi tak, že maxima (hřebeny) jsou na hranicích mezi objekty a minima v homogenních oblastech. Tento algoritmus pak segmentuje obraz dle hřebenových přechodů, pro lepší představu (viz obr. č. 8).




Obrázek 7: Topografická reprezentace jedno pásmového obrazu (Tarabalka et al. 2010).



Obrázek 8: Příklad WS v 1D (Tarabalka et al. 2010)


Názornou ukázkou celého procesu segmentace pomocí WS pak (viz obr. č. 9). V první fázi máme klasický snímek rostliny, následně je tento snímek zbaven pozadí, kdy zůstane

jen samotná rostlina, poté je na rostlině detekováno ohraničení listů. Následným výpočtem směru délky odtoku jsou detekována lokální maxima (těžiště) listů. Výstupem je pak konečná segmentace, kdy linie ohraničují listy rostliny. Problém v tomto algoritmu vidí (Liu et al. 2015), že některé nekompaktní listy mohou být rozděleny do několika dalších segmentů považovaných tímto algoritmem za další listy.



Obrázek 9: Proces segmentace WS (Wang & Xu 2018)

Na obrázku č. 10. lze spatřit proces klasifikace napadení listové plochy patogenem, detekci plochy a její následnou segmentaci, díky které může být například stanoven procentuální podíl napadení (Boulent et al. 2019).



Obrázek 10: Klasifikace, detekce patogenu, segmentace (Boulent et al. 2019)

Moderní trend hyperspektrálního zobrazování představuje, oproti konvenčnímu DPZ, významné zlepšení sběru a kvality dat, což vede k tvorbě specifických zemědělských charakteristik jako jsou například biochemické veličiny (Clark & Roberts 2012),

klasifikaci druhů plodin (Thenkabail et al. 2013), management a stresové faktory, jako například nedostatek dusíku či vody (Delalieux et al. 2009).

Používá se k sběru dat s vysokým prostorovým a časovým rozlišením. Tento proces zpracování dat obvykle vyžaduje značné množství času a poměrně komplikované postupy pro obrazovou analýzu.

3.7 Příklady aplikace DPZ v zemědělství

Studie autorů Wójtowicz et al. (2016) stručně shrnuje možné aplikace DPZ v zemědělství na všech úrovních letových hladin a jejich příslušných platform. Nižší popsané příklady jsou zmiňovány jako nejvýznamnější nejen pro zemědělce, ale i pro vládní agentury, obchodníky s komoditami a výrobce. Čím dříve jsou tyto informace k dispozici, tím je například vyšší schopnost udržet vysokou míru stability ve společnosti, která je spojená s finanční ale i potravinovou bezpečností.

Předpověď výnosů

Na tuto oblast se například zaměřuje studie autorů Galvão et al. (2009). Autoři zkoumali možnost využití hyperspektrálních snímků družice Hyperion k odhadu výnosu sóji. Bylo dosaženo vysoké korelace mezi vegetačními indexy NDWI ($r=0,74$), NDVI ($r=0,6$) a hmotností sklizené produkce. Je třeba zmínit, že vegetační indexy byly stanoveny 62. až 81. den po výsadbě. Přičemž výsadba proběhla v době 11. až 17. listopadu a sklizeň od 24. března do 9. dubna.

Nutriční požadavky rostlin

Autoři studie Bagheri et al. (2013) například využili data satelitního snímkování pro stanovení míry používání dusíkatých hnojiv na rozloze 23 ha. Bylo uvedeno, že z dat pořízených satelitním snímkováním, lze stanovit množství dusíkatých látek v průběhu celé vegetace rostlin. Naproti tomu, další studie autorů Stroppiana et al. (2009) měla za cíl pomocí ručně neseného spektro-radiometru kvantifikovat koncentraci dusíku v rýži. Bylo zjištěno, že tato metoda je vhodná pro zjišťování časových a prostorových změn ve využití dusíku rýží.

Detekce poškození chorobami a škůdci

Dle Wójtowicz et al. (2016) se charakteristika spektrální odrazivosti u zdravých a napadených rostlin výrazně liší. Tuto tezi potvrdili autoři Genc et al. (2008). S využitím ručního radiometru bylo spolehlivě vyhodnoceno poškození pšenice hmyzím škůdcem

(*Eurygaster integriceps*) pomocí vegetačních indexů založených na normalizovaném diferenčním vegetačním indexu (NDVI). Bylo zjištěno, že pomocí DPZ lze detekovat nejen rozdílná stádia poškození pšenice škůdce, ale také stanovit přibližnou hustotu tohoto škůdce v poškozené oblasti.

Další ze studií zabírající se touto problematikou je (Kumar et al. 2013). Autoři této studie porovnávali spektrální odrazivost od zdravých a zamořených zápojů hořčice mšicemi pomocí polní spektroskopie. Výsledky ukázaly, že spektrální indexy NDVI, RVI, AI, SIPI významně korelovaly s napadením mšic a tyto indexy lze použít pro identifikaci napadení škůdci.

Posouzení potřeby vody pro rostliny

Ve studii autorů Taghvaeian et al. (2013) bylo k tomuto účelu využito termální infračervené spektrum. To z toho důvodu, že teplota rostlinného zápoje závisí na stupni tepelného stresu a zásobení vodou. Tudíž je tak možné určit aktuální stav zásobení rostlin vodou pomocí TIR. Rostliny v závislosti dostupnosti vody trpící deficitem vykazují více dlouhovlnného infračerveného záření. Pro srovnání tepelných dat byl použit index vodního stresu plodin (CWSI), jenž byl získán normalizací teploty korun rostlin a teplotami vzduchu.

Ve studii autorů Mogensen et al. (1996) byl prokázán silný vztah mezi indexem relativní odrazivosti (Relative reflectivity index – RRI) a obsahem vody v půdě. Tento index byl vypočten jako poměr indexu odrazivosti uschlých plodin k indexu plně zavlažované referenční plodiny. Díky tomu je tak možné například stanovit optimální datum zahájení zavlažování.

3.8 Rozlišování plevelů plodin na základě spektrálních vlastností

Vzhledem k tomu, že odrazivost plodin, plevelů a půdy se v RGB a infračerveném spektru vlnových délek liší, naskytá se potenciál pro použití měření odrazu na různých vlnových délkách k jejich rozlišení.

Na tuto problematiku se zaměřuje studie autorů Vrindts et al. (2002). Do měření byla zahrnuta cukrová řepa (*Beta vulgaris*) a kukuřice (*Zea mays*). Cíle výzkumu bylo definovat potenciál reflexních měření a spektrální analýzy pro detekci plevelů na základě spektrální odrazivosti zápoje. Za účelem prvotního definování důležitých pásem vlnových délek signifikantních pro rozlišení, byla první část výzkumu provedena v laboratorních podmínkách. Nástrojem byl Optical Spectral Analyser (OSA) v rozsahu

400 až 2000 nm. Do této analýzy bylo zahrnuto sedm druhů plevelů. Následně, po ukončení laboratorních testů s kontrolovanými světelnými podmínkami, byla testována klasifikace v polních podmínkách spektrografem v rozsahu 480 až 820 nm a CCD kamerou. Současně bylo zahrnuto do klasifikace jedenáct druhů plevelů. Výsledky testů v laboratorních podmínkách ukázaly, že při vzájemném rozlišování kukuřice a plevele byla celková chyba klasifikace menší než 1 %, a pro kombinaci cukrové řepy a plevele byla chyba klasifikace menší než 2 %, při použití poměrů tří vlnových délek (z důvodů změn intenzity záření) a diskriminačních modelů. Takto nízká chybovost naznačila potenciál využití měření odrazivosti v polních podmínkách. V polním měření hrály však světelné podmínky velmi důležitou roli pro klasifikaci. Z důvodu podobnosti světelných podmínek při sběru dat bylo v případě cukrové řepy a plevele dosaženo 90 % přesnosti klasifikace. V případě kukuřice bylo z důvodu odlišnosti světelných podmínek v době sběru dat klasifikováno pouze 15 % rostlin správně. Plevel však byl z 97 % klasifikován správně. Proto autoři uvádějí, že lze z 90 % správně identifikovat plevel v polních porostech, když jsou diskriminační modely specifické pro převládající světelné podmínky.

