

**Česká zemědělská univerzita v Praze**

**Fakulta agrobiologie, potravinových a přírodních zdrojů**

**Katedra agroekologie a rostlinné produkce**



**Česká zemědělská  
univerzita v Praze**

**Rozlišování plodin a plevelů na základě spektrálních  
vlastností**

**Diplomová práce**

**Autor práce: Bc. Kamila Nová**

**Obor studia: Rozvoj venkovského prostoru**

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

**© 2020 ČZU v Praze**

### **Čestné prohlášení**

Prohlašuji, že svou diplomovou práci "Rozlišování plodin a plevelů na základě spektrálních vlastností" jsem vypracovala samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou citovány v práci a uvedeny v seznamu literatury na konci práce. Jako autorka uvedené diplomové práce dále prohlašuji, že jsem v souvislosti s jejím vytvořením neporušila autorská práva třetích osob.

V Praze dne 23.7.2020

---

## **Poděkování**

Ráda bych touto cestou poděkovala Ing. Pavlu Hamouzovi, Ph.D za odborné vedení, věcné připomínky a vstřícnost při konzultacích a zpracování diplomové práce.

# Rozlišování plodin a plevelů na základě spektrálních vlastností

## Souhrn

Tato diplomová práce je zaměřena na rozlišování plodin a plevelů na základě spektrálních vlastností. V současné době je nezbytně nutné zaměřit se na snížení aplikace přípravků na ochranu rostlin v zemědělství včetně herbicidů. Jejich cílená aplikace však vyžaduje efektivní a spolehlivé metody pro detekci zaplevelení v porostech plodin. Spektrální analýza je ve srovnání s dalšími analytickými postupy rychlá a šetrná k životnímu prostředí, což se v posledních letech dostává do popředí zájmu. Pro detekci vegetace a rozlišení jednotlivých rostlinných druhů jsou využívány vlnové délky obvykle v rozsahu od 400 do 2500 nm, tedy viditelné záření, NIR a SWIR.

Pro potřeby naplnění cílů je v první části práce stanovena hypotéza, která předpokládá, že mezi některými rostlinnými druhy existují rozdíly ve spektrálních vlastnostech, které umožní jejich vzájemné odlišení. V teoretické části se jedná o literární rešerši a výstupy z výzkumů týkajících se této metody. Ve druhé části byla zpracována a analyzována data z vlastního pozorování. Byly navrženy algoritmy pro vhodné rozpoznání jednotlivých rostlinných druhů a stanoven závěr.

S využitím přenosného spektrometru Fieldspec 4 byla analyzována spektrální odrazivost u bílého zelí a vybraných plevelů (bažanka roční, ježatka kuří noha, laskavec ohnutý, merlík bílý) v raných růstových fázích, v rozsahu vlnových délek od 350 do 2500 nm. Byla identifikována spektrální pásma, která jsou charakteristická pro jednotlivé rostlinné druhy a jejich růstové fáze. Pomocí analýzy hlavních komponent (PCA) byla ověřena vhodnost vybraných spektrálních pásem pro diskriminaci jednotlivých rostlinných druhů. Pro klasifikaci dat byla použita lineární diskriminační analýza (LDA). Výsledky klasifikace byly vyjádřeny celkovou přesností klasifikace a chybovou maticí, senzitivitou a specificitou.

V případě validačních dat bylo dosaženo velmi vysoké přesnosti klasifikace (99,45 %). Většina měřených objektů byla pomocí lineární diskriminační analýzy přiřazena zcela bezchybně k rostlinným druhům. Tomu odpovídají vysoké hodnoty dalších sledovaných parametrů. Senzitivita i specificita byla u všech klasifikačních tříd vyšší než 0,98 a korigovaná přesnost klasifikace byla pro všechny třídy vyšší než 0,99.

Prezentované výsledky naznačují, že spektrální analýza může být velmi spolehlivou metodou pro odlišení plevelů od plodiny. Získaná data mohou být využita při tvorbě klasifikačních algoritmů pro detekční systémy založené na hyperspektrálním snímkování.

**Klíčová slova:** spektrální analýza, plevele, plodiny, vegetační indexy, cílená regulace, precizní zemědělství

# Discrimination of crops and weeds based on spectral properties

## Summary

This diploma thesis is focused on discrimination of crops and weeds based on spectral properties. At present, it is essential to focus on reducing the application of plant protection products in agriculture, including herbicides. However, their targeted application requires effective and reliable methods for weed detection in crops. Spectral analysis is fast and environmentally friendly, along with other analytical procedures, which has come to the forefront of interest in recent years. Wavelengths usually in the range from 400 to 2500 nm in visible, NIR and SWIR are used to detect vegetation and distinguish individual plant species.

For purposes of meeting the objectives the first part of the thesis provides a hypothesis which suggests that there are differences in spectral properties between some plant species which will enable their discrimination. In the theoretical part there is a literature search and research outputs related to this method. In the second part the data from own observations have been processed and analyzed. Algorithms for appropriate recognition of individual plant species have been suggested and the conclusion has been set.

The spectral reflectance of white cabbage and selected weeds (*Mercurialis annua* L., *Echinochloa crus-galli*, *Chenopodium album* L, *Amaranthus retroflexus* L) in early growth stages was analyzed in the wavelengths range from 350 to 2500 nm, using a portable Fieldspec 4 spectrometer. Spectral bands that are characteristic for individual plant species and their growth phases were identified. Using the principal component analysis (PCA), the suitability of the selected spectral bands for the discrimination of individual plant species was verified. Linear discriminant analysis (LDA) was used to classify the individual plant species. The classification results were expressed by the overall accuracy of the classification and the error matrix, sensitivity and specificity.

In the case of validation data, the classification accuracy was achieved (99,45 %). Most of the measured objects were assigned to plant species without any errors using linear discriminant analysis. This corresponds to the high values of other monitored parameters. Sensitivity and specificity were higher than 0,98 for all classification classes and corrected classification accuracy was higher than 0,99 for all classes.

The presented results suggest that spectral analysis can be a very reliable method for distinguishing weeds from crops. The obtained data can be used in the creation of classification algorithms for detection systems based on hyperspectral imaging.

**Keywords:** spectral analysis, crops, weeds, vegetation indices, targeted regulation, precision agriculture

# Obsah

<b>1</b>	<b>Úvod</b>	<b>1</b>
<b>2</b>	<b>Vědecká hypotéza a cíle práce</b>	<b>2</b>
<b>3</b>	<b>Literární rešerše</b>	<b>3</b>
<b>3.1</b>	<b>Precizní zemědělství</b>	<b>3</b>
<b>3.2</b>	<b>Dálkový průzkum Země</b>	<b>4</b>
3.2.1	Elektromagnetické záření	5
3.2.2	Historie dálkového průzkumu Země	7
3.2.3	Spektrální vlastnosti vegetace	15
<b>3.3</b>	<b>Vegetační indexy</b>	<b>16</b>
3.3.1	Širokopásmové vegetační indexy	17
3.3.2	Úzkopásmové vegetační indexy	20
<b>3.4</b>	<b>Využití dálkového průzkumu pro detekci plevelů</b>	<b>23</b>
3.4.1	Letecké a satelitní snímkování plevelů	23
3.4.1	Pozemní senzorové systémy k detekci zaplevelení	25
<b>4</b>	<b>Metodika</b>	<b>28</b>
	<b>Sběr dat</b>	<b>28</b>
<b>5</b>	<b>Výsledky</b>	<b>31</b>
<b>6</b>	<b>Diskuze</b>	<b>38</b>
<b>7</b>	<b>Závěr</b>	<b>40</b>
<b>8</b>	<b>Seznam literatury</b>	<b>41</b>

# 1 Úvod

Světová populace roste, narůstá poptávka po zemědělských produktech, ubývá dostupná půda a zároveň dochází ke klimatickým změnám. Stále častěji se tedy dostává do popředí otázka nutnosti zvyšování zemědělské produkce a zároveň snižování chemických vstupů a ochrany životního prostředí. Zemědělci musí usilovně reagovat na zvyšující se globální potřeby výživy a zároveň řešit krizi životního prostředí. (Michalopoulos 2016).

Získávání znalostí o tom, jak obhospodařovat rozdílné části pozemku je při tradičním přístupu náročné. Proto rychlý rozvoj výpočetní techniky, vývoj globálních navigačních satelitních systémů (GNSS), senzorová technika a aplikační ovládací prvky umožňují rozpoznávání a lokalizaci rozdílů v rámci pozemků. Klíčovým úkolem precizního zemědělství je rozpoznání heterogenity pozemku (Oliver 2010).

K získávání relevantních a přesných informací o zaplevelení přispívá dálkový průzkum Země. Je možné snímat určitou oblast z družic, letadel, bezpilotních platform a pozemních senzorových systémů a získat tak informace o zdravotním stavu pozemku a rozpoznat kritická místa, která je při běžném provozu obtížné zachytit. Hlavním úkolem získaných dat o půdě, plodinách, živinách, škůdcích, vlhkosti a výnosu, je optimalizace zisku a ochrana životního prostředí (Thorp & Tian 2004; López-Granados et al. 2006; Jones & Vaughan 2010; Dominguez et al. 2015). Tyto metody optimalizují produkční vstupy (pesticidy, hnojiva, pohonné látky) na základě konkrétních požadavků plodin a půdy formou variabilně prováděných zásahů (Jones & Vaughan 2010; Clay & Shanahan 2011; Neudert & Lukas 2015).

Podle přední světové organizace pro výzkum životního prostředí (Land Care of New Zealand) by měl být plevel považován za největšího přírodního nepřítele farmáře. Plevel v kulturní vegetaci má obrovský nežádoucí dopad na celý proces zemědělské produkce, což přináší obrovské finanční ztráty. Zemědělci se tedy neustále musí potýkat s nechtěným zaplevelením v zemědělské krajině. Vzhledem k těmto okolnostem, je nutné hledat vysoce účinné metody pro efektivní hubení plevelů (Deng et al. 2016). Řešením by mohlo být rozšířenější využívání metod precizního zemědělství.

Cílené ošetření plevelů by mohlo výrazně snížit spotřebu herbicidu v závislosti na druhu plevele a rozsahu jeho rozšíření. Hustota zaplevelení dlouhodobě nestoupá, je-li jeho výskyt regulován pouze v lokálních ohniscích. Důležitým předpokladem této aplikace na lokální úrovni, je potřeba znát druhové složení plevele v konkrétní oblasti. Přesné a včasné mapování rozložení plevelů je klíčovým krokem pro dosažení lokální aplikace herbicidu (López-Granados et al. 2006; De Castro et al. 2013).

Cílem práce bylo analyzovat spektrální vlastnosti vybraných plodin a plevelů a identifikovat takové spektrální rozdíly, které bude možno využít pro rozlišení jednotlivých rostlinných druhů v porostech polních plodin při cílené regulaci zaplevelení v systému precizního zemědělství.

## **2 Vědecká hypotéza a cíle práce**

Cílem práce bylo analyzovat spektrální vlastnosti vybraných plodin a plevelů a identifikovat takové spektrální rozdíly, které bude možno využít pro rozlišení jednotlivých rostlinných druhů v porostech polních plodin při cílené regulaci zaplevelení v systému precizního zemědělství. Vědecká hypotéza předpokládala, že mezi některými rostlinnými druhy existují rozdíly ve spektrálních vlastnostech, které umožní jejich vzájemné odlišení. Pomocí přenosného spektrometru byla analyzována spektrální odrazivost vybraných plodin a plevelů v různých růstových fázích. Byla identifikována spektrální pásma, která jsou charakteristická pro jednotlivé rostlinné druhy a jejich růstové fáze. Byly navrženy algoritmy vhodné pro rozpoznání jednotlivých rostlinných druhů.



## 3 Literární rešerše

### 3.1 Precizní zemědělství

Precizní zemědělství je pokročilý vztah zemědělství k životnímu prostředí, biodiverzitě, ochraně přírodních zdrojů a k potravinové bezpečnosti. Jedná se o systém hospodaření, který je založen na informacích a technologiích používaných na konkrétním místě s ohledem k aktuálním potřebám plodin a stavu půdy. Jsou využívána data o půdě, plodinách, živinách, škůdcích, vlhkosti a výnosu. Hlavním úkolem získaných dat je optimalizace zisku a ochrana životního prostředí. Precizní zemědělství dává do souladu typ a množství vstupů s reálnými požadavky plodiny na malých homogennějších plochách v rámci pozemku. Dát tedy plodinám tolik, kolik opravdu potřebují, což je možné pouze s podkladovými daty. Původně byl určen jako nástroj při pěstování obilnin, ale postupným vývojem a častějším využíváním, roste jeho využívání i u široké škály dalších plodin (Clay & Shanahan 2011; Whelan & Taylor 2013; Neudert & Lukas 2015).