Autoři Rodarmel a Shan (2002) se zaměřují na klasifikaci plevelné rýže (*Oryza sativa f. spontanea*) a trávu (*Echinochloa crusgalli*) v rýžovém poli. Celkovým souborem dat bylo celkem 287 vzorků rostlinných listů, které byly naskenovány hyprespektrálním senzorem ve spektrálním rozsahu 380–1080 nm. Po sběru dat bylo provedeno předzpracování dat pomocí LDA. Následně byly využity klasifikátory jako RF a SVM a SPA k rozlišení rostlinných druhů. Výsledky byly vypočteny a zprůměrovány dle reflektance všech vzorků z každé třídy, tedy rýže, plevelné rýže a trávy. Za využití těchto pokročilých postupů bylo vybráno šest spektrálních bodů o vlnových délkách 415, 561, 687, 705, 735, 1007 nm. Tyto vlnové délky se ukázaly jako nejlepší pro automatickou klasifikaci rozlišování plavených druhů rýže. V tomto případě bylo dosaženo 92 % celkové přesnosti klasifikace. V případě rozeznání rýže od trávy bylo dosaženo 100 %.

Detekce plevele v řádcích plodin v reálném čase stále zůstává hlavní výzvou pro komercializaci univerzálního robotického systému kontroly plevele pro řádkové rostliny, na tuto problematiku se zaměřuje studie autorů Slaughter et al. (2008). Cílem výzkumu bylo zjistit proveditelnost použití spektroskopie odrazu v VIS a NIR v oblasti 384 až 810 nm, pomocí autonomního vozidla na kolečkách, pro rozlišení listů listového salátu (*L.*

sativa) od plevelů (*Capsella bursa-pastori* L., *Senecio vulgaris*) a (*Sonchus spp.* L) pěstovaných v podmínkách přímého výsevu v polovině srpna 2004., kdy sběr dat byl proveden o několik týdnů později ve fázi růstu druhého pravého listu. Proces sběru dat zahrnoval vytvoření stabilních světelných podmínek nezávislých na kolísavosti přirozeného osvětlení uvnitř vozidla. K tomu byl použit řízený zdroj světla. Hyperspektrálních snímky byly pořízeny pomocí kamery s vlastní regulací teploty, vybavené transmisní mřížkou, objektivem a modrým filtrem, která byla také naistalována uvnitř vozidla. Při sběru dat bylo autonomní vozidlo poháněno konstantní rychlostí 25m/s. Tímto způsobem bylo analyzováno celkem 7114 hyperspektrálních snímků plodin a plevelných rostlin. Pro provedení správné klasifikace byly použity dva vegetační indexy jako NDVI a RVI a vícerozměrné klasifikační modely. Pro vícerozměrné klasifikátory byly vyhodnoceny dvě techniky výběru vlnových pásem. Jako první technika výběru konkrétních vlnových pásem pro klasifikaci posloužila diskriminační analýza. Druhou technikou byl zkrácený spektrofotometrický model s 25 rovnoměrně rozmístěnými pásmy. Byl vytvořen vlastní makro program, který provedl interní křížové validace klasifikátoru pomocí procedury Discrim. Výsledky dokázaly, že bylo dosaženo celkové průměrné přesnosti klasifikace z 90,3%, přičemž průměrná klasifikační přesnost pro plevele byla 87,8%. Tato studie prokázala, že speciálně uzpůsobené autonomní vozidlo jedoucí konstantní rychlostí, může být použito pro sběr spektrálních charakteristik rostlin ve VIS a NIR spektru, kdy takto získaná data odrazivosti listů jsou vhodná k dalšímu vývoji automatického klasifikátoru specifického pro danou lokalitu a rozlišování rostlin od plevelů. Byla tak nastíněna možnost detekce plevele v řádcích plodin v reálném čase.

4 Materiál a metody

Pomocí přenosného spektrometru FieldSpec 4 (Malvern Panalytical 2022) (viz obr. č. 11) byla analyzována spektrální odrazivost vojtěšky (*Medicago sativa*) ve stádiu obrůstání porostu vojtěšky po seči při výšce rostlin 15 – 30 cm. a plevelů jako pampeliška (*Taraxacum officinale*) a šťovík tupolistý (*Rumex obtusifolius*) ve fázi obrůstání přízemní růžice s počtem listů obvykle 4-8. Následně byla identifikována spektrální pásma, která jsou charakteristická pro jednotlivé rostlinné druhy a jejich růstové fáze. Poté byly vytvořeny algoritmy vhodné pro rozpoznání jednotlivých rostlinných druhů. Spektrální měření byla provedena Ing. Pavlem Hamouzem, Ph.D. v pěti porostech vojtěšky v letech 2019 až 2022.

4.1 FiledSpec 4 Spektrometr



Obrázek 11: FieldSpec 4 (foto autor)

Dle Malvern Panalytical (2022) je FieldSpec 4 od společnosti ASD špičkovým nástrojem pro terénní spektroskopii a měření odrazivosti, absorbance, zářivosti a spektra ozáření. Navržen je tak, aby splňoval požadavky nové generace hyperspektrálního zobrazování a výzvy kterým výzkumníci čelí při provádění spektrálních měření v terénu při různých světelných podmínkách. Při provádění samotného měření drží operátor

v rukou pouze lehké příslušenství a společně s pohodlným ukládáním zařízení do ergonomického batohu, je dosažen maximální komfort ručního sběru spektrálních dat.

Detekční schopnost optické sondy se pohybuje od 350 nm do 2500 nm, což umožňuje rovnoměrný sběr dat v celém spektru VIS/NIR/SWIR. Optická konstrukce sondy je určena pro měření odrazivosti jak v laboratoři, tak v terénu a minimalizuje chyby měření, váží 1,5 kg a má štíhlou konstrukci a snadno uchopitelnou rukojeť. Mezi další výhody se řadí rychlost měření, kvalita dat při sběru v neoptimálních podmínkách, eliminace takzvaných „mrtvých pixelů“, nutnost vyplňovat mezery interpolací dat, možnost bezdrátového přenosu na velké vzdálenosti, odolná konstrukce, která eliminuje rizika poškození přístroje či optických vláken a široké portfolio příslušenství.

Díky tomu tento přístroj nachází uplatnění, kromě PZ i v řadě dalších odvětvích jako například kalibrace senzorů a analýza snímků, monitoring stavu životního prostředí, atmosférický výzkum, analýza biomasy, výzkum sněhu a ledu, nedestruktivně zkoumat umělecká díla, měření složení materiálů ale dokonce i v armádě. Přehled specifikací lze spatřit v tabulce č. 2.

Tabulka 2: Specifikace produktu FieldSpec 4 (Malvern Panalytical 2022)

Parametr	Hodnota
Rozsah vlnových délek (nm)	350–2500
Rozlišení VNIR 700 nm	3
Rozlišení SWIR 1400 a 2100 nm	8
Šířka pásma VNIR nm	1,4
Šířka pásma SWIR nm	1,1
Doba skenu (ms)	100
Přesnost vlnové délky (nm)	+/- 1
Hmotnost (kg)	5,44
Kanály	2151
Teplota uskladnění (°C)	-15 až 45
Rozsah provozních teplot (°C)	0 až 40

4.2 Sběr a zpracování dat

Za účelem nalezení spektrálních rozdílů bylo uskutečněno měření spektrální odrazivosti vojtěšky a plevelných druhů. Sběr vzorků rostlin byl proveden destruktivním způsobem. Měření probíhalo bez využití slunečního záření. Byla použita kontaktní měřicí sonda s integrovaným zdrojem světla. Sonda snímá odrazivost z kruhové plochy o průměru 19 mm. Tato sonda byla přímo položena na každý list studované rostliny, pod

list byl položen reflexní terč. Poté byl ze sondy vystřelen paprsek světla, který prošel listem a od reflexního terče se odrazil zpět do sondy. Takto bylo zaznamenáno 1502 listů vojtěšky, 1731 listů šťovíků a 1225 listů pampelišky (viz tab. č. 3).

4.2.1 Zpracování dat Microsoft Excel

Příprava dat pro analýzy byla provedena v prostředí Microsoft Excel. Nejprve bylo třeba rozdělit datové soubory dle rostlinných druhů. Následně bylo provedeno jejich seřazení, dle prvního sloupce, který reprezentoval vlnové délky od 350. do 2500 nm. Podle toho sloupce byly seřazeny jednotlivé záznamy odrazivosti listových ploch. Dalším krokem bylo třeba opravit křivky jednotlivých měření pomocí parabolické korekce (Hueni & Bialek 2017) a to ve vlnových délkách 725 – 1000 nm a 1800 – 1950 nm dle vzorců:

$$C_{725:1000} = \frac{(X_{725:1000} - 725)^2 * (L_{1001} - L_{1000})}{L_{1000} * (1000 - 725)^2} + 1$$

$$C_{725:1000} = \frac{(X_{1800:1950} - 1950)^2 * (L_{1800} - L_{1801})}{L_{1801} * (1800 - 1950)^2} + 1$$

Použití této korekce se dle výše zmíněné studie doporučuje pro korekci napojení jednotlivých částí spektrální křivky, kde jsou chyby způsobeny zejména rozdílným vlivem teploty na jednotlivé senzory spektrometru. Obvykle se jedná o chyby v rozsahu několika procent. Naše data vykazovala přesně takovýto rozsah chyb.

Průběh spektrálních křivek pro jednotlivá měření byl vyneseno do grafu a na základě vizuálního zhodnocení byla provedena eliminace těch křivek, které vykazovaly zřetelně zcela odlišný průběh způsobený chybami při měření. Takto eliminovaných vzorků bylo u vojtěšky celkem 30, u šťovíků 37 a u pampelišky 25.

V případě pampelišky zůstalo po odstranění odlehlých měření 1200 spektrálních křivek. V případě vojtěšky a šťovíku bylo tak náhodně vybráno vždy 1200 vzorků, aby počty měření v jednotlivých kategoriích byly shodné (viz tab. č. 3).

Tabulka 3: Počty provedených spektrálních měření pro jednotlivé druhy rostlin

Vědecký název druhu	Počet rostlin			
	Celkem	Použité	Použité trénovací	Použité validační
Medicago sativa	1502	1200	800	400
Taraxacum officinale	1225	1200	800	400
Rumex obtusifolius	1731	1200	800	400

Hodnoty odrazivosti v jednotlivých spektrálních pásmech byly vypočteny jako průměr hodnot měření zastoupených v příslušném rozsahu vlnových délek od 350. do 2500 nm. Poté byly tyto hodnoty vyneseny do grafu (viz graf č. 4). Na základě zobrazených spektrálních křivek, které byly opticky zhodnoceny, byla vybrána spektrální pásma, která vykazovala rozdíly v odrazivosti a mohla by potenciálně přispět k diskriminaci mezi jednotlivými rostlinnými druhy (viz tab. č. 4).

Finálním krokem bylo rozdělení dat na dva soubory „trénovací“ a „validační“ podle algoritmu 2x validační a 1x trénovací. Soubor trénovacích dat obsahoval 2400 záznamů a soubor validačních dat 1200 záznamů. Zde je důležité zmínit, že data v obou souborech byly unikátní. Po provedení tohoto zpracování dat byly výsledné soubory převedeny do formátu csv. a dále zpracovány v prostředí R.

4.2.2 Zpracování dat v prostředí Rstudio

Pro potvrzení vědecké hypotézy, která předpokládala, že mezi rostlinnými druhy existují rozdíly ve spektrálních vlastnostech, které umožní jejich vzájemné odlišení byl použit programovací jazyk R, který je používán v prostředí zvaném Rstudio.

Pomocí statistické analýzy hlavních komponent (PCA) byla nejprve pro trénovací sadu dat stanovena významnost jednotlivých komponent podle klesajícího rozptylu (od největšího po nejmenší) a zároveň stanovena i míra korelace mezi hlavními komponentami a hodnotami odrazivosti pro jednotlivá spektrální pásma (původní proměnné). Díky tomu tak mohlo být posouzeno, které proměnné nejvíce přispívají k variabilitě dat.

K samotné klasifikaci dat byla použita lineární diskriminační analýza (LDA) na základě vybraných spektrálních pásem identifikovaných pomocí PCA. Pomocí této analýzy došlo k určení a rozdělení těch znaků, které se podílí na klasifikaci více a které méně.

Aplikací lineární diskriminační analýzy (LDA) byly nejprve vypočteny průměrné hodnoty proměnných (spektrálních pásem) pro jednotlivé rostlinné druhy. Dále byly vypočteny koeficienty lineárních kombinací původních proměnných, které jsou nejvhodnější pro diskriminaci mezi skupinami. Dalším krokem pro samotnou klasifikaci rostlinných druhů bylo třeba nejprve natrénovat model LDA na základě proměnných v trénovacích datech. Správnost klasifikace natrénovaného modelu byla následně ověřena pomocí chybové matice. K ověření kvality klasifikačního modelu LDA byl shodný klasifikační model aplikován i na validační data, která pro tvorbu algoritmu nebyla využita a opět byla správnost ověřena pomocí chybové matice.


Výsledky klasifikace byly vyjádřeny celkovou přesností klasifikace a chybovou maticí. Statistické analýzy provedené v prostředí R byly využity s balíčky MASS, caret, car, ggbiplot a rattle.

Rstudio

Programovací jazyk R byl poprvé napsán v roce 1992 Novozélandčany Rossem Ihakaou a Robertem Gentlemanem. Dnes je spravován lidmi z celého světa, kteří si říkají “R Core team“ a díky tomu je rozvoj R stále progresivní. R byl stvořen jako open – source systém a je jedním z nejkompexnějších statistických softwarů, jenž obsahuje všechny základní typy pro moderní statistické analýzy včetně funkcí pro grafickou prezentaci dat, které jsou stále průběžně doplňovány a aktualizovány díky nepřetržité práci týmu R-Core (Pékar & Brabec 2016). Samotné Rstudio je platforma, jenž podporuje funkce jazyka R (de Vries & Meys 2015).

5 Výsledky

Z grafu č. 4 lze odečíst vlnová pásma vykazující největší rozdíly v průměrné odrazivosti pro rostlinné druhy. V tabulce č. 4 jsou pak tyto hodnoty vypsány.



Graf 4: Porovnání průměrných hodnot odrazivosti pro jednotlivé rostlinné druhy

Tabulka 4: Spektrální pásma vybraná pro diskriminaci rostlinných druhů na základě vizuálního hodnocení spektrálních křivek

Spektrální pásmo	Rozsah vlnových pásem (nm)
1	430-450
2	540-560
3	720-730
4	765-785
5	7060-1080
6	1440-1460
7	1920-1940

5.1 PCA

Výsledkem této analýzy jsou nové proměnné (hlavní komponenty), které reprezentují lineární kombinace původních proměnných (např. PC1=430-450) a vysvětlují největší část variability v datech (Abdi & Williams 2010). Základní statistické informace o hlavních komponentách jsou shrnuty v tabulce č. 5.

Směrodatná odchylka udává měřítko variability dat v každé hlavní komponentě. Vyšší hodnota znamená, že v této dané komponentě je vyšší rozdílnost mezi datovými body.