Precizní zemědělství zahrnuje datové technologie, do nichž patří satelitní navigační systémy jako GPS, dálkový průzkum a internet. Všechny tyto technologie pomáhají dosáhnout lepší úrody a zároveň výrazně snižují množství použitých hnojiv, pesticidů a vody. Zavádění těchto technologií pomáhá zemědělcům spravovat jejich podnik udržitelným způsobem, s ohledem na nejmenší detaily každodenního hospodaření. Širší využívání metod precizního zemědělství by dokázalo účinněji využít chemické vstupy (pesticidy a hnojiva), a přispět k ochraně půdy, podzemní vody, zvýšit efektivitu výroby, kvalitnější výrobky a snížit spotřebu energií. Je to nadstavba konvenčního zemědělství, které nepřihlíží k individuálním potřebám hnojení, používání pesticidů a zavlažování (Clay & Shanahan 2011).


Zavádění metod precizního zemědělství je možné pouze díky vývoji technologie snímačů v kombinaci s postupy pro propojení mapových proměnných s odpovídající zemědělskou činností jako je pěstování, výsev, hnojení, aplikace herbicidů a sklizeň. Rychlý pokrok v technologiích byl možný díky miniaturizaci a lepší přesnosti družicového navigačního systému (GNSS). Spousta farem v EU využívá GNSS technologie (GPS je nejrozšířenější) zejména k určování polohy zemědělské techniky, geo-referenčním informacím (např. mapování výnosů). GNSS umožnil rozšíření strojního vedení, automatického řízení strojů a CTF (Control Traffic Farming) systémy (řízené provozování dopravy). Takové metody umožňují řízení stroje v přesné stopě, snižují chyby způsobené člověkem, snižují únavu operátora, dovolují lepší načasování operací a omezují zhutňování půdy. Dalším důležitým prvkem je použití technologie VRT (Variable Rate Technology), která optimalizuje výsadbu, pěstování, použití herbicidů a hnojiv, což snižuje náklady a dopady na životní prostředí (Zarco-Tejada et al. 2014). Precizní zemědělství je značně nákladné. Kromě jednorázových pořizovacích nákladů (GPS přijímač nebo variabilní aplikátor) jsou nutné i pravidelné úhrady mapování půdy, korekce GPS signálu nebo servis strojů (Neudert & Lukas 2015). Proto se metody precizního zemědělství omezují zpravidla jen na velké podniky. Podle Daberkow & McBride (1998) je to navíc upřednostňováno na půdách s vysokou produktivitou nebo pro plodiny s vysokým výnosem. Jak píše Khanna (2001), pokud jsou na úrodné půdě různé výnosy, dokáže tento způsob řízení rychleji a efektivněji

vyrovnat rozdíly a dosáhnout zisku. Na druhou stranu je přínos pro životní prostředí větší při hospodaření na méně úrodných půdách.

Groffman (1997) upozorňuje na ekologické limity této zemědělské praxe, které jsou jeho podstatou, a precizní zemědělství se s nimi neumí vypořádat. Jedná se hlavně o ztrátu dusíku. I přestože precizní zemědělství dokáže tyto ztráty snižovat, neumí zmírnit vyplavování před výsevem a při sklizni, kdy je půda bez vegetace. Obdobně to vidí s orbou, která vystavuje půdu erozi.

### 3.2 Dálkový průzkum Země

Nejčastější definicí tohoto vědního oboru je získávání informací o zemském povrchu bez přímého kontaktu s ním (Budd 1991). Podstatou je tedy sběr dat pomocí snímkování. Snímky jsou pořizovány díky záznamovým zařízením umístěným na různých nosičích. Nejčastěji se jedná o družice nebo letadla. Přístroje dokážou zaznamenat intenzitu elektromagnetického záření v různých intervalech vlnových délek. Následně přichází na řadu analýza získaných dat. Tato metoda má velký přínos pro pozorování vegetace. Hlavní předností je skutečnost, že se jedná o metodu šetrnou, což umožňuje provádět ji opakovaně v různých fázích vegetačního vývoje zkoumaného porostu (Jones & Vaughan 2010).



Obr. 1: Princip Dálkového průzkumu Země (Copernicusa 2020).

K obrovskému rozvoji DPZ (Dálkový průzkum Země) došlo zejména v posledních desetiletích, kdy bylo dokázáno, že z této vědní disciplíny profituje celá společnost. Jde se o získávání důležitých informací. Všechny tyto poznatky by nebylo možné získat pouhým monitorováním a pozorováním – bylo by to časově příliš náročné a finančně nákladné. Jedná se totiž o procesy odehrávající se ve velkých měřítcích, monitorují se těžko dostupné oblasti a změny v průběhu času. Obrovskou výhodou je sběr dat a informací, které nejsou pouhým okem viditelné – zahrnuje to práci s různými spektry záření, které se v DPZ využívá (Schott 2007).


Celý systém DPZ je složen ze základny (letadlo, vesmírná loď, balón nebo může být spojen i se zemí) a speciálního senzoru, který je schopen zaznamenat elektromagnetické záření a tato data následně poslouží k dalším analýzám. Takto získané informace jsou buď vizuální, nebo digitální (Joseph 2005).

Dálkový průzkum Země používá dvě metody snímání – pasivní a aktivní.

- Pasivní – elektromagnetické záření, jež je odraženo od všech předmětů na Zemi. Sluneční záření, které dopadá na zemský povrch se odráží, a tím je pasivní metodou snímáno elektromagnetické záření. Pokud je teplota předmětu vyšší než 0 K, je tento předmět schopný sám vyzařovat termální záření, a tehdy mluvíme o termálním snímání.
- Aktivní – u aktivních metod snímání dochází k vysílání vlastního záření a přijímání odraženého signálu od vybraných objektů. Ze získaných informací jsou následně vyvozeny závěry (Joseph 2005).

### 3.2.1 Elektromagnetické záření

Elektromagnetické záření se mění s délkou, velikostí vysílaného signálu, podmínkami atmosféry a vlnovou délkou. Největší podíl na ovlivňování záření má rozptyl a absorpce. Jednotlivé materiály a objekty na zemském povrchu se liší podle odrazení a pohlcování elektromagnetického záření, které na ně působí – tedy silového pole. Tato vlastnost je využívána při DPZ. (Dobrovolný 1998).




Obr. 2: Křivky spektrálního odrazu (Copernicusa 2020)

Podstatou elektromagnetického záření je elektrické a magnetické pole, vlnová délka, rychlost a frekvence.

Vlnová délka ( $\lambda$ ) – vzdálenost libovolného bodu na křivce záření k bodu, který se nachází ve stejné poloze na dané křivce

Rychlost ( $c$ ) – rychlost světla, která tvoří část spektra elektromagnetického záření

Frekvence ( $\nu$ ) – počet kmitů (vrcholů) vlnění za jednotku času (Aggarwal 2004).



Obr. 3: Elektromagnetické záření (Aggarwal 2004).

E – elektrické pole, M – magnetické pole, c – rychlost světla,  $\nu$  – frekvence,  $\lambda$  – vlnová délka

Podle vlnových délek elektromagnetického záření rozlišujeme hlavní intervaly záření (vlnová délka) – spektra (Halounová & Pavelka 2008). Ta od sebe diferencují intervaly vlnových délek, ve kterých jsou zaznamenávány (viz tab. 1).

Tabulka č. 1: Hlavní skupiny elektromagnetického spektra

VLNOVÁ DÉLKA	POPIS
Gama paprsky	Gama paprsky
Rentgenové paprsky	Rentgenové paprsky
Ultrafialové (UV) – oblast 0,30-0,38 $\mu\text{m}$	Tato oblast je za fialovou částí viditelné oblasti vlnové délky. Některé zemské povrchy, zejména horniny a minerály vyzařují viditelné UV záření. Ovšem toto záření je do značné míry rozptýlené atmosférou, a proto se dálkové snímání nepoužívá.
Viditelné spektrum - oblast 0,4-0,7 $\mu\text{m}$ Fialová 0,4-0,446 $\mu\text{m}$ Modrá 0,446-0,5 $\mu\text{m}$ Zelená 0,5-0,578 $\mu\text{m}$ Žlutá 0,578-0,592 $\mu\text{m}$ Oranžová 0,592-0,62 $\mu\text{m}$	Světlo, které naše oči dokážou rozpoznat. Toto je jediná část spektra, která může být spojována s pojmem barvy. Modrá, zelená a červená jsou tři základní barvy viditelného spektra. Jsou takto definovány, protože pro všechny ostatní barvy

Červená 0,62-0,76 $\mu\text{m}$	potřebujeme v různých poměrech tyto 3 základní barvy. Barva objektu je definována barvou světla, které odráží.
Blízké infračervené (NIR) – 0,76-1,4 $\mu\text{m}$ Krátké infračervené (SWIR) – 1,4-3 $\mu\text{m}$ Střední infračervené (MWIR) – 3-8 $\mu\text{m}$ Dlouhé infračervené (LWIR) – 8-15 $\mu\text{m}$ Vzdálené infračervené (FIR) – 15-1000 $\mu\text{m}$	Vlnové délky delší než červená část viditelného spektra, jsou označovány jako infračervené spektrum. Infračervená oblast může být rozdělena do 2 kategorií na základě vlastností jejich záření: 1. Odražené IR (0,7-3,0 $\mu\text{m}$ ) se používá pro dálkové snímání 2. Tepelné IR (3,0-35 $\mu\text{m}$ ) je záření vyzařované ze zemského povrchu ve formě tepla a používá se pro dálkové snímání
Mikrovlnná oblast 1 mm-1m	Toto je nejdelší vlnová délka používaná v dálkovém snímání. Nejkratší vlnové délky v tomto rozsahu mají vlastnosti podobné termální infračervené oblasti. Hlavní předností tohoto spektra je schopnost projít přes oblaky.
Radiové vlny – (> 1m)	Toto je nejdelší část spektra používaná pro komerční vysílání a meteorologii.

(Knipling 1970; Dobrovolný 1998; Weir & Herring 2000; Aggarwal 2004; Halounová & Pavelka 2008; Rees 2012).

### 3.2.2 Historie dálkového průzkumu Země

V roce 1859 byl ve Francii pořízen snímek z balónu. Další zmínky o počátcích snímání z balónů pochází z období americké občanské války. Od roku 1909 byly pořizovány snímky z letadel, které byly následně využívány pro vojenské účely, inventarizaci využití půdy a publicitu. Fotografie tedy zůstává důležitou součástí aplikace dálkového snímání se sofistikovanými kamerami používanými pro sběr informací o geologii, využití půdy, zemědělských podmínkách, lesích, znečištění vody, přírodní katastrofy, územní plánování, sledování volně žijících živočichů a posouzení dopadů na životní prostředí (Liverman et al. 1998).

Světové války byly významnou etapou v historii dálkového průzkumu Země. Šlo zejména o snímání pro vojenské záměry a monitorování zemského povrchu. Později bylo této metody využíváno i v lesnictví a zemědělství (Dobrovolný 1998).

## Satelitní snímkování

V 50. letech dvacátého století začal probíhat v USA a také v Sovětském svazu vesmírný program. Americká družice Explorer pořídila úplně první snímek zemského povrchu z vesmíru. V roce 1957 vypustil Sovětský svaz tři družice Sputnik. Vypuštění těchto družic je považováno za prvopočátek DPZ z vesmíru (Halounová & Pavelka 2008). Následně NASA (National Aeronautics and Space Administration) vypustila do vesmíru několik dalších družic, které byly určeny pro program DPZ. První z nich měla za cíl sledovat povrch Země a získat geodetická data. Později byly do družic přidány elektrooptické senzory, které celý výzkum posunuly dopředu (Schott 2007).

V roce 1960 vypustila NASA do vesmíru družici TIROS (Television and Infra-Red Observation Satellite). Jednalo se o první meteorologickou družici. Projekt byl úspěšný a měl podporu politiků i veřejnosti. Díky této skutečnosti bylo v následujících pěti letech vypuštěno do vesmíru dalších 10 družic (National Research Council 2008). Díky následné spolupráci s NOAA (National Oceanic and Atmospheric Administration) byl tento projekt prodloužen. Experimentální satelit byl vybaven pokročilým radiometrem AVHRR (Advanced Very High Resolution Radiometer) s velmi vysokým rozlišením, který poskytuje denní a noční teploty oblaků a teplotu mořských hladin, stejně tak i sněhové podmínky a stav ledu. Tento satelit poprvé také nesl platformu pro sběr dat, která slouží k přijímání, zpracování a ukládání informací z volně plovoucích balónů a bójí po celém světě pro přenos do jednoho centrálního zpracovatelského zařízení (NASA 2016).

Během následujících let se družicové systémy zlepšovaly a jejich počet rostl s kvantem a kvalitou informací, které předávaly pomocí nejrůznějších zařízení a senzorů na jednotlivých družicích. S tímto rozmachem byl spojen i rozvoj vědních oborů, které využívaly data z DPZ pro analýzu a odhad vývoje ekosystému, meteorologie, geologie, rozvoj navigačních systémů (National Research Council 2008). Později byl DPZ využíván v zemědělství pro studium vegetace, pozorování stavu zemědělských plodin, zjišťování pravděpodobného výnosu, určování vlivu tvaru zemského povrchu na výnos plodin na konkrétním místě (Dominguez et al. 2015).

V roce 1972 byl zahájen program LANDSAT, v té době ještě známý jako ERTS (Earth Resource Technology Satellite). Byl to první satelit určený pro pozorování Země, který byl vypuštěn s cílem studovat a sledovat zemský povrch naší planety. Aby mohl toto pozorování provést, byl vybaven kamerovým systémem RBV (Return Beam Vidicon) a multispektrálním snímačem MSS (Multispectral Scanner). Poslední družice LANDSAT 8 byla vypuštěna v roce 2013 (NASAa 2020).

Program LANDSAT postupně následovaly další družicové systémy:

**Terra** – vypuštěna na oběžnou dráhu v roce 1999. Nese 5 senzorů pro sledování zemského povrchu – MODIS, ASTER, CERES, MISR, MOPITT (NASAc 2020).

**EO1** – družice vypuštěna v roce 2000. Je vybavena kamerou Hyperion pro snímání povrchu (ARCDATA 2020).

**RapidEye** – družice byla vypuštěna 2008. Je vybavena multispektrálním snímačem s vysokým rozlišením. Prostorové rozlišení dosahuje 5 m/pixel. Snímá v oblastech:

- Modré - 440-510 nm

- Zelené – 520-590 nm
- Červené – 630-685 nm
- Red-edge – 690-730 nm
- NIR – 760-850 nm (Geoimage 2020).

**Sentinel 1** – družice vypuštěna 2014. Je vybavena jednofrekvenčním senzorem a poskytuje radarová data s prostorovým rozlišením 5-40 m. Získaná data jsou snímána také při oblačnosti bez ohledu na denní dobu. Pracuje ve čtyřech různých módech:

- Strip map mode – rozlišení 5 m; šíře 80 km
- Interferometric mode – 5x20 m; 250 km
- Extra wide mode – 20x40 m; 400 km
- Wave mode – 5x5 m; 20x20 km (Copernicusb 2020).

**Sentinel 2** – vypuštěna 2015. Navazuje na LANDSAT a SPOT. Tato družice získává optická data a je vybavena multispektrálním senzorem, který pořizuje data s prostorovým rozlišením 10-60 m v závislosti na spektrálním pásmu. Senzor snímá data ve 13 pásmech v rozmezí 443-2190 nm:

- Viditelné spektrum (VIS) – 4
- Blízké infračervené (NIR) – 6
- Krátké infračervené (SWIR) – 3

Oproti Sentinel 1 ovlivňuje pořizování snímků oblačnost. Výhodou je kombinace jednotlivých spektrálních pásem, což je vhodné zejména pro sledování stavu vegetace, zjišťování vodního stresu atd. (Copernicusb 2020).

**WorldView 4** – vypuštěna na oběžnou dráhu v roce 2016. Družice je vybavena multispektrální kamerou s velmi vysokým rozlišením (31 cm v panchromatickém režimu a 1,24 m v multispektrálním).

Panchromatické 450-800 nm

Multispektrální:

- Modré – 450-510 nm
- Zelené – 510-580 nm
- Červené – 655-690 nm
- Blízké infračervené – 780-920 nm (Geoimage 2020).

## Letecké snímání

Při leteckém snímání jsou běžně využívány dva typy letounů. Tím tradičnějším je pilotovaný letoun, který může nést větší náklad, nabízí dostatečný zdroj elektrické energie, která je nezbytná pro fungování aktivních senzorů upevněných na letadle (Matese et al. 2015). Tyto člověkem pilotované letouny většinou operují ve výšce od 500 m – 8 km. V minulosti byl tento způsob sběru dat určen zejména pro systematické mapování zemského povrchu. V současnosti jejich využívání klesá, vzhledem ke zlepšujícím se výstupům dat ze satelitů a zvyšující se kapacitou a klesající cenou bezpilotních letounů (Tempfli et al. 2009). Hlavní nevýhodou tradičního letadla je nízká flexibilita a vysoké náklady (Matese et al. 2015). Přesto

klasické letecké snímkování stále zůstává důležitou platformou pro získávání dat v rámci dálkového průzkumu Země (Reddy 2008).

Bezpilotní letouny UAV (Unmanned aerial vehicle) jsou oproti družicím a letadlům relativně novou metodou. Nabízejí nejvyšší flexibilitu, nejnižší provozní náklady a umožňují získávání dat s nejvyšším rozlišením (Matese et al. 2015). Existují však i nevýhody spojené s používáním těchto platforem. Jejich použití je omezeno legislativně, pokud hrozí potenciální nebezpečí pro třetí stranu. Přestože dochází k neustálému vylepšování, je jejich nosnost a rozsah stále omezen. Do budoucna se bude jejich využívání stále zvyšovat v zemědělství, na ochranu životního prostředí a soukromými subjekty. Tato skutečnost může vést k získání kvalitnějších dat za rozumnou cenu (Puliti et al. 2015).

Bezpilotní prostředky – umožňují flexibilní použití i při nepříznivých klimatických podmínkách a zaručují nižší náklady (ve srovnání s leteckým snímkováním) pro získání informací o heterogenitě pozemku. Drony jsou využívány zejména k multispektrálnímu snímání a mapování pozemku. Výhody:

- Připraven během několika minut
- Lze zvolit a uložit letový plán – oblast a parametry snímkování
- Letový plán je možné použít kdykoliv v časových intervalech
- Při nízkých průletech je možné pořídít data s rozlišením až 1 cm/pixel
- Umožňuje získat přesný počet a rozmístění vegetace, plevelů a parazitů (Jamcopters 2020).



Obr. 4: Bezpilotní letouny v precizním zemědělství (Farm Management 2020).


### **Multispektrální kamery**

Údaje o zemském povrchu jsou zaznamenávány v několika spektrálních pásmech. Každé spektrální pásmo je možné znázornit odstíny šedi a díky kombinaci tří pásem nám vzniká barevná syntéza. Z jednotlivých snímků je možné následně vytvořit barevné syntézy díky optickým a elektronickým směšovačům. Při pořizování multispektrálních snímků, jsou odlišné intervaly vlnových délek zaznamenány do rozčleněných obrazových pásem. Dílčí intervaly vlnových délek se přibližně shodují s určitou barvou viditelného optického spektra nebo individuální částí neviditelné oblasti spektra. Ty přibližně odpovídají konkrétním



barvám viditelného optického spektra nebo některým zvoleným typickým částem neviditelné části spektra. Při spojení jednotlivých multispektrálních pásem pomocí tzv. RGB syntézy (červené (R) se zobrazí červeně, zelené pásmo (G) zeleně a modré pásmo (B) modře) je výsledkem obraz v přirozených barvách. Ten se podobá barvám, jak je vnímá lidský zrak (Plánka 2007; GISATa 2020).

Multispektrální senzory snímají vlnovou délku od 0,3-14  $\mu\text{m}$ , tedy spektrální oblasti – ultrafialovou, viditelnou, infračervenou a termální a získávají snímky v užším pásmu (Lillesand et al. 2015).



Obr. 5: Multispektrální snímek (Photonics 2020).

Pro vysvětlení multispektrální syntézy je potřeba znát spektrální odrazivost jednotlivé vegetace na sledovaném území. Pro interpretaci je používána (hloubka pixel) a týká se i té nejmenší změny v intenzitě záření, jakou umí rozlišit snímací systém (Jensen 2007).

Příklad:

- LANDSAT ETM+ - 7 pásem
- Quick Bird MS – 4 pásma
- WorldView 2 – 8 pásem

Časové rozlišení – četnost s jakou jsou pořizovány snímky stejného území.

- LANDSAT – 16 dnů
- Quick Bird – 1-3,5 dne
- NOAA – 6 hodin

Data s vysokým rozlišením – měření probíhá v řádu 10 m, v několika denních intervalech. Současně jsou pořizována multispektrální (MS) i panchromatická data (PAN) viz tab. 2. Následně jsou využívána pro mapování vegetace a zemědělských ploch.

Tabulka č. 2: Pořizování dat s vysokým rozlišením

Družice	Rozlišení (m)		Počet pásem	Velikost oblasti (km)	Start
	PAN	MS			
LANDSAT 7	15	30	7	180x180	1999
SPOT 5	2,5-5	10	4	60x60	2002
ASTER	-	15-90	14	60x60	1999

(GISATb 2020; NASAb 2020)

Data s velmi vysokým rozlišením – rozlišení v řádu 1 m, jsou pořizována MS a PAN data (někdy pouze PAN) viz tab. 3. Nejmodernější družice vhodné pro kontrolu zemědělských aktivit, mapování rozptýlené vegetace, půdní eroze.

Tabulka č. 3: Pořizování dat s velmi vysokým rozlišením

Družice	Rozlišení (m)		Počet pásem	Velikost oblasti (km)	Start
	PAN	MS			
IKONOS	1	4	4	11x11	1999
Quick Bird	0,6	2,4	4	16x16	2001
WorldView 1	0,5	-	-	17,5x14	2007
WorldView 2	-	0,46	8	17,5x14	2009

(Geoimage 2020; GISATb 2020; SIC 2020)


Multispektrální kamery jsou v současnosti nejčastěji používaným typem senzorů. Jejich výhodou je delší historie (ve srovnání s hyperspektrálními), což je spojeno se stávajícími zkušenostmi s využíváním těchto snímků v různých oborech. Multispektrální data jsou často využívána v dálkovém průzkumu Země, vzhledem k jejich informační hodnotě a široké dostupnosti (Jensen 2007). Multispektrální mají nižší prostorové rozlišení oproti snímkům panchromatickým. Výhodou jejich pořizování je snížení množství přenášených dat z družice na Zemi (GISATa 2020).

### Hyperspektrální kamery

Hyperspektrální snímkování neboli obrazová spektroskopie využívá technologie DPZ a fyzikálního oboru spektroskopie. Díky DPZ jsou získávána data bez přímého kontaktu

s objektem, kdežto spektroskopie se opírá o vzájemné působení elektromagnetického záření se vzorkem (Hladíková 2012; Smith 2012). Hyperspektrální data ve srovnání s multispektrálními, snímají až stovky spektrálních pásem. Takové číslo umožňuje studovat fyzické a chemické vlastnosti povrchu téměř jako v laboratoři. Jejich dostupnost je v současnosti výrazně horší než dostupnost dat multispektrálních (Tempfli et al. 2009). Jak uvádí Málková (2010) výzkum v oblasti DPZ se v posledních desetiletích zaměřil hlavně na vývoj hyperspektrálních technologií oproti multispektrálním obrazovým datům. Jedná se spíše o skenery, jelikož povrch je snímán po řádcích. Tento přístroj může být nesen družicí, letadlem nebo jako pozemní spektrometr pro získávání dat při terénním šetření (Málková 2010). Smith (2012) upozorňuje na skutečnost, že rozdíl mezi hyperspektrálním a multispektrálním snímáním je založen na počtu a šířce spektrálních pásem použitých na sběr dat.

Hyperspektrální senzory umí získat spektrální křivku pro každý jednotlivý bod snímku. Což znamená, že každý pixel může být znázorněn jako průřez přes všechna spektrální pásma a tak může být využit pro detailní popis sledovaného objektu (Smith 2012). Spektrum pro jeden pixel v hyperspektrálním obrazci vypadá velmi podobně jako měřené ve spektroskopické laboratoři. Tento typ podrobného spektra pixelů poskytuje mnohem více informací o povrchu než multispektrální spektrum pixelů (Shippert 2003).



Obr. 6: Hyperspektrální obraz získaný ze zeleného listu. A – jednotlivé části obrazu tvořící 3D hyperspektrální kostku, B – odražené spektrum jednotlivých pixel (Mishra et al. 2017).