Podíl variace udává, jak velkou část variability v datech vysvětlí každá hlavní komponenta. Například PC1 vysvětluje 45,23 % variability v datech.

Kumulativní podíl variance udává součet příspěvku jednotlivých os k celkové varianci. Z výsledků je patrné, že k vyčerpání alespoň 97 % variability je třeba prvních čtyř hlavních komponent (kumulativní podíl 97,22 %). Ostatní hlavní komponenty přispívají k popisu variability zanedbatelnou měrou.

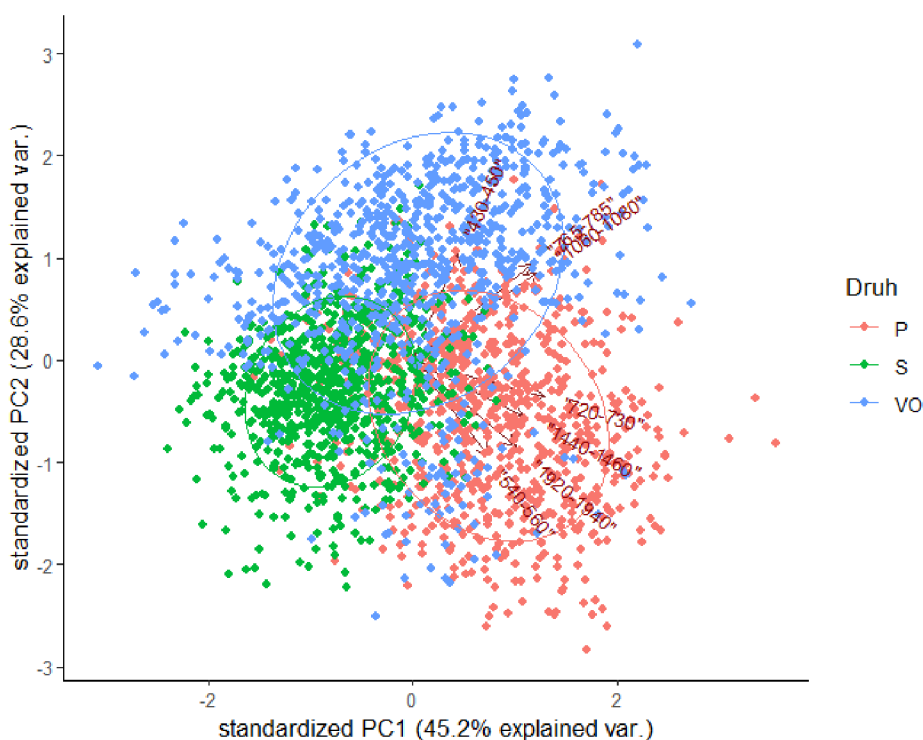
Vzhledem k tomu, že komponenta PC1 má největší směrodatnou odchylku a zároveň podíl variace, znamená to, že má největší vliv na celkovou variabilitu v datech. Sama o sobě dokonce vysvětluje 45,23 % variability dat.

Tabulka 5: Významnost hlavních komponent

Komponenty	PC1	PC2	PC3	PC4	PC5	PC6	PC7
Směrodatná odchylka	1,77937	1,41378	0,99499	0,80663	0,39231	0,17768	0,09438
Podíl variace	0,45231	0,28554	0,14143	0,09295	0,02199	0,00451	0,00127
Kumulativní podíl variace	0,45231	0,73785	0,87928	0,97223	0,99422	0,99873	1

Grafem č. 5 je „biplot.“ Ten znázorňuje pozici každého měření vzhledem k PC1 a PC2, jako bod a také příspěvek jednotlivých spektrálních pásem k PC1 a PC2, které se zobrazují jako šipky. Tyto šipky nesou informace o zatíženích, či jinak vektory proměnných. Délka těchto šipek udává, jak dobře jsou proměnné reprezentovány grafem. V případě dokonalé shody budou mít stejnou délku. Po detailním přezkoumání těchto šipek, lze pozorovat, že všechny vykazují téměř shodné délky. Úhel svíraný mezi libovolnými dvěma šipkami pak představuje korelaci mezi těmito proměnnými. Čím je úhel menší, tím proměnné vykazují vyšší vzájemnou pozitivní korelaci (Agron 2020). Finální separace jednotlivých rostlinných druhů sice patrná je, nicméně lze pozorovat významné vzájemné překryvy pro všechny tři skupiny. Tím pádem, spolu s velkým množstvím dat, tento graf trpí jistou mírou nepřehlednosti. Z toho důvodu byla vytvořena tabulka č. 6, která vyjadřuje hodnoty hlavních komponent pro každou z původních proměnných (vlnových délkách). Každé číslo v tabulce č. 6 reprezentuje hodnotu, kterou dané vlnové pásmo přispívá do každé z hlavních komponent. Například hodnoty vlnových délek 430–450 nm v prvním řádku přispívají k PC1 16,4 %, k PC2 47,8 %, atd. Hodnoty v tabulce tak ukazují, do jaké míry jsou vlnové délky propojeny s hlavními komponentami. Například pokud vlnové délky 430–450 nm a 540 – 560 nm mají vysoké pozitivní hodnoty pro PC4, mohlo by to znamenat, že tyto dvě vlnové délky jsou

významně propojeny s nějakým fenoménem, který lze vysvětlit pomocí této hlavní komponenty (Gabriel 1971). Záporným znaménkem u některých hodnot není třeba se znepokojovat, a to z důvodu, že hlavní komponenty jsou lineárními kombinacemi původních proměnných (Abdi & Williams 2010). Z grafu č. 5 je patrné, že například hodnoty obou komponent u druhu „šťovík“ jsou převážně záporné. Hodnoty vektorů proměnných lze spatřit v tabulce č. 6.



Graf 5: Biplot s pozicemi druhů vzhledem k PC1 a PC2 (P-pampeliška, S-Šťovík, VO-vojtěška)

Tabulka 6: Tabulka zátěží pro původní proměnné (nm) vzhledem k hlavním komponentám

Pásmo vlnových délek (nm)	PC1	PC2	PC3	PC4	PC5	PC6	PC7
430-450	0.1641767	0.4783517	-0.02166879	0.8356857	0.0944196	-0.18007173	0.06359781
540-560	0.2720101	-0.4303776	-0.56660073	0.3174924	-0.13633683	0.53806008	-0.10417007
720-730	0.4736179	-0.1670657	-0.44714065	-0.1759897	0.03563579	-0.70047912	0.15788316
765-785	0.4263235	0.434548	-0.02671178	-0.2502708	-0.05301641	0.09401792	-0.74459198
1060-1080	0.4456516	0.3938159	0.01559035	-0.2802435	0.08016515	0.41281118	0.62504777
1440-1460	0.3981742	-0.2502835	0.54120686	0.1357419	-0.67756492	-0.07252083	0.05595788
1920-1940	0.3685687	-0.3892032	0.4297649	0.101281	0.70915153	0.05369189	-0.10928685

5.2 LDA

Průměrné hodnoty proměnných (spektrálních pásem) pro jednotlivé rostlinné druhy, lze spatřit v tabulce č. 7. Tyto výsledky ukazují možnosti diskriminace mezi rostlinnými druhy na základě hodnot proměnných. Výstup ukazuje, že hodnoty proměnných se pro jednotlivé rostlinné druhy liší a lze je použít k rozlišení mezi skupinami a klasifikaci.