Hyperspektrální senzory:

- Družicové – Hyperion, MODIS, FTHSI
- Letecké – AVIRIS, CASI, AISA, HyMap
- Pozemní – SpecTIR, FieldSpec

Hyperion – je umístěn na družici EO-1, která byla vypuštěna na oběžnou dráhu v roce 2000. Tento senzor dokáže snímat až 242 spektrálních pásem se spektrálním rozlišením 357-2579 nm a prostorovým rozlišením 30 m. Principem je snímání dat pomocí dvou

spektrometrů. Jeden v krátkém infračerveném spektru a druhý ve viditelném. Je dobře využitelný v geologii, lesnictví a zemědělství (ARCDATA 2020).

ASTER – Advanced Spaceborn Emission and Reflection Radiometer je nesen družicí Terra. Tento senzor snímá data ze 14 spektrálních pásem viz tab. 4.

Tabulka č. 4: Spektrální pásma snímaná senzorem ASTER

Oblasti spektra	Počet spektrálních pásem
VNIR (Visible Near Infrared)	3
SWIR (Short Wave Infrared)	6
TIR (Thermal Infrared)	5

(NASAb 2020)

MODIS – Moderate resolution Imaging Spectroradiometer je umístěn na dvou družicích Terra (1999) a Aqua (2002). Dokáže snímat ve 36 spektrálních pásmech a zahrnuje vlnové délky od 0,4-14,4  $\mu\text{m}$  viz tab. 5.

Tabulka č. 5: Spektrální pásma snímaná senzorem MODIS

Počet Pásem	Rozlišení
2	250 m
5	500 m
29	1000 m

(NASAc 2020)

AISA – Airborne Imaging Spectroradiometer for Applications byl vyroben v roce 1992 a je určen pro letecké snímání. Tento přístroj pracuje v rozsahu vlnových délek 450-900 nm, který je rozdělen do 286 kanálů. Počet prostorových pixel je 384 (Makisara et al. 1993).

AVIRIS – Airborne Visible Infrared Imaging Spectrometer byl navržen pro NASA v roce 1983 jako první zobrazovací systém určený pro získávání dat z jednotlivých úzkých spektrálních pásem napříč elektromagnetickým spektrem v rozmezí od 0,4-2,5  $\mu\text{m}$  a snímá 224 pásem. Šířka jednoho pásma je 10 nm. V zemědělství se uplatňuje zejména při sledování vodního stresu plodin, zdravotního stavu vegetace, zjišťování kvality a množství úrody (Vane et al. 1993).

HyMAP – poskytuje data ze 100-200 spektrálních pásem ve spektrálním rozlišení 0,45-2,5  $\mu\text{m}$  a prostorovým rozlišením 2-10 m. Používá se zejména pro geologické aplikace, ale má své uplatnění také v zemědělství pro detekci zaplevelení, chorob a škůdců (Cocks et al. 1998).

Podle Zemka et al. (2014) patří mezi nejpoužívanější skenery v dnešní době HyMAP, Hyperion, AVIRIS, MODIS. Data získávána z těchto senzorů jsou dostupnější než dříve. Postupným technologickým pokrokem se podařilo snížit jejich hmotnost, což umožňuje jejich využití na některých bezpilotních letounech UAV (Unmanned Aerial Vehicle) – Micro Hyperspec nebo PIKA.

### 3.2.3 Spektrální vlastnosti vegetace

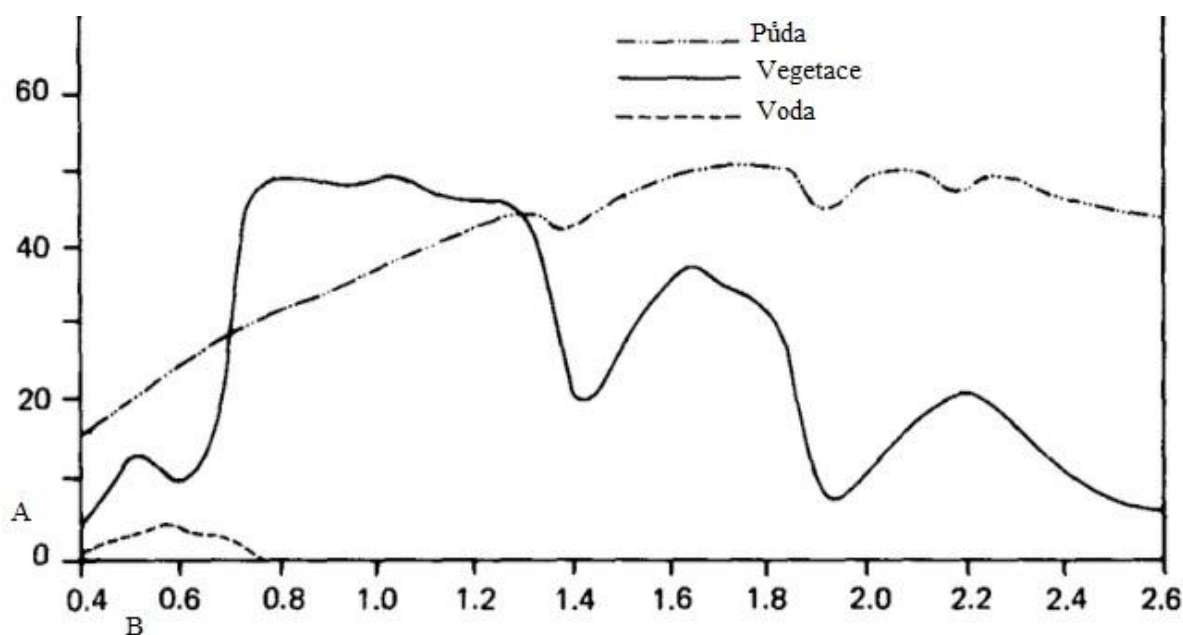
Sluneční záření, které dopadá na pozorovaný objekt je přímo závislé na momentálních podmínkách atmosféry a na úhlu dopadajícího paprsku. Dopadající světlo je jiné při zvýšené oblačnosti než při jasné obloze. Atmosféra pohlcuje určité vlnové délky, což ovlivňuje využití jednotlivých druhů záření. Základem DPZ je skutečnost, že v různých vlnových délkách odrážejí nebo vyzařují objekty různé množství záření. Toto určité záření je spektrálním „podpisem“ konkrétních povrchů. Odrazivost od živé vegetace závisí na obsahu vody, chlorofylu, buněčné struktuře a struktuře rostlin (Budd 1991). Záření je také ovlivňováno při průchodu atmosférou, proto je důležité využívat atmosférické korekce (Rees 1999). Pokud tedy chceme získat relevantní hodnoty odrazivosti a zjistit vegetační indexy, musíme tuto korekci použít. To je nutné zejména pro porovnání jednotlivých dat, aby nedocházelo k rozdílným výsledkům (Hadjimitsis et al. 2010).

Spektrální vlastnosti vegetace je možné popsat díky odrazovým rysům povrchu ve vazbě na druh látky, fyzikální vlastnosti a na vlnovou délku. U vegetace to lze objasnit pomocí odrazů od zelené hmoty, tedy nejčastěji listů. Spektrální křivka vegetace je rozčleněna do tří zón. V první zóně se pigmentová absorpce objevuje ve vlnových délkách 0,4-0,7  $\mu\text{m}$ . Vzhledem k přítomnosti chlorofylu jsou zde pohlcovány červené a modré části spektra, což způsobuje zelené zbarvení listů (Dobrovolný 1998).

Nejvyšší hodnoty odrazivosti jsou v blízké infračervené části spektra. Každá plodina či plevel však záření odráží jiným způsobem. Záleží na vlastnostech dané rostliny, jež jsou specifické a lze tedy rozlišit jednotlivé druhy či rozpoznat zdravou vegetaci od nezdravé. U vegetace můžeme rozlišit tři oblasti spektrální odrazivosti (Halounová & Pavelka 2008).

Jedná se o: pigmentační absorpci, buněčnou strukturu a vodní absorpci.

- **Pigmentační absorpce** – absorpce viditelného záření 0,4-0,7  $\mu\text{m}$ . Odrazivost je malá vzhledem k obsahu chlorofylu, který pohlcuje modré a červené části spektra. Rostliny odrážejí jen 10% záření v zelené části spektra, což je ovšem více než v modré nebo červené části. Proto vidíme vegetaci zeleně (Knipling 1970).
- **Buněčná struktura** – vlnová délka 0,72-1,3  $\mu\text{m}$ . Buňky celulózy nepohlcují tolik záření a tím pádem zde dochází ke zvýšení odrazivosti vegetace. Index lomu stavebních buněk listu je 1,4, proto dosahuje mnohem většího odrazu uvnitř listu a zesílení odrazivosti záření. Díky své typické stavbě uvnitř listu a různým hodnotám odrazivosti, je možné rozpoznávat jednotlivé druhy plodin a plevelů (Halounová & Pavelka 2008). Pro rozpoznávání stavu vegetace, zvláště obsahu chlorofylu v rostlinném krytu, jsou vhodná právě tato pásma (Frampton et al. 2013).
- **Vodní absorpce** – ve vlnových délkách 1,3-3  $\mu\text{m}$ . Infračervené záření je pohlcováno vodou obsaženou v buněčných strukturách. Odrazivost je závislá na množství vody. Čím větší je podíl vody, tím je absorpce větší a odrazivost se zmenšuje. Toto pomáhá určit vodní stres vegetace (Rees 2012). V hodnotách vlnových délek 1,6-2,2  $\mu\text{m}$  je reflektivita listů nepřímo úměrná obsahu vody (Frampton et al. 2013).



Obr. 7: Spektrální křivky půdy, vegetace a vody. A – Odrazivost (%), B – Vlnová délka ( $\mu\text{m}$ ) (Lillesand et al. 2015)

### 3.3 Vegetační indexy

Pro práci s poznatky získanými z DPZ, byl důležitý rozvoj vegetačních indexů (VI). S těmito indexy se v oblasti studia vegetace pracuje už od roku 1972. Jde zejména o jejich využití s LANDSAT a prvními senzory AVHRR po roce 1978 (Jones & Vaughan 2010). V současnosti se rozlišuje až 150 vegetačních indexů. Každý z nich poskytuje rozlišné informace o vegetaci. Všechny indexy ale testovány nebyly. Systematicky bylo testováno 27 vegetačních indexů s biofyzikálním základem. Vegetační indexy a jejich výpočet dokážou účinně zhodnotit stav vegetace, kterou sledujeme. Tato metoda patří mezi šetrné a úsporné systémy analýzy. Výsledky těchto měření mají zásadní význam pro plánování a organizaci zásahů na zemědělském pozemku. Jde o soubor aritmetických operací, které díky využití více spektrálních pásem dokážou zdůraznit například množství organické hmoty v jednom pixel (HARRIS 2020).

V oblasti aplikací dálkového průzkumu Země vyvinuli vědci vegetační indexy pro potřeby kvalitativního a kvantitativního hodnocení vegetačního pokryvu spektrálním měřením. Spektrální měření představuje komplexní směs vegetace, barvy půdy, stavu životního prostředí, stínu a vlhkosti. VI jsou ovlivněny momentálními změnami atmosféry (Bannari et al. 1995). Jak uvádí Jackson & Huete (1991), index by měl být citlivý na vegetační pokryv, necitlivý k jasu půdy, k barvě půdy a být pouze částečně ovlivněn atmosférickými účinky, účinky na životní prostředí, dopad slunečního záření a stavu senzorů (Jackson et al. 1983).

První vývojová fáze indexů byla založena na lineárních kombinacích (rozdíl nebo součet) nebo na poměrech surového pásma, bez přihlídnutí k dalším vnějším faktorům, kde se

nepřehlíželo k interakci mezi půdou a vegetací. Ve druhé koncepční fázi se vědci zaměřili na fyzické jevy, které vysvětlují interakci mezi elektromagnetickým zářením, atmosférou, vegetačním pokryvem a půdou. K získání ideálního VI je nutné znát všechny faktory, které tyto indexy ovlivňují (Bannari et al 1995).

V roce 1972 vytvořili Pearson a Miller první dva vegetační indexy RVI (Ratio Vegetation Index) a VIN (Vegetation Index Number). Oba pro odhad a monitorování vegetace.

- $RVI = R/NIR$       R – střední odrazivost v červené oblasti
- $VIN = NIR/R$       NIR – střední odrazivost v blízké infračervené oblasti

Tyto indexy zvětšují kontrast mezi povrchem a vegetací. Jsou méně ovlivněny vlivem podmínek osvětlení, ale jsou citlivé na optické vlastnosti povrchu. RVI index je citlivý na vliv atmosféry a pokud je vegetační pokryv méně hustý (méně než 50%) je jeho rozlišovací schopnost slabší (Pearson & Miller 1972).

Pásma:

- NIR (near- infrared) – blízké infračervené záření
- Red – červené spektrum viditelného záření
- Green – zelené spektrum viditelného záření
- Blue – modré spektrum viditelného záření

### 3.3.1 Širokopásmové vegetační indexy

V této skupině se nachází vegetační indexy, jež slouží jako ukazatele obsahu a hodnoty fotosyntetizujícího materiálu. Slouží jako elementární metoda vhodná pro určování biomasy a životaschopnosti vegetace. Dochází zde ke srovnání odrazivosti vegetace v blízkém infračerveném spektrálním pásmu a červeném viditelném pásmu. Indexy této skupiny slouží zejména k určování listové plochy, růstových fází, vlivu klimatických změn a k zachycení využití půdy. Výpočty z tohoto dosti širokého spektra pomáhají odhalit fyziologický stres rostlin – tedy stresové projevy a výživový stav rostlin, pomocí dat získaných z multispektrálních sensorů, jako je AVHRR nebo LANDSAT TM (Gitelson & Merzlyak 1998).

#### **DVI – Difference Vegetation Index**

Jedná se o jednoduchý index citlivý na množství vegetace. Umí rozpoznat půdu od vegetace, ale ne na zastíněných místech. Nedává přesnou informaci, pokud jsou odražené vlnové délky ovlivněny topografií, atmosférou nebo stínem.

$$DVI = R_{800}/R_{670}$$


R = odrazivost v dané vlnové délce ( $\mu\text{m}$ )  
(Akkartal et al. 2004).

## NDVI - Normalized Difference Vegetation Index

Tento index poprvé použil Rouse et al. (1973).

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

Pracuje s viditelným a blízkým infračerveným zářením, které se odráží od zemského povrchu zpět do vesmíru. Pigment v listech (chlorofyl) silně absorbuje viditelné světlo od 0,4 – 0,7  $\mu\text{m}$ . Naopak buněčná struktura listů odráží blízké infračervené světlo od 0,7 – 1,1  $\mu\text{m}$ . Čím více listů rostlina má, tím více jsou vlnové délky světla ovlivněny. Pokud je rozdíl v intenzitě viditelných a blízkých infračervených vlnových délek, je vegetace zřejmě řidší. Zdravá vegetace absorbuje větší část viditelného spektra a odráží většinu infračerveného světla. Vegetace nepříliš hustá nebo nezdravá odráží viditelné světlo a méně blízké infračervené světlo. Hodnoty se pohybují v rozmezí od -1 do 1. Hodnoty blízké nule znamenají nízkou intenzitu vegetačního pokryvu (Weier & Herring 2000). Záporné hodnoty znamenají vyšší odraz v oblasti viditelného spektra, než v oblasti infračerveného. U satelitů může být příčinou zvýšená oblačnost, sníh či led (Hadjimitsis et al. 2010). Vzhledem ke změnám na vegetaci způsobených jednotlivými fenologickými fázemi během roku, je rozdílná také detekce plodin či plevelů pomocí indexu NDVI. Metání u obilnin snižuje odrazivost, jelikož květenství částečně kryje listovou plochu. Na konci kvetení se hodnoty zvyšují a tento trend pokračuje až do fáze stáří (Dominguez et al. 2015).



Obr. 8: Odraz světla (Weier & Herring 2000).



Štych et al. (2015) uvádí, že měření s využitím indexů NDVI má své limity. Jedná se zejména o fakt, že nezahrnuje strukturu půdy, odrazivost půdy a obsah chlorofylu. Tyto skutečnosti mohou výsledky velmi ovlivnit, zejména při nízké hustotě vegetace.

Citlivost tohoto indexu na atmosférické účinky zvýšila potřebu vyvinout nové indexy, které jsou méně citlivé. Jako je třeba index SAVI, upravený pro půdu (Hadjimitsis et al. 2010).

### **GNDVI – Green Normalized Difference Vegetation Index**

$$\text{GNDVI} = (\text{NIR} - \text{Green}) / (\text{NIR} + \text{Green})$$

Počítá se podobně jako NDVI. Červená oblast spektra je zde ovšem nahrazena oblastí zelenou, pohybující se ve vlnových délkách od 0,54 – 0,57  $\mu\text{m}$ . Tento vegetační index je díky tomuto malému rozdílu citlivější na obsah chlorofylu než zmiňovaný NDVI. Díky tomu je možné lépe rozpoznat obsah chlorofylu ve vegetaci a lépe odhadnout koncentraci pigmentu v listech rostlin (Gitelson et al. 1996).

### **SAVI – Soil Adjusted Vegetation Index**

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

Tento index se snaží snižovat působení jasu půdy pomocí korekčního faktoru. Často se využívá v suchých oblastech, kde je řídký pokryv půdy. U tohoto indexu je potřeba zadat množství vegetačního krytu:

- 1 – oblast bez pokryvu
- 0,5 – oblast se střední hodnotou množství zeleného vegetačního pokryvu
- 0 – oblast s vysokým pokryvem (Huete 1988).

### **MSAVI – Modified Soil Adjusted Vegetation Index**

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

U tohoto indexu je konstanta L v SAVI nahrazena funkcí L. Zvyšuje dynamický rozsah vegetačního signálu a současně minimalizuje vlivy na pozadí půdy, což vede k větší citlivosti vegetace (Qia et al. 1994).

### **TSARVI – Transformed Soil Atmospherically Resistant Vegetation Index**

$$\text{TSARVI} = \frac{[a_{rb}(\text{NIR} - a_{rb}\text{RB} - b_{rb})]}{[(\text{RB} + a_{rb}\text{NIR} - a_{rb}b_{rb} + X(1 + a_{rb}^2))]}$$

Tato nová forma indexu TSAVI vykazuje zanedbatelnou citlivost na holou půdu a její barvu (-<sup>+</sup> 2 %) a je přesnější než TSAVI. Využívá červeno-modré spektrum místo červeného (Bannari et al. 1995).

### **EVI – Enhanced Vegetation Index**

$$EVI = G \times \frac{(NIR - RED)}{(NIR + C1 \times RED - C2 \times Blue + L)}$$

Tento vegetační index vytvořili, Huete et al. (2002) pro senzor MODIS (Moderate Resolution Imaging Spectroradiometer), který je nesen na satelitech Terra a Aqua. EVI dokáže redukovat atmosférické vlivy začleněním odrazivosti v modrém spektrálním pásmu. Je citlivější na topografické podmínky než index NDVI a proto Matsushita et al. (2007) doporučuje při počítání s tímto indexem tuto skutečnost zohlednit. Postupným vylepšováním se tento index stal oblíbeným mezi vědci pro sledování fotosyntetických vegetačních aktivit. Přestože tento VI dokáže snížit vliv environmentálních faktorů, jako jsou atmosférické podmínky a půda, nedokáže snížit topografický efekt, což je jeden z velmi důležitých faktorů – zejména v horských oblastech.

### **EVI2 – 2band Enhanced Vegetation Index**

$$EVI2 = 2,5 * ((NIR-Red) / (NIR + 2,4 * červený + 1))$$

Pro zajištění rozeznání výsledků mezi senzory bez zaznamenané odrazivosti v modré části spektra, byl index EVI upraven na verzi EVI2, která počítá s červeným a blízké infračerveným pásmem. Přestože tento VI nepočítá s modrým pásmem, má funkční vlastnosti původního indexu EVI a díky tomu je dobře využitelný u multispektrálních senzorů. Důležitý pro tento index je i vývoj v oblasti atmosférických korekcí, díky kterým je snížena jeho senzitivita na aerosol (Jiang et al. 2008; Trnka et al. 2018).

Tento vegetační index může být použit pro senzory bez modrého pásma, jako je například AVHRR (Advanced Very High Resolution Radiometer). Tento VI také dokáže odhalit odlišný stav vegetace, tedy její dynamiku (Jiang et al. 2008).

### **3.3.2 Úzkopásmové vegetační indexy**

Úzkopásmové indexy jsou určeny k měření signálu ze specifických vlnových délek. Jsou k dispozici pouze v případě, že senzor snímá pásma, která spadají do přijatelného rozsahu vlnových délek. Fungují podobně jako starší širokopásmové indexy, ale s tím rozdílem, že rozpětí hodnot odrazivosti je v rovnicích těchto indexů upřesněno, aby se využily detaily citlivosti v hyperspektrálních datech. Tyto indexy určují množství chlorofylu, velikost listové plochy a využívají spektrum blízké infračervené oblasti (Red Edge) s vlnovými

délkami 690-740 nm. Jsou citlivější na menší změny, a to zvláště v místě s hustou vegetací (Datt & Paterson 2000). Všechny následující vegetační indexy jsou využívány v precizním zemědělství.

### **MCARI2 – Modified Chlorophyll Absorption Ratio Index – Improved**

$$MCARI2 = \frac{1.5[2.5(\rho_{800} - \rho_{670}) - 1.3(\rho_{800} - \rho_{550})]}{\sqrt{(2 * \rho_{800} + 1)^2 - (6 * \rho_{800} - 5 * \sqrt{\rho_{670}}) - 0.5}}$$

$\rho_{550}$  (540-560 nm),  $\rho_{670}$  (650-690 nm),  $\rho_{800}$  780-865 (nm)

Tento vegetační index je modifikací indexu MCARI ale je lepším prediktorem indexu listové plochy. Zahrnuje faktor úpravy půdy při zachování citlivosti na listovou plochu a odolnosti vůči vlivu chlorofylu.

(Haboudane et al. 2004)

### **MRENDVI – Modified Red Edge Normalized Difference Vegetation Index**

$$MRENDVI = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705} - 2 * \rho_{445}}$$

$\rho_{445}$  (435-448 nm),  $\rho_{705}$  (697-708 nm),  $\rho_{750}$  (730-760 nm)

Jedná se o modifikaci indexu NDVI Red Edge, která koriguje zrcadlový odraz listů. Je citlivý na jakékoliv množství listů, mezery a stáří vegetace. Je vhodný pro precizní zemědělství, monitorování lesů a detekci stresu vegetace.

(Datt 1999; Sims & Gamon 2002)

### **MRESR – Modified Red Edge Simple Ratio**

$$MRESR = \frac{\rho_{750} - \rho_{445}}{\rho_{705} - \rho_{445}}$$

$\rho_{445}$  (435-448 nm),  $\rho_{705}$  (697-708 nm),  $\rho_{750}$  (730-760 nm)

Tento index je modifikací jednoduchého indexu SR. Používá pásma v červeném okraji spektra a zahrnuje korekci pro zrcadlový odraz listů.

(Datt 1999; Sims & Gamon 2002)

### **MTVI – Modified Triangular Vegetation Index**

$$MTVI = 1.2[1.2(\rho_{800} - \rho_{550}) - 2.5(\rho_{670} - \rho_{550})]$$

$\rho_{550}$  (540-560 nm),  $\rho_{670}$  (650-690 nm),  $\rho_{800}$  (780-865 nm)

Díky modifikaci indexu TVI, je tento index vhodný pro odhad listové plochy nahrazením vlnové délky 750 nm vlnovou délkou 800 nm, jejíž odrazivost je ovlivněna změnami ve struktuře listů a porostu.

(Haboudane et al. 2004)

### **MTVI2 – Modified Triangular Vegetation Index - Improved**

$$MTVI2 = \frac{1.5[1.2(\rho_{800} - \rho_{550}) - 2.5(\rho_{670} - \rho_{550})]}{\sqrt{(2 * \rho_{800} + 1)^2 - (6 * \rho_{800} - 5 * \sqrt{\rho_{670}}) - 0.5}}$$

$\rho_{550}$  (540-560 nm),  $\rho_{670}$  (650-690 nm),  $\rho_{800}$  (780-865 nm)

Podobný indexu MTVI, ale je považován za vhodnějšího prediktora zelené listové plochy.

(Haboudane et al. 2004)

### **RENDVI – Red Edge Normalized Difference Vegetation Index**

$$RENDVI = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705}}$$

$\rho_{705}$  (697-708 nm),  $\rho_{750}$  (730-760 nm)

Jedná se o upravený NDVI index. Liší se použitím vlnových délek podél červeného okraje spektra, místo hlavních vrcholů absorpce a odrazivosti.

(Gitelson & Merzlyak 1994)

### **TCARI – Transformed Chlorophyll Absorption Reflectance Index**

$$TCARI = 3 \left[ (\rho_{700} - \rho_{670}) - 0.2(\rho_{700} - \rho_{550}) \left( \frac{\rho_{700}}{\rho_{670}} \right) \right]$$

$\rho_{550}$  (540-560 nm),  $\rho_{670}$  (650-690 nm),  $\rho_{700}$  (680-730 nm)

Tento index znázorňuje relativní množství chlorofylu. Je ovlivněn základní odrazivostí půdy, zejména u vegetace s malou listovou plochou.