Tabulka 7: Průměrné hodnoty proměnných (nm) pro jednotlivé rostlinné druhy

Pásmo vlnových délek (nm)	Pampeliška	Šťovík	Vojtěška
430-450	0.04467908	0.04373453	0.05315753
540-560	0.1392072	0.1328761	0.1212636
720-730	0.3775217	0.3550170	0.3531762
765-785	0.4732710	0.4446366	0.4803561
1060-1080	0.4664321	0.4318646	0.4666481
1440-1460	0.1549881	0.1180195	0.1432612
1920-1940	0.04957425	0.03621800	0.03687443

Vypočtené koeficienty lineární kombinace proměnných v našem případě byly LD1 a LDA2. Ty udávají, jak moc každá proměnná přispívá k vytvoření každého z diskriminačních faktorů. Proporce stopy pro koeficient LD1 vysvětluje 77,4 % celkové variability dat. Koeficient LD2 vysvětluje 22,54 % celkové variability. Celkově tedy oba koeficienty vysvětlují 100 % variability dat (viz tab. č. 8).

Tabulka 8: Vypočtené koeficienty lineárních diskriminantů (LD)

Pásmo vlnových délek (nm)	LD1	LD2
430-450	87.95627	44.85526
540-560	48.90298	-45.274626
720-730	-94.10931	41.024683
765-785	107.96911	-135.83616
1060-1080	-66.3615	135.788237
1440-1460	105.35383	43.266333
1920-1940	-275.41212	-6.209508

V dalším kroku proběhlo natrénování výsledného modelu LDA. Výsledkem byl natrénovaný LDA model, který je schopen klasifikovat nová data na základě trénovacích. Ověření správnost klasifikaci pomocí chybové matice (viz tab. č. 9). Výsledky chybové matice ukazují, kolik případů bylo správně či špatně klasifikováno pomocí LDA. Výkonost modelu LDA pro trénovací data vykazuje celkovou přesnost klasifikace 95,58 %. Hodnota Kappa byla 93,38 %, což ukazuje velmi vysokou shodu mezi skutečnými a předpovězenými hodnotami.

Tabulka 9: Chybová matice pro trénovací data

Druh		Reference		
		Pampeliška	Šťovík	Vojtěška
Predikce	Pampeliška	734	10	3
	Šťovík	66	789	26
	Vojtěška	0	1	771

V případě klasifikace validačních dat bylo dosaženo naprosto shodné přesnosti 95,58 % a hodnoty Kappa 93,38 %. Výsledná chybová matice je uvedena v tabulce č. 10. V tomto případě bylo 36 měření pampelišky zaměněno se šťovíkem, čtyři měření šťovíku zaměněno s pampeliškou, tři měření vojtěšky zaměněna s pampeliškou a deset měření vojtěšky zaměněno s šťovíkem.

Tabulka 10: Chybová matice pro validační data

Druh		Reference		
		Pampeliška	Šťovík	Vojtěška
Predikce	Pampeliška	364	4	3
	Šťovík	36	394	10
	Vojtěška	0	0	387

V tabulce č. 11 jsou statistiky výkonnosti modelu LDA pro každou třídu zvlášť.

Sensitivita udává podíl správně klasifikovaných pozitivních případů tříd. Pro třídu Pampeliška je 0,91, což znamená, že model správně klasifikoval 91% pozitivních případů pro tuto třídu. Sensitivita třídy Šťovík je 0,99. Sensitivity třídy Vojtěška je 0,9675.

Specificita udává podíl správně klasifikovaných negativních případů tříd. Pro třídu Pampeliška je 0,9221, což znamená, že model správně klasifikoval 92,21 % negativních případů pro tuto třídu pozorování. Specificita třídy Šťovík je 0,9425. Specificita třídy Vojtěška je 1.

Pozitivní prediktivní hodnota udává podíl správně klasifikovaných pozitivních případů k celkovému počtu případů tříd. Pro pampelišku je 0,9811, což znamená, že když model klasifikoval nějaký případ jako Pampeliška, byl správně z 98,11 % případů. Pozitivní prediktivní hodnota třídy Šťovík je 0,8959. Pozitivní prediktivní hodnota třídy Vojtěška je 1.

Negativní prediktivní hodnota udává podíl správně klasifikovaných negativní případů k celkovému počtu případů tříd. Pro pampelišku je 0,9566, což znamená, že když model klasifikoval nějaký případ jako negativní pro třídu Pampeliška, z 95,66 % nepatří do této třídy. Negativní prediktivní hodnota třídy Šťovík je 0,9947 a Vojtěšky 0,984.

Korigovaná přesnost klasifikace udává podíl všech správně klasifikovaných případů, tedy pozitivních a negativních k celkovému počtu případů tříd. Pro třídu Pampeliška je 95 %, pro třídu Šťovík je 96,63 % a pro třídu Vojtěška je 98,38 %, což potvrzuje procentuální správnost klasifikace modelu pro všechny třídy.

Tabulka 11: Statistiky výkonosti modelu LDA pro validační data

	Pampeliška	Šťovík	Vojtěška
Senzitivita	0.9100	0.9900	0.9675
Specifita	0.9221	0.9425	1
Pozitivní prediktivní hodnota	0.9811	0.8959	1
Negativní prediktivní hodnota	0,9566	0,9947	0,984
Korigovaná přesnost klasifikace	0.9506	0.9663	0.9838

6 Diskuze

Neselektivní detekci a regulaci plevelů v reálném čase (za jízdy) lze realizovat pomocí optických senzorů přimontovaných na traktor, které při detekci zelené vegetace spustí krátce otevřený ventil postřikovací trysky (Bennett & Pannell 1998). Tento přístup lze aplikovat na celá pole před vzejitím plodiny nebo mezi řádky po vzejití (Shapira et al. 2013). Využití chemických látek a postřiků v kontextu životního prostředí se však v zemědělství stává stále diskutovanějším tématem. Proto je zde kladen zvláštní důraz na přesnou a nízkou aplikaci herbicidů, což motivuje výzkumníky vytvořit, pokud možno spolehlivé, přesné a automatické systémy k detekci plevelů v porostech zemědělských plodin. Právě hyperspektrální senzory, či kamery představují účinný nástroj, který umožňuje kvantifikovat odrazivost vegetace v úzkých spektrálních pásmech a získávat tak kýžené informace. Precizní zemědělství je synonymem pro moderní přístupy v zemědělské výrobě. Tato práce se zaměřuje na progresivní přístup provádění druhové identifikace plevelných (šřovík a pampeliška) a kulturních (vojtěška) plodin.

Prvním krokem nutným k rozlišení plodin a plevelů je získání souvislých spekter rostlin každého druhu. V této práci byl získán dat o spektrální odrazivosti vojtěšky, šřovíku a pampelišky proveden destruktivním způsobem v polních podmínkách bez přímého slunečního záření pomocí přesného spektrometru FieldSpec 4. Spektra listů získaná kontaktní sondou byla čistá. Rostlinné druhy se od sebe odlišovaly celkovou úrovní odrazivosti, ale jinak měly spektrální křivky poměrně podobný průběh. Rozdíly ve spektrální odrazivosti lze pozorovat zejména v NIR (700–1200 nm), SWIR (1500–2500 nm) ale i ve viditelném spektru (400–700nm). To lze přičíst vnitřní struktuře listů studovaných plodin a jejich přirozené rozdílnosti. Spektra listů nebyla při měření ničím ovlivněna.

Postup sběru dat provedený v této práci má zcela jistě své opodstatnění na akademické úrovni, ale pro budoucí praxi automatické diskriminace plevelů polních plodin se jeví do značné míry jako náročný, což potvrzuje i studie autorů Tiruneh et al. (2022). Nicméně prezentované výsledky lze použít pro další výzkum této problematiky. Proto autoři studie Deng et al. (2016) provedli obdobný experiment pro rozlišení plevelů jako ježatky kuří nohy, kalužnice, rosičky krvavé, merlíku čilského a bėru zeleného v porostech zelí. Uskutečnili sběr dat nedestruktivním způsobem v podmínkách přirozeného slunečního záření tak, že optickou sondu spektrometru FieldSpec umístili svisle nad korunu živého porostu. Tento přístup by mohl v budoucí praxi zjednodušit postup sběru dat. Nicméně

takto provedené bezkontaktní měření s externím zdrojem světla sice možné je, avšak je obtížné docílit konstantních podmínek, protože intenzita osvětlení záleží na různých faktorech. Navíc s využitím přímého slunečního záření nejde zaznamenat průběh spektrální křivky vegetace v celé délce. To z toho důvodu, že některé vlnové délky jsou filtrovány oblohou, zejména pak vlivem oblačnosti. Navíc se mohou výsledné spektrální křivky při opakování měření měnit v závislosti na zdroji světla (slunce nebo modrá obloha). V této diplomové práci bylo však cílem zobrazit celou spektrální křivku za konstantních podmínek pro všechna měření tak, aby bylo možné detekovat veškeré spektrální rozdíly.