(Haboudane et al. 2004)

## VREI1 – Vogelmann Red Edge Index 1

$$VREI1 = \frac{\rho_{740}}{\rho_{720}}$$

$\rho_{720}$  (718-722 nm),  $\rho_{740}$  (730-750 nm)

Toto úzkopásmové měření odrazivosti je citlivé na kombinaci účinku množství chlorofylu, listové plochy a obsahu vody. Jeho aplikace zahrnuje pozorování stáří vegetace, precizní zemědělství a modelování produktivity vegetace.

(Vogelmann et al. 1993)

## VREI2 – Vogelmann Red Edge Index 2

$$VREI2 = \frac{\rho_{734} - \rho_{747}}{\rho_{715} + \rho_{726}}$$

$\rho_{715}$  (714-715 nm),  $\rho_{726}$  (723-727 nm),  $\rho_{734}$  (730-736 nm),  $\rho_{747}$  (742-748 nm)

(Vogelmann et al. 1993)

### 3.4 Využití dálkového průzkumu pro detekci plevelů

#### 3.4.1 Letecké a satelitní snímkování plevelů

De Castro et al. (2013) zkoumali možnost využití multispektrálního vysoko-prostorového rozlišení snímků ze satelitního systému Quick Bird k detekci brukvovitých plevelů na polích ozimé pšenice. V současné studii byl proveden výzkum na šesti polích (rozloha polí byla mezi 3-52 ha) ve Španělsku a na segmentovaném snímku Quick Bird pšenice ozimé. Pro vyhodnocení mapování plevelů v terénu byly použity dvě metody – klasifikátor maximální pravděpodobnosti (MLC) a vegetační indexy. Poté byly vybrány nejlepší hodnotící metody, aby mohly být vyvinuty specifické mapy pro danou oblast. Analýza ukázala, že ohniska plevelů byla rozlišena, jak v malém tak velkém měřítku. Vzhledem k rozsáhlému výzkumu byla přesnost klasifikace 91,3-89,45% za použití MLC a modrozelených (3B/G) vegetačních indexů. Získané mapy ukázaly, že je vysoký potenciál ke snížení použití herbicidů během sezony. Použitím cíleného ošetření mohlo být ušetřeno až 61,31% herbicidu na místech neošetřovaných a 13,02% na místech s nízkým použitím herbicidů (De Castro et al. 2013).

Garcia-Ruiz et al. (2015) ve svém výzkumu zkoumali vysoké rozlišení cukrové řepy a pcháče rolního. Výzkum probíhal na univerzitním pozemku v Dánsku o rozloze 0,4 ha, které bylo oseto cukrovou řepou a přirozeně zapleveleno pcháčem rolním. V letech 2011 a 2012 proběhlo celkem pět měření, při kterých byly získány vzorky spektrálních vlastností cukrové

řepy a pcháče rolního. Při měření měla cukrová řepa 4-10 pravých listů a odpovídající vývojové stadium pcháče rolního mělo v té době od 5-14 pravých listů. Světelné podmínky při všech pěti měřeních se výrazně lišily. Při prvních čtyřech měřeních byla nulová oblačnost a měření začaly ve 12 SELČ. Poslední páté měření začalo při zvýšené oblačnosti v 17 SELČ. Po předběžném zpracování odrazivosti vykazovaly oba druhy jasně viditelné rozdíly v zelené oblasti (520-570 nm) a v červené REIP oblasti (600-740 nm), přičemž vzorky z jedné třídy měly kladné hodnoty a z druhé třídy záporné. Výrazné rozdíly byly také rozpoznány v oblasti red edge a to (690-740).

Vzorky byly získány přenosným spektrometrem v polních podmínkách. Byly vyvinuty klasifikační modely částečné analýzy nejmenších čtverců PLS-DA (Partial Least Squares Discriminant Analysis) s 211 a 36 spektrálními charakteristikami šířky pásma 1,56 a 10 nm. Míra klasifikace získaná pomocí těchto modelů byla považována za maximálně dosažitelnou. Poté byly porosty snímkovány pomocí multispektrální kamery, která byla vybavena konfigurací filtru navrženého na základě klasifikačního modelu. Nakonec byla provedena simulace rozpoznání plevelů a plodin pomocí malého bezpilotního letounu vybaveného multispektrální kamerou miniMCA-6. Ověření založené na leteckých snímcích ukázalo, že cukrová řepa a pcháč rolní by mohli být rozpoznány na snímcích, kdyby bylo k dispozici dostatečné množství čistých pixel obsahujících listová spektra. Při měření bylo rozpoznáno 95% pcháče rolního a 89% cukrové řepy. Přesnost rozpoznání klesla na 93% u pcháče a na 84% u řepy, když byly použity pouze čtyři nejlepší spektrální pásma (Garcia-Ruiz et al 2015).

Garcia-Ruiz et al (2015) došli k závěru, že klasifikace cukrové řepy a pcháče rolního lze získat ze snímků založených na UAV pomocí čtyř spektrálních pásem v rozsahu VIS, pokud se podaří ze snímků získat dostatečně spektrálně čisté pixely cukrové řepy a pcháče rolního. Toho lze dosáhnout při prostorovém rozlišení snímků 6 mm/pixel nebo vyšším.

López-Granados et al. (2006) zkoumali použití dálkového průzkumu pro rozpoznání travovitých plevelů v pšenici v pozdějším období. Výzkum probíhal od podzimu 2002 do léta 2003 v Santa Cruz v Andalusii na pozemku o rozloze 25,6 ha. Data byla sbírána každé dva týdny, za použití pozemního spektrometru ASD HandHeld FieldSpec, aby byla získána data všech vývojových stádií. Rozdíly odrazu mezi pšenicí bez plevelů a ovšem hluchým, chrasticí kanárskou a jíllem byly statisticky významné ve většině vlnových pásem o šířce 25 nm ve spektru 400-900 nm, hlavně kvůli jejich rozdílnému zrání.

Přesné a včasné mapování rozložení plevelů je klíčovým prvkem pro dosažení pouze lokální aplikace herbicidů. Dálkové snímání může být užitečným nástrojem pro mapování plevelů a jeho zamoření, ale pouze v pozdějším vývojovém stádiu. Toto lze spíše použít k předpovědi, kde by měl být v následujícím roce více nasměrován postřik herbicidů, aby byla zasažena ohniska plevelů na počátku vegetace. Nerovnoměrné rozšíření ovsa hluchého v pšenici je možné stabilizovat během 5 letého období. Je také nutné zohlednit, že jakýkoliv snímek ukazuje spektrální charakteristiku vegetace v okamžiku pořízení a že se mění s časem (López-Granados et al. 2006).

### 3.4.1 Pozemní senzorové systémy k detekci zaplevelení

Dálkový průzkum je považován za velice efektivní techniku pro rozpoznávání plevelů (Thorp & Tian 2004; López-Granados et al. 2006; Peña-Barragán et al. 2007). Metody DPZ a leteckého snímání jsou ale závislé na oblačnosti. Toto je hlavním omezením vzhledem k relativně krátkému časovému oknu vhodnému pro detekování plevelů a následné včasné ošetření. Pokud se přidá ještě skutečnost, že chvíli trvá než se pořízené snímky a data zpracují, může to způsobit nežádoucí zpoždění při aplikaci herbicidů (Lamb et al. 1999).

Přestože přímá měření nejsou součástí DPZ jako takového, je to přesto užitečná a často nutná metoda pro získávání výsledků. Toto pozemní snímání je v mnoha případech kombinováno s DPZ – například pro kalibraci senzoru, stanovení atmosférických parametrů, měření přesného umístění pozorovaného objektu a pro kalibraci pozemních kontrolních bodů (Smith & Atkinson 2001). Často je také nutné doplnit údaje nebo zlepšit přesnost informace získané metodami dálkového průzkumu Země. Dalším příkladem potřeby přímých měření je tvorba tréninkových dat. Ty slouží k nalezení algoritmů potřebných pro identifikaci předmětu zájmu a pro ověření výsledné analýzy. V neposlední řadě může přímé měření ověřit a doplnit výsledky DPZ, které odrážejí pouze stav vegetace v okamžiku měření (Mishra et al. 2017).

Data z družic pokrývají rozsáhlejší území, ale s nižší přesností. Nevýhodou se jeví i stáří snímku, což je způsobeno přeletem družic nad danou oblastí. Vzhledem k malému rozlišení rostlin pořízených ze satelitů a leteckého snímání, používá proto řada vědců pozemní kamerové systémy pro následné zpracování množství a druhu plevelů (Thorp & Tian 2004).

Pozemní senzory namontované na strojích nabízejí hodně předností pro detekování plevelů. Tyto systémy jsou relativně nezávislé na environmentálních podmínkách. Mohou být použity v reálném čase nebo krátce před ošetřením herbicidem a mohou omezit hustotu zaplevelení (Gerhards & Oebel 2006; Slaughter et al. 2008).

**Hsensor** – tento senzor je určen pro detekci zaplevelení a dokáže rozlišit plodinu od plevelů. Kamerový systém může být upevněn přímo na rámu postřikovače. Přístroj dokáže vytvářet mapu zaplevelení a ve stejném okamžiku provést aplikaci herbicidů. Jelikož je vybaven vlastním zdrojem světla, není závislý na okolních podmínkách a dokáže zachytit snímky při rychlosti stroje až 12 km/h (Brant et al. 2020).



Obr. 9: Hsensor (Agricon 2020).

**GreenSeeker Handheld Crop Sensor** – tento optický senzor je určen pro pozemní měření indexu NDVI, zejména ke snímání biomasy a určení množství živin, stav plodin, výnos, vodní stres a dopad chorob a škůdců na porost. Jedná se o bodové měření vybrané vegetace. Tento snímač vysílá paprsky v červeném, infračerveném spektru, ty se odráží od vegetace a jsou následně zaznamenány prostřednictvím fotodiod umístěných na senzoru (Debuisson et al. 2010).



Obr. 10: GreenSeeker senzor (Trimble 2020).

**Trimble WeedSeeker** – optický senzor nové generace, který slouží pro variabilní dávkování hnojiv a k cílené aplikaci pesticidů. Je určen pro cílené bodové ničení plevelů. Tento systém dokáže pomocí pokročilé optiky a výkonu zpracování, detekovat a eliminovat odolné plevely. Když se plevel objeví pod senzorem, ten vyšle signál připojené rozprašovací trysce a následně dojde k aplikaci přípravku na ochranu rostlin. Tímto způsobem je možné výrazně snížit množství chemických vstupů. Přístroj je vybaven inteligentním senzorem, který nepoužije herbicid na místě, kde již aplikován byl a upraví načasování postřiku během otáčení. Tento senzor provádí sám kalibraci – tedy upraví změnu okolních podmínek jako je teplota, osvětlení a povrch (Trimble 2020).





Obr. 11: WeedSeeker (Trimble 2020).

**FieldSpec4** – univerzální spektrometr vhodný pro mnoho aplikací, které měří odrazivost, propustnost, záření nebo ozáření. Tento přístroj má pevný optický kabel, který umožňuje jeho kalibraci. Je speciálně navržen pro snímání v terénu a získává data z VNIR (viditelné a blízké infračervené spektrum) a SWIR (krátké infračervené spektrum). Nástroj je kompaktní, přenosný a přesný přístroj se spektrálním rozsahem 350-2500 nm a rychlým sběrem dat 0,2 sekundy na spektrum (ASD 2016).



Obr. 12: FieldSpec4 (ASD 2016).

## 4 Metodika

Pomocí přenosného spektrometru byla analyzována spektrální odrazivost vybraných plodin a plevelů v různých růstových fázích. Byla identifikována spektrální pásma, která jsou charakteristická pro jednotlivé rostlinné druhy a jejich růstové fáze. Byly navrženy algoritmy vhodné pro rozpoznání jednotlivých rostlinných druhů. Spektrální měření probíhala během jarních a letních měsíců prvního ročníku studia. V podzimním období byla data zpracována a analyzována. Prosinec až červen druhého ročníku byl vyhrazen pro kompletaci diplomové práce.

### Sběr dat

Za účelem nalezení spektrálních rozdílů bylo uskutečněno měření spektrální odrazivosti zelí a čtyř druhů plevelů, které se v porostu zelí často vyskytují.

Pro měření byl použit spektrometr ASD Fieldspec 4 (Malvern Pananalytical, USA) s měřicím rozsahem 350 - 2500 nm. 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.

Rostliny zelí byly předpěstovány v nádobách o velikosti 8 x 8 x 8 cm do fáze BBCH 14-15. Rostliny plevelů byly získány přímo v porostech zeleniny. Měření bylo provedeno na třetím až šestém pravém listu. Listy byly bezprostředně před měřením odděleny od rostlin. Kontaktní sonda byla náhodně přiložena na horní stranu listu a po ustálení křivky bylo zaznamenáno měření. V případě ježatky kuří nohy bylo měření provedeno vždy na dvou vedle sebe umístěných listech tak, aby bylo vždy celé snímané pole vyplněno listovou plochou. Počet provedených měření je uveden v tabulce 6.

Tabulka č. 6: Počty provedených spektrálních měření pro jednotlivé druhy rostlin

Český název druhu	Vědecký název druhu	počet spekter			
		celkem	použité	trénovací skutečné	testovací skutečné
bažanka roční	<i>Mercurialis annua</i> L.	273	220	132	73
ježatka kuří noha	<i>Echinochloa crus-galli</i> (L.) B.P.	213	213	128	71
laskavec ohnutý	<i>Amaranthus retroflexus</i> L.	219	219	131	73
merlík bílý	<i>Chenopodium album</i> L.	220	220	132	73
zelí bílé (hybrid Oklahoma)	<i>Brassica oleracea convar. capitata var. alba</i> (hybrid Oklahoma)	541	220	132	73

Před započítáním analýzy dat byl korigován nesoulad hodnot z jednotlivých měřicích senzorů pomocí parabolické korekce (Hueni & Bialek 2017).

Ze získaných dat byla náhodně vybrána měření jednotlivých rostlinných druhů tak, aby každý druh byl reprezentován přibližně stejným počtem měření. Takto vybraná data byla rozdělena na trénovací a validační podíl. Počty měření použitých k analýze jsou uvedeny v tabulce 6. Spektrální data byla nejprve vizuálně zhodnocena a byla identifikována spektrální pásma vykazující odlišné hodnoty pro jednotlivé druhy rostlin. Hodnoty odrazivosti v jednotlivých spektrálních pásmech byly vypočteny jako průměr hodnot měření zastoupených v příslušném rozsahu vlnových délek.

Pomocí analýzy hlavních komponent (PCA, Principal Component Analysis) byla identifikována relevantní spektrální pásma vhodná pro diskriminaci jednotlivých rostlinných druhů. PCA je základní metodou používanou pro extrakci proměnných – tedy k dekorelaci dat. Používá se před hodnocením dat jako nástroj pro snížení počtu proměnných s co nejmenší ztrátou informace. Cílem je hlavně zjednodušení popisu skupiny vzájemně lineárně závislých (korelovaných) znaků. Je to metoda lineární přeměny původních znaků na nové, nekorelované proměnné – tedy hlavní komponenty. Jednotlivá komponenta zobrazuje lineární kombinaci původních znaků a její primární charakteristikou je rozptyl, tedy míra variability. Komponenty jsou řazeny podle významu, což znamená podle klesajícího rozptylu – od největšího k nejmenšímu (Sebera 2012). Kromě toho je možné stanovit míru korelace mezi hlavními komponentami a původními proměnnými (tj. hodnotami odrazivosti pro jednotlivá spektrální pásma) a posoudit tak, které proměnné nejvíce přispívají k variabilitě dat.

Pro klasifikaci dat na základě vybraných spektrálních pásem byla použita lineární diskriminační analýza (LDA). Diskriminační analýza je metoda vícenásobné statistické analýzy, ve které jde o nalezení proměnných diskriminujících mezi předem určenými skupinami objektů a rozdělení daných objektů do rozlišitelných skupin. Hlavním úkolem je určit, které znaky jsou významné pro zařazení do jednotlivých skupin, a které už méně. Další úlohou je vytvořit podle sledovaných znaků pravidla, která by každý nový objekt jednoznačně zařadila do jedné ze skupin. Zároveň je potřeba, aby pravděpodobnost špatného zařazení byla co nejnižší. Jednotlivé odlišnosti v datech jsou vysvětleny pomocí klasifikačních rovnic, které slouží k rozčlenění objektů do skupin pomocí vybraných proměnných, které zobrazují vlastnosti objektu. Proměnné mají kvantitativní charakter a očekává se jejich rozdělení v jednotlivých skupinách (Hodásová 2011).

Výsledky klasifikace byly vyjádřeny celkovou přesností klasifikace a chybovou maticí, senzitivitou a specificitou. Celková přesnost klasifikace je definována jako podíl úhrnu všech měření klasifikovaných správně. Chybová matice vyjadřuje počty případů (měření) zatříděných do skupin pomocí klasifikátoru (LDA) oproti skutečné příslušnosti případu ke třídám. Senzitivita je pro jednotlivé klasifikační třídy (v tomto případě rostlinné druhy) vyjádřena jako:

$$\frac{SP}{SP + FN}$$

Kde SP (skutečně pozitivní) je počet případů skutečně spadajících do určité třídy a FN (falešně negativní) je počet případů této třídy chybně zařazených do jiné třídy.

Specificita je pro jednotlivé klasifikační třídy vyjádřena jako:

$$\frac{SN}{TN + FP}$$

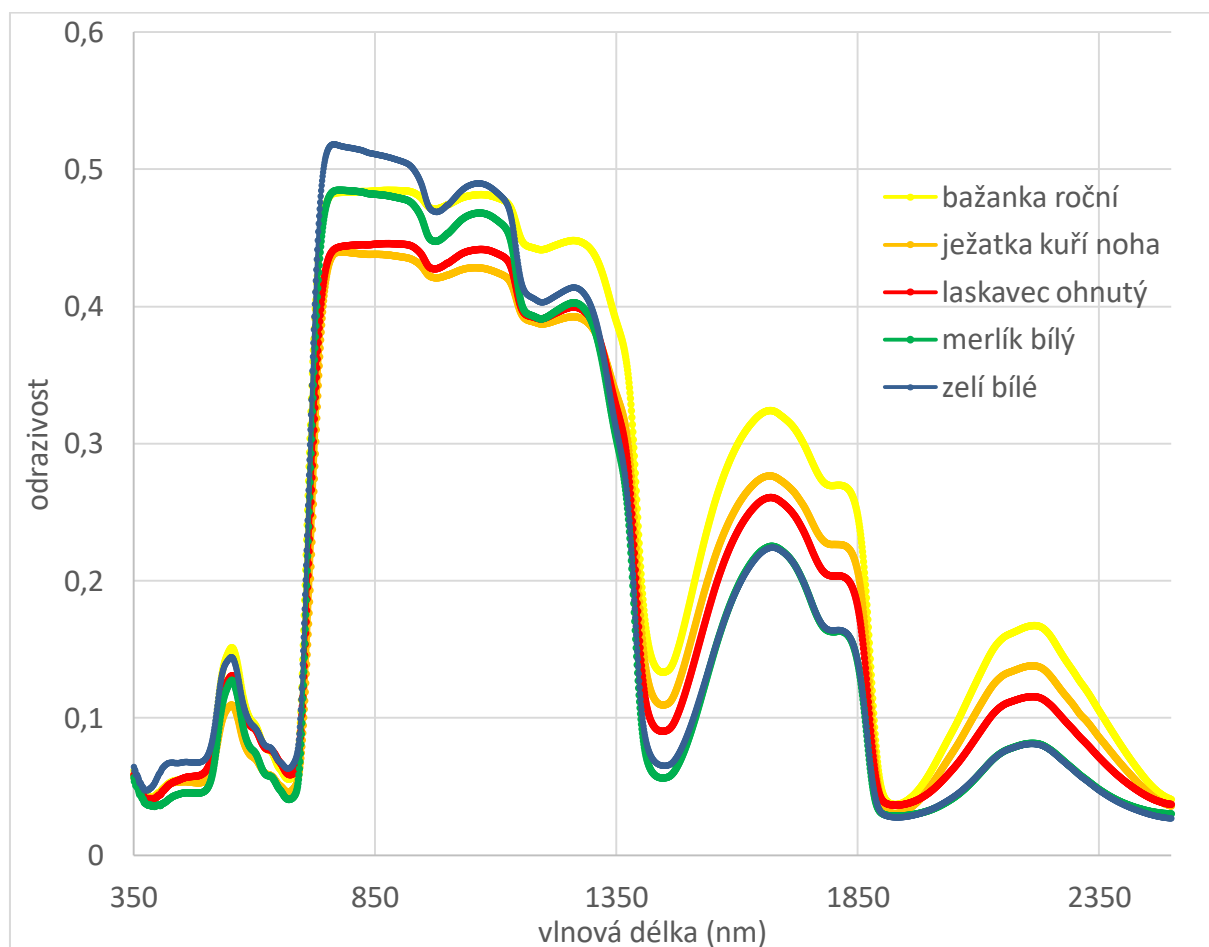
Kde SN (skutečně negativní) je počet všech případů skutečně nespádajících do dané třídy a FP (falešně pozitivní) je počet případů chybně zařazených do dané třídy.

Všechny statistické analýzy byly provedeny pomocí statistického programu R s využitím balíků ggbiplot, rattle, car, MASS a caret.

## 5 Výsledky

### Základní výběr spektrálních pásem

Pro porovnání rozdílů v průběhu spektrální odrazivosti mezi jednotlivými druhy plevelů byly vypočteny aritmetické průměry hodnot odrazivosti v jednotlivých vlnových délkách. Křivky průměrné odrazivosti pro jednotlivé druhy jsou znázorněny v grafu 1. Z grafu 1 je patrné, že největší rozdíly lze nalézt v oblasti NIR (700-1200 nm) a dále potom ve viditelném spektru a pásmu 1400 – 1800 nm.



Graf 1: Porovnání průměrných hodnot odrazivosti pro jednotlivé rostlinné druhy

Na základě těchto spektrálních křivek byla vybrána úzká spektrální pásma, která vykazují rozdíly v odrazivosti a mohla by potenciálně přispět k diskriminaci mezi jednotlivými rostlinnými druhy (Tabulka 7).

Tabulka 7: Spektrální pásma vybraná pro diskriminaci rostlinných druhů na základě vizuálního hodnocení spektrálních křivek.


Spektrální pásmo	Rozsah vlnových délek (nm)
1	365 -385
2	400 - 420
3	540 -560
4	665 - 685
5	710-720
6	770 - 790
7	900 - 920
8	970 - 990
9	1055 -1075
10	1190 - 1210
11	1370 - 1380
12	1440 - 1460
13	1665 - 1685
14	1920 - 1940
15	2210 - 2230

### **Analýza hlavních komponent**

Pomocí analýzy hlavních komponent byla nejprve pro trénovací sadu dat kvantifikována významnost jednotlivých komponent. Základní statistické informace o hlavních komponentách jsou shrnuty v tabulce 8. Podíl variance vyjadřuje, kolik procent celkového rozptylu je vyčerpáno pomocí jednotlivých komponent. V tomto případě první hlavní komponenta vysvětluje 41,38 % a druhá hlavní komponenta dalších 32,7 % celkové variability. Kumulativní podíl variance udává součet příspěvku jednotlivých os k celkové varianci. Z výsledků je patrné, že k vyčerpání alespoň 95 % variability je třeba prvních pěti hlavních komponent (kumulativní podíl 97,33 %). Ostatní hlavní komponenty přispívají k popisu variability zanedbatelnou měrou. V grafu 2 je vyjádřena pozice každého měření vzhledem k první a druhé hlavní komponentě a dále příspěvek jednotlivých proměnných (tj. spektrálních pásem) k prvním dvěma komponentám. Je patrná separace jednotlivých rostlinných druhů s určitými vzájemnými překryvy, zejména v případě laskavce ohnutého a ježatky kuří nohy. Naopak spektrální odezvu zelí lze velmi dobře rozlišit od jednotlivých plevelů. K první hlavní komponentě přispívají zejména pásma v kratších vlnových délkách, zatímco spektrální pásma s vlnovými délkami nad 1200 nm se vztahují zejména k druhé hlavní komponentě.

Tabulka 8: Významnost hlavních komponent

Komponenty	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10
Směrodatná odchylka	2,4915	2,2148	1,4748	0,9134	0,6910	0,4959	0,2681	0,2202	0,1368	0,0964
Podíl variance	0,4138	0,3270	0,1450	0,0556	0,0318	0,0164	0,0048	0,0032	0,0013	0,0006
Kumulativní podíl variance	0,4138	0,7409	0,8859	0,9415	0,9733	0,9897	0,9945	0,9977	0,9910	0,9996



Graf 2: Grafické znázornění prvních dvou hlavních komponent (vysvětlivky ke zkratkám: b – bažanka roční, j – ježatka kuří noha, l – laskavec ohnutý, m – merlík bílý, z – zelí)

Hodnoty zátěží (tabulka č. 9) udávají míru korelace původních proměnných s hlavními komponentami. Z dat je patrné, že spektrální pásma o kratších vlnových délkách významně korelují převážně s první a třetí a čtvrtou hlavní komponentou, pásma větších vlnových délek potom korelují zejména s druhou hlavní komponentou. Všechna vybraná spektrální pásma se tedy podílí dostatečnou měrou na variabilitě dat a je vhodné je použít jako proměnné pro diskriminační analýzu.