Na základě vizuálního zhodnocení průběhu spektrálních křivek rostlin bylo pro účely této diplomové práce vybráno sedm možných spektrálních pásem vykazujících odlišné hodnoty pro jednotlivé druhy rostlin. Pro potvrzení vhodnosti zvolených vlnových pásem bylo použito analýzy hlavních komponent (PCA), podobně jako autoři Deng et al. (2016), avšak s tím rozdílem, že pomocí PCA ověřovali samotné vlnové délky pro pětítýdenní fázi (567, 667, 715, 1345, 1402, 1725, 1925, 2015 nm). Pro sedmitýdenní fázi (567, 667, 745, 1345, 1402, 1545, 1725 a 1925 nm). V této diplomové práci byla potvrzena pomocí PCA vhodnost použití vlnových pásem pro diskriminaci v rozmezí 430-450, 540-560, 720-730, 765-785, 1060-1080, 1440-1460, 1920-1940 nm. Autoři Deng et al. (2016) dodávají, že změna vegetačního stádia zelí a plevelů měla pouze omezený vliv na výběr spektrálních znaků.

V této diplomové práci bylo na základě zvolených vlnových pásem pomocí LDA dosaženo 95,58 % přesnosti klasifikace jak pro testovací, tak pro validační data rostlinných druhů. V porovnání s autory Deng et al. (2016), kteří použili na místo LDA, Bayesovský klasifikační model, vykazovala přesnost klasifikace pro testovací sadu dat 95 % a pro validační 100 %. V obou případech lze tvrdit, že obě analýzy mohou být použity k identifikaci plevelů pomocí hyperspektrální odrazivosti listů. Navíc zvolený postup autorů Deng et al. (2016) naznačuje i snazší uplatnění v praxi.

Diskriminaci na základě spektrálních vlastností a různých přístupů lze aplikovat i pro pestrou škálu jiných plodin.

Například autoři Shapira et al. (2013) provedli pomocí spektrometru FieldSpec pro FR sběr spektrálních dat pšenice a cizrny. Kvalitativní klasifikační analýza byla provedena metodou obecné diskriminační analýzy. Autoři dosáhly přesnosti klasifikace u pšenice z 95 % pomocí úzkých pásem 675, 715, 705, 745, 690, 875, 850, 1909, 750,

760, 1070 nm. a u cizrny 94 % pomocí úzkých pásem 675, 725, 705, 730, 690, 715, 685 a 680 nm. Naproti tomu studie Girma et al. (2005) popisuje diskriminaci plevelů sveřep stoklasa a jílek mnohokvětý v zápoji ozimé pšenice. Pracovním nástrojem byl ruční spektrometr SD2000, který pracoval v rozsahu 350–1000 nm. Pro vlnové délky 400-865 nm byly měřené spektrální hodnoty o šířce 1 nm byly zprůměrovány do 10 nm. Autoři provedli diskriminační analýzu pro kombinaci vlnových délek 515/675, 555/675 805/815 nm. Bylo dosaženo 94 % správnosti klasifikace.

V posledních letech se přístup automatické detekce plevelů a cílená aplikace herbicidů těší stále většímu rozvoji. Dnes již existuje celá řada společností, které se specializují na vývoj a výrobu zařízení pro automatizovanou kontrolu plevelů. Jsou to například FarmWise (FarmWise Labs 2016) či Blue River technology (Blue River Technology 2011). Technologie, které tyto společnosti vyvíjejí, mohou být následně instalovány do různých typů zemědělské mechanizace ale i UAV. Nicméně určité výzvy v aplikaci této technologie představují i vysoké náklady na pořízení, údržbu a kvalifikovaný personál.

Na závěr tak lze potvrdit vědeckou hypotézu, že mezi vojtěškou, šťovíkem a pampeliškou existují rozdíly ve spektrálních vlastnostech, které umožní jejich vzájemné odlišení.

7 Závěr

Přesná detekce plevelů na orné půdě je nezbytným předpokladem pro aplikaci různých opatření, jako je selektivní postřik, či mechanické, elektrické či tepelné odplevelení. Použití moderních senzorů či kamer nabízí velmi vysoké prostorové a časové rozlišení, díky čemuž lze v ideálních podmínkách sbírat velmi přesná a spolehlivá data použitelných pro klasifikaci celé řady rostlinných druhů.

Cílem předložené diplomové práce bylo vyjádřit a popsat spektrální vlastnosti vojtěšky seté (*Medicago sativa*) a vybraných druhů plevelů jako šťovík tupolistý (*Rumex obtusifolius*) a pampelišky lékařské (*Taraxacum officinale*) ve stádiu obrůstání na základě odrazivosti vlnových délek. Po vytvoření a zhodnocení spektrálních křivek bylo vybráno sedm úzkých spektrálních pásem využitelných k odlišení plevelů od plodiny.

Výsledky PCA prokázaly, že všechny vybrané vlnové délky v rozmezí 430-450 nm, 540-560 nm, 720-730 nm, 765-785 nm, 1060-1080 nm, 1440-1460 nm, 1920-1940 nm vykazují významnou korelaci s hlavními komponentami a podílí dostatečnou měrou na variabilitě dat a jsou vhodné pro klasifikaci rostlinných druhů. Pro LDA tak byly použity všechny vybrané vlnové délky.

Výsledná chybové matice validačních dat ukázala, že model LDA byl úspěšný a prezentoval celkovou správnost klasifikace 95,58 %. Správně bylo klasifikováno 364 rostlin pampelišek, kdy došlo k záměně se 36 rostlinami šťovíku, 396 rostlin šťovíku, kdy došlo k záměně s 4 rostlinami pampelišky a 387 rostlin vojtěšky, kdy došlo k záměně s 10 rostlinami šťovíku a 3 rostlinami pampelišky. Výsledky tak odpovídají 91 % správnosti klasifikace pampelišek, 99 % šťovíků a 96,7 % vojtěšek.

Tato diplomová práce ukazuje, že měření spektrálních charakteristik založené na přístupu pozemního spektrálního sběru dat s využitím metod matematicko-statistických algoritmů je využitelné pro klasifikaci vojtěšky, šťovíku a pampelišky. Prezentované výsledky naznačují, že spektrální analýza může být velmi spolehlivou metodou pro odlišení plevelů od plodiny a data by mohla být využita při tvorbě klasifikačních algoritmů pro detekční systémy založené na hyperspektrálním snímkování. Byl tak nastíněn další příklad výzkumu na poli precizního zemědělství, což bude mít přínos pro další vývoj.

Předpokládá se, že spolu s vývojem v oblasti sensoriky, mechaniky, elektroniky, navigací, zpracování a interpretací dat bude mít technologie automatické detekce a diskriminace rostlinných druhů jako odvětví precizního zemědělství v budoucích letech

signifikantní vliv na změnu přístupu k celkové aplikaci herbicidních látek (Brant et al. 2020).

8 Seznam literatury

- Abdi H, Williams LJ. 2010. Principal component analysis. *Wiley interdisciplinary reviews: computational statistics* **2**:433-459.
- Adão T, Hruška J, Pádua L, Bessa J, Peres E, Morais R, Sousa JJ. 2017. Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry. *Remote sensing* **9**:18-31.
- Agron 2020. Biplot of PCs using ggbiplot function. Agron Info Tech, USA. Available from <https://www.buymeacoffee.com/Agron> (accessed March 2023)
- Al-Abbas AH, Barr R, Hall JD, Crane FL, Baumgardner MF. 1972. Spectra of normal and nutrient-deficient maize leaves. Purdue University, West Lafayette, Indiana.
- Antognelli S. 2018. NDVI and NDMI vegetation indices: instructions for use. Agricolous s.r.l, Perugia, Italia. Available from <https://www.agricolus.com/en/vegetation-indices-ndvi-ndmi/> (accessed January 2023).
- Bagheri N, Ahmadi H, Alavipannah SK, Omid M. 2013. Multispectral remote sensing for site-specific nitrogen fertilizer management. *Pesquisa Agropecuária Brasileira* **48**:1394-1401.
- Bennett AL, Pannell DJ. 1998. Economic evaluation of a weed-activated sprayer for herbicide application to patchy weed populations. *Australian Journal of Agricultural and Resource Economics* **42**:389-408.
- Blue River Technology, Inc., 2011. Blue River Technology. Available from <https://bluerivertechnology.com/> (accessed March 2023).
- Boulet J, Foucher S, Théau J, St-Charles PL. 2019. Convolutional neural networks for the automatic identification of plant diseases. *Frontiers in plant science* **10**:1-15.
- Brant V, Kroulík M, Krček V, Krása J, Kapička J, Hamouz P, Petrus, D. 2020. Implementace principů precizního zemědělství do rostlinné výroby. Kurent, sro., České Budějovice.
- Campbell JB, Wynne RH. 2011. *Introduction to Remote Sensing*. The Guilford Press, New York.
- Česká technologická platforma pro zemědělství. 2022. Dálkový průzkum Země a precizní zemědělství. Zemědělský svaz ČR - Česká technologická platforma pro zemědělství, Praha.
- Chiteculo V, Abdollahnejad A, Panagiotidis D, Surový P, Sharma RP. 2019. Defining deforestation patterns using satellite images from 2000 and 2017: Assessment of forest management in miombo forests—A case study of Huambo Province in Angola. *Sustainability* **11**:1-20.

- Cisternas I, Velásquez I, Caro, A, Rodríguez A. 2020. Systematic literature review of implementations of precision agriculture. *Computers and Electronics in Agriculture* **176**:1-11.
- Clark ML, Roberts DA. 2012. Species-level differences in hyperspectral metrics among tropical rainforest trees as determined by a tree-based classifier. *Remote Sensing* **4**:1820-1855.
- De Vries, Andrie a Joris MEYS. 2015. *R for Dummies* 2nd Edition. John Wiley & Sons, Inc., 111 River Street, Hoboken
- Delalieux S, Auwerkerken A, Verstraeten, WW., Somers B., Valcke R., Lhermitte, S, Coppin P. 2009. Hyperspectral reflectance and fluorescence imaging to detect scab induced stress in apple leaves. *Remote sensing* **1**:858-874.
- Deng W, Huang Y, Zhao C, Chen L, Wang, X. 2016. Bayesian discriminant analysis of plant leaf hyperspectral reflectance for identification of weeds from cabbages. *African Journal of Agricultural Research* **11**:551-562.
- Edmund Optics. 2023. *Hyperspectral and Multispectral Imaging*. Edmund Optics Available from https://www.edmundoptics.eu/knowledge-center/application-notes/imaging/hyperspectral-and-multispectral-imaging/?fbclid=IwAR2TUZa1TW9rc_zVc sa f7_jJckJo_XtVmcYcA_Jl_7e5D5YsZ2c9_9SWX4 (accessed March 2023)
- European Parliament. 2016. *Precision agriculture and the future of farming in Europe Scientific Foresight Study*. Scientific Foresight Unit, Brussels
- Ehleringer J, Forseth I. 1980. Solar tracking by plants. *Science* **210**: 1094–1098.
- Farmwise Labs Inc. 2016. *FarmWise. Feeding Our World and Our Future*. Available from <https://farmwise.io/> (accessed March 2023)
- Galvão LS, Roberts, DA, Formaggio R, Numata I, Breunig FM. 2009. View angle effects on the discrimination of soybean varieties and on the relationships between vegetation indices and yield using off-nadir Hyperion data. *Remote Sensing of Environment* **113**:846-856.
- Genc H, Genc L, Turnah H, Smith SE, Nation JL. 2008. Vegetation indices as indicators of damage by the sunn pest (Hemiptera: Scutelleridae) to field grown wheat. *African Journal of Biotechnology* **7**:173–180.
- Girma K, Mosali J, Raun WR, Freeman KW, Martin KL., Solie JB., Stone M. L. 2005. Identification of optical spectral signatures for detecting cheat and ryegrass in winter wheat. *Crop Science* **45**:477-485.
- Gras C, Caceres DM. 2020. Technology, nature's appropriation and capital accumulation in modern agriculture. *Current Opinion in Environmental Sustainability* **45**:1-9.

- Guimarães N, Pádua L, Marques P, Silva N, Peres E, Sousa, JJ. 2020. Forestry remote sensing from unmanned aerial vehicles: A review focusing on the data, processing and potentialities. *Remote Sensing* **12**:1-33.
- Hueni A, Bialek A. 2017. Cause, effect, and correction of field spectroradiometer interchannel radiometric steps. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **10**:1542-1551.
- Huete AR. 1988. A soil-adjusted vegetation index (SAVI). *Remote sensing of environment* **25**:295-309.
- Jin S, Wang Q, Dardanelli G. 2022. A review on multi-GNSS for earth observation and emerging applications. *Remote Sensing* **14**:1-23.
- Jordan CF. 1969. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. *Ecology*. **50**:663–666.
- Gabriel K R. 1971. The biplot graphic display of matrices with application to principal component analysis. *Biometrika* **58**:453-467.
- Kauth RJ, Thomas GS. 1976. Tasselled Cap - a Graphic Description of the Spectral-Temporal Development of Agricultural Crops As Seen By Landsat 41–51.
- Kaufman YJ, and Tanre D. 1992. Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing* **30**:261–270.
- Kornilov AS, Safonov IV. 2018. An overview of watershed algorithm implementations in open source libraries. *Journal of Imaging* **4**:1-23.
- Koutsos T, Menexes G. 2019. Economic, agronomic, and environmental benefits from the adoption of precision agriculture technologies: A systematic review. *International Journal of Agricultural and Environmental Information Systems (IJAEIS)* **10**:40-56.
- Kumar J, Vashisth A, Sehgal VK, Gupta V. K. 2013. Assessment of aphid infestation in mustard by hyperspectral remote sensing. *Journal of the Indian Society of Remote Sensing* **41**:83-90.
- Kuželka K, Slavík M, Surový P. 2020. Very high density point clouds from UAV laser scanning for automatic tree stem detection and direct diameter measurement. *Remote Sensing* **12**:1-20.
- Liaghat S, Balasundram SK. 2010. A review: The role of remote sensing in precision agriculture. *American journal of agricultural and biological sciences* **5**:50-55.
- Liu T, Im J, Quackenbush L. J. 2015. A novel transferable individual tree crown delineation model based on Fishing Net Dragging and boundary classification. *ISPRS journal of photogrammetry and remote sensing* **110**:34-47.

- Malvern Panalytical. 2022. ASD FieldSpec 4 Brochure. Available from <https://www.malvernpanalytical.com/en/products/product-range/asd-range/fieldspec-range/fieldspec-4-standard-res-spectroradiometer> (accessed March 2023)
- Mantero P, Moser G, Serpico SB. 2005. Partially supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Transactions on Geoscience and Remote Sensing* **43**:559-570.
- Mason B., Schmetz J. 1992. Meteorological satellites. *International Journal of Remote Sensing* **13**: 307.
- Milton EJ, Schaepman ME, Anderson K, Kneubühler M, Fox N. 2009. Progress in field spectroscopy. *Remote Sens. Environ* **113**:92-109.
- Mintert JR, Widmar D, Langemeier M, Boehlje M, Erickson B. 2016. The challenges of precision agriculture: Is big data the answer? Southern Agricultural Economics Association, San Antonio, Texas
- Moon KS, Daughtry CT, Chappelle EW, McMurtrey JE, Walthall CL. 1994. The use of high spectral resolution bands for estimating absorbed photosynthetically active radiation (A par). Proceedings of the 6th International Symposium on Physical Measurements and Signatures in Remote Sensing, CNES. Phoenix, Arizona
- Mogensen VO, Jensen CR, Mortensen G, Thage JH, Koribidis J, Ahmed A. 1996. Spectral reflectance index as an indicator of drought of field grown oilseed rape (*Brassica napus* L.). *European Journal of Agronomy* **5**:125-135.
- Monteiro A, Santos S. 2022. Sustainable approach to weed management: The role of precision weed management. *Agronomy* **12**:1-14.
- Mountrakis G, Im J, Ogole C. 2011. Support vector machines in remote sensing: A review. *ISPRS journal of photogrammetry and remote sensing* **66**:247-259.
- Nanni MR, Demattê JAM. 2006. Spectral reflectance methodology in comparison to traditional soil analysis. *Soil science society of America journal* **70**:393-407.
- Neale CM, Jayanthi H, Wright JL. 2005. Irrigation water management using high resolution airborne remote sensing. *Irrigation and Drainage Systems* **19**:321-336.
- Novotný I, Papaj V, Podhrázská J, Kapička J, Vopravil J, Kristenová H, Kadlec V. 2017. Příručka ochrany proti erozi zemědělské půdy. Výzkumný ústav meliorací a ochrany půdy, Praha.
- Noyel G, Angulo J, Jeulin D. 2020 Nemělo by to být 2007?. Morphological segmentation of hyperspectral images. *Image Analysis and Stereology* **26**:101-109.
- O'Shea K, Nash R. 2015. An introduction to convolutional neural networks. ArXiv e-prints:1511.08458.

- Patočka Z, Sabol J, Mikita T, Carbol S. 2016. Využití plošného přístupu ke zpracování dat leteckého laserového skenování v inventarizaci lesa. Praktické využití GIS v lesnictví a zemědělství, 1-6.
- Pavelka K. 2010. Dálkový průzkum Země-družicové systémy. České vysoké učení technické v Praze, Praha
- Pékar S, Brabec M. 2016. Modern analysis of biological data: generalized linear models in R. Masarykova univerzita, Brno.
- Qi J, Chehbouni A, Huete AR, Kerr YH, Sorooshian S. 1994. A modified soil adjusted vegetation index. Remote sensing of environment **48**:119-126.
- Qin J, Chao K, Kim MS, Lu R, Burks TF. 2013. Hyperspectral and multispectral imaging for evaluating food safety and quality. Journal of Food Engineering **118**:157-171.
- Richards JA. 2022. Supervised classification techniques. Remote sensing digital image analysis. Springer, Berlin.
- Richardson AJ, Wiegand CL. 1977. Distinguishing vegetation from soil background information. Photogrammetric engineering and remote sensing **43**:1541-1552.
- Rodarmel C, Shan J. 2002. Principal component analysis for hyperspectral image classification. Surveying and Land Information Science **62**: 115-122.
- Roy PS. 1989. Spectral reflectance characteristics of vegetation and their use in estimating productive potential. Proceedings: Plant Sciences **99**:59-81.
- Sebera M. 2012. Vícerozměrné statistické metody. Masarykova univerzita, Brno. Available from www.fsps.muni.cz (accessed July 2020).
- Shapira U, Herrmann I, Karnieli A, Bonfil DJ. 2013. Field spectroscopy for weed detection in wheat and chickpea fields. International journal of remote sensing, **34**:6094-6108.
- Slaughter DC, Giles DK, Fennimore SA, Smith RF. 2008. Multispectral machine vision identification of lettuce and weed seedlings for automated weed control. Weed Technology **22**:378-384.
- Stroppiana D, Boschetti M, Brivio PA, Bocchi S. 2009. Plant nitrogen concentration in paddy rice from field canopy hyperspectral radiometry. Field crops research **111**:119-129.
- Surový P, Kuželka K, Slavík M, Melichová Z, Sirotková K. 2019. Aplikace dálkového průzkumu země v lesnictví. Česká zemědělská univerzita v Praze, Praha.
- Taghvaeian S, Cháves JL, Altenhofen J, Trout T, DeJonge K. 2013. Remote sensing for evaluating crop water stress at field scale using infrared thermography: potential and limitations, Hydrology Days, Colorado State University.

- Tarabalka Y, Chanussot J, Benediktsson, JA. 2010. Segmentation and classification of hyperspectral images using watershed transformation. *Pattern Recognition* **43** :2367-2379.
- Thenkabail PS, Mariotto I, Gumma MK, Middleton EM, Landis DR, Huemmrich KF. 2013. Selection of hyperspectral narrowbands (HNBS) and composition of hyperspectral twoband vegetation indices (HVIs) for biophysical characterization and discrimination of crop types using field reflectance and Hyperion/EO-1 data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **6**: 427-439.
- Thenkabail PS, Gumma MK, Teluguntla P, Irshad A. 2014. Hyperspectral Hyperion Images and Spectral Libraries of Agricultural Crops. **80**(8).
- Thompson JF, Stafford JV, Miller PC H. 1991. Potential for automatic weed detection and selective herbicide application. *Crop protection* **10**:254-259.
- Thorp KR, Tian L, Yao H, TangL. 2004. Narrow-band and derivative-based vegetation indices for hyperspectral data. *Transactions of the ASAE* **47**:291.
- Tiruneh GA, Meshesha DT, Adgo E, Tsunekawa A, Haregeweyn N, Fenta AA, Reichert JM. 2022. A leaf reflectance-based crop yield modeling in Northwest Ethiopia. *Plos one* **17**:1-21.
- Vrindts E, De Baerdemaeker J, Ramon H. 2002. Weed detection using canopy reflection. *Precision agriculture* **3**:63-80.
- Vysoudil M. DÁLKOVÝ PRŮZKUM ZEMĚ III. 1993. Univerzita Palackého, Olomouc s. 57.
- Wang Y, Xu L. 2018. Unsupervised segmentation of greenhouse plant images based on modified Latent Dirichlet Allocation. *PeerJ* **6**:1-31.
- White JC, Coops NC, Wulder MA, Vastaranta M, Hilker T, Tompalski P. 2016. Remote sensing technologies for enhancing forest inventories: A review. *Canadian Journal of Remote Sensing* **42**:619-641.
- Wójtowicz M, Wójtowicz A, Piekarczyk J. 2016. Application of remote sensing methods in agriculture. *Communications in biometry and crop science* **11**:31-50.
- Xue J, Su B. 2017. Significant remote sensing vegetation indices: a review of developments and applications. *J Sens* **2017**:1–17.
- Yue J, Feng H, Jin X, Yuan H, Li Z, Zhou C, Tian Q. 2018. A comparison of crop parameters estimation using images from UAV-mounted snapshot hyperspectral sensor and high-definition digital camera. *Remote Sensing* **10**:1-24.
- Žížala D, Lukas V, Kumhálová J. 2021. Dálkový průzkum Země a precizní zemědělství P. První. B.m.: Zemědělský svaz ČR - Česká technologická platforma pro zemědělství, Praha.

Zwiggelaar R. 1998. A review of spectral properties of plants and their potential use for crop/weed discrimination in row-crops. *Crop protection* **17**:189-206.