Tabulka 9: Tabulka zátěží pro původní proměnné vzhledem k hlavním komponentám

Spektrální pásmo (nm)	Hlavní komponenty									
	PC 1	PC 2	PC 3	PC 4	PC 5	PC 6	PC 7	PC 8	PC 9	PC 10
365-385	-0,204	-0,001	0,510	-0,263	0,074	0,661	-0,326	-0,028	-0,274	-0,055
400-420	-0,239	0,063	0,480	-0,304	0,228	0,139	0,371	0,161	0,590	-0,017
540-560	-0,309	-0,034	0,154	0,588	0,298	0,025	-0,115	-0,626	0,179	-0,001
665-685	-0,257	-0,008	0,455	0,018	-0,225	0,669	-0,217	0,092	-0,386	-0,115
710-720	-0,330	0,061	-0,062	0,533	0,248	0,157	0,095	0,698	-0,123	-0,000
770-790	-0,346	0,182	-0,168	-0,152	-0,033	0,057	0,359	-0,131	-0,073	-0,670
900-920	-0,359	0,141	-0,188	-0,132	-0,108	0,025	0,169	-0,134	-0,109	-0,016
970-990	-0,372	0,011	-0,227	-0,155	-0,100	0,000	-0,045	-0,037	0,048	0,098
1055-1075	-0,367	0,092	-0,210	-0,099	-0,162	0,018	-0,033	-0,070	-0,010	0,563
1190-1210	-0,305	-0,237	-0,233	-0,131	-0,070	0,041	-0,381	0,087	0,200	0,093
1370-1380	-0,092	-0,428	-0,098	-0,125	0,125	0,089	-0,131	0,122	0,102	-0,226
1440-1460	-0,024	-0,441	0,045	-0,056	0,164	0,023	0,461	-0,098	-0,443	0,186
1665-1685	-0,066	-0,437	-0,094	-0,072	0,117	0,021	-0,238	0,060	0,186	-0,256
1920-1940	-0,054	-0,323	0,201	0,301	-0,777	0,235	0,222	0,024	0,225	-0,038
2210-2230	-0,012	-0,446	-0,020	-0,045	0,167	0,029	0,215	-0,089	-0,135	0,128



## Lineární diskriminační analýza

Lineární diskriminační analýza nejprve vypočte průměrné hodnoty proměnných (spektrálních pásem) pro jednotlivé skupiny (rostlinné druhy). Tyto průměry jsou uvedeny v tabulce 10. Dále jsou vypočteny koeficienty lineárních diskriminantů (LD), které jsou lineární kombinací predikčních proměnných použitých pro diskriminační analýzu (tabulka 11).

Tabulka č. 10: Průměrné hodnoty proměnných (spektrálních pásem) pro jednotlivé třídy

Spektrální pásmo (Vlnová délka v nm)	Druh				
	bažanka roční	ježatka kuří noha	laskavec ohnutý	merlík bílý	zelí
365-385	0,043	0,043	0,043	0,039	0,048
400-420	0,046	0,048	0,047	0,038	0,063
540-560	0,148	0,108	0,129	0,124	0,143
665-685	0,057	0,047	0,060	0,0420	0,065
710-720	0,302	0,194	0,240	0,270	0,300
770-790	0,483	0,440	0,443	0,485	0,518
900-920	0,484	0,437	0,445	0,478	0,506
970-990	0,472	0,422	0,428	0,448	0,470
1055-1075	0,482	0,430	0,441	0,468	0,490
1190-1210	0,442	0,389	0,392	0,391	0,404
1370-1380	0,346	0,297	0,280	0,242	0,251
1440-1460	0,133	0,110	0,092	0,056	0,065
1665-1685	0,323	0,276	0,261	0,223	0,224
1920-1940	0,037	0,030	0,037	0,029	0,028
2210-2230	0,166	0,137	0,116	0,080	0,081

Tabulka č. 11: Vypočtené koeficienty lineárních diskriminantů (LD)

Vlnová délka	LD1	LD2	LD3	LD4
365-385	-242,971	213,619	-248,806	-213,796
400-420	360,064	-307,604	330,361	133,760
540-560	-160,698	-84,561	-70,507	19,515
665-685	-159,675	132,102	54,866	95,305
710-720	137,578	96,442	31,083	-0,686
770-790	92,985	-142,187	-81,907	-209,104
900-920	-314,378	133,213	127,179	316,848
970-990	626,081	-591,164	-67,378	48,9703
1055-1075	-277,064	304,649	-32,692	-295,738
1190-1210	-62,107	385,886	92,084	150,224
1370-1380	-73,728	-33,810	-4,445	-28,294
1440-1460	125,185	39,116	102,083	63,722
1665-1685	3,307	-107,724	-78,989	45,154
1920-1940	171,705	-101,053	-258,663	141,137
2210-2230	-170,008	63,559	60,913	-191,699

Dalším krokem je vlastní klasifikace trénovačích dat, tedy přiřazení jednotlivých měření k definovaným třídám (zde rostlinným druhům). Správnost zařazení je následně ověřena porovnáním se skutečnou příslušností jednotlivých měření ke třídám a úspěšnost klasifikace je vyjádřena chybovou maticí. Z chybové matice (tabulka 12) je patrné, že v případě trénovačích dat byla většina měřených objektů přiřazena pomocí lineární diskriminační analýzy zcela bezchybně k rostlinným druhům, pouze dva listy laskavce ohnutého byly chybně klasifikovány jako bažanka roční.

Tabulka 12: Chybová matice pro trénovací data

Druh		Skutečný				
		bažanka	ježatka	laskavec	merlík	zelí
Predikovaný	bažanka	147	0	2	0	0
	ježatka	0	142	0	0	0
	laskavec	0	0	144	0	0
	merlík	0	0	0	146	0
	zelí	0	0	0	0	147

Za účelem ověření kvality klasifikačního algoritmu byla shodná klasifikace poté aplikována na validační data, která pro tvorbu algoritmu nebyla využita. Rovněž v případě validačních dat bylo dosaženo velmi vysoké přesnosti klasifikace (99,45 %). Chybová matice pro validační data (tabulka 13) ukazuje, že většina měřených objektů byla pomocí lineární diskriminační analýzy přiřazena zcela bezchybně k rostlinným druhům, pouze jedno měření laskavce ohnutého a jedno měření ježatky kuří noha byly chybně klasifikovány jako bažanka roční. Tomu odpovídají vysoké hodnoty dalších sledovaných parametrů. Senzitivita i specificita byla u všech klasifikačních tříd vyšší než 0,98 a korigovaná přesnost klasifikace byla pro všechny třídy vyšší než 0,99 (viz tabulka 14).

Tabulka 13: Chybová matice pro validační data

Druh		Skutečný				
		bažanka	ježatka	laskavec	merlík	zelí
Predikovaný	bažanka	73	1	1	0	0
	ježatka	0	70	0	0	0
	laskavec	0	0	72	0	0
	merlík	0	0	0	73	0
	zelí	0	0	0	0	73

Tabulka 14: Senzitivita a specificita pro validační data

	bažanka	ježatka	laskavec	merlík	zelí
Senzitivita	1,0000	0,9859	0,9863	1,0000	1,0000
Specificita	0,9931	1,0000	0,9966	1,0000	1,0000
Podíl třídy	0,2011	0,1956	0,2011	0,2011	0,2011
Korigovaná přesnost klasifikace	0,9966	0,9930	0,9932	1,0000	1,0000

## 6 Diskuze

Ve své práci jsem se zaměřila na spektrální klasifikaci zelí (hybrid Oklahoma) a plevelů (bažanka roční, ježatka kuří noha, laskavec ohnutý, merlík bílý), které se v porostu zelí často vyskytují. Rostliny zelí byly vypěstovány v nádobách a plevele byly získány přímo v porostech zeleniny. Při měření byl použit přenosný spektrometr ASD Fieldspec s integrovaným zdrojem světla. Podobný experiment provedli Deng et al. (2016), kteří rovněž srovnávali spektrální vlastnosti zelí a plevelů, skladba plevelového spektra byla však odlišná (ježatka, bér, kalužnice, rosička, merlík čilský). V jejich studii byl použit podobný spektrometr, avšak bez vlastního zdroje světla, což mohlo snížit přesnost měření ve spektrálních oblastech odpovídajících absorpčním pásmům vody.

Spektrální data byla nejprve vizuálně zhodnocena a byla identifikována spektrální pásma vykazující odlišné hodnoty pro jednotlivé druhy rostlin. Podobně jako Deng et al. (2016) jsem i já použila analýzu hlavních komponent pro ověření vhodnosti výběru vlnových délek. Největší rozdíly lze nalézt v oblasti NIR (700-1200 nm) a dále potom ve viditelném spektru a pásmu 1400 – 1800 nm. Deng et al. (2016) stanovili charakteristické vlnové délky pro jejich práci – 567, 667, 715, 745, 1345, 1402, 1545, 1725, 1925 nm.

Pomocí lineární diskriminační analýzy byla většina rostlin přiřazena zcela bezchybně k rostlinným druhům, pouze dva listy laskavce ohnutého byly chybně klasifikovány jako bažanka roční. V případě validačních dat bylo dosaženo velmi vysoké přesnosti klasifikace (99,45 %). Naproti tomu u Deng et al. (2016) byla správnost výsledků v tréninkové sadě 90,7 % a správnost ve validační sadě byla 84,3 %. Jelikož byly použity dva druhy zelí, zvýšila se tím chybovost. Po zařazení obou druhů zelí do jedné skupiny vzrostla správnost v tréninkové sadě na 95 % a ve validační na 100 %.

Prezentované výsledky mé práce nelze zcela zobecnit, jelikož v případě hlávkového zelí byla měřena jen jedna odrůda. Na základě jiných studií lze předpokládat, že jednotlivé odrůdy zelí budou vykazovat mírné odlišnosti v průběhu spektrální křivky. Použití vytvořeného klasifikátoru pro jiné odrůdy zelí by mohlo vést k nižší přesnosti klasifikace. Pro spolehlivou diskriminaci je tedy vhodné znát spektrální charakteristiku konkrétní odrůdy nebo hybridu.

Aplikace chemických látek je citlivým ekologickým tématem a stále častěji je kladen důraz na co nejpresnější aplikaci herbicidních látek. Nalezené spektrální rozdíly by bylo možné použít k přesnému odhalení výskytu plevelů v porostech bílého zelí v rámci cíleného postřiku. Značný potenciál v tomto směru představují zejména hyperspektrální kamery, které umožňují kvantifikovat odrazivost objektů v úzkých spektrálních pásmech. Před samotným postřikem by mohl být pozemek nasnímován – například pomocí bezpilotního letounu a následně by mohla být vytvořena aplikační mapa. Další možností je umístění kamer přímo na rámu postřikovače. To by umožnilo vytvářet mapu a provést aplikaci herbicidů současně s detekcí zaplevelení.

Je zřejmé, že diskriminaci na základě úzkopásmových rozdílů bude možné uplatnit i pro celou řadu dalších plodin. Např. Vrindts et al. (2002) měřili spektrální vlastnosti cukrové řepy, kukuřice a plevelů (bažanka roční, pcháč rolní, merlík bílý, ptačinec prostřední, rdesno červinec, lilek černý, heřmánek pravý). Pomocí diskriminační analýzy byla cukrová řepa

rozpoznána v 94 % případů a plevele v 94 % případů při použití pouze 11 vybraných vlnových délek (814,6; 801,4; 753; 713,5; 698,1; 522,1; 761,8; 603,5; 764; 537,5; 579,3). Při rozpoznání kukuřice od plevelu bylo použito 8 vybraných vlnových délek (700,3; 511,1; 592,5; 484,4; 495,8; 671,7; 687,1; 605,7) a přesnost klasifikace byla u kukuřice 84 % a u plevelu 95 %.

Další výzkum ukazuje rozpoznání spektrální odezvy plevelů (sveřep stoklasa, jílek mnohokvětý) v porostu pšenice ozimé. Měření probíhalo s přenosným optickým spektrometrem SD 2000, který snímá viditelné a blízké infračervené spektrum 350-1000 nm s rozlišením 1 nm. Spektrální hodnoty byly měřeny v intervalu 1 nm a zprůměrovány do šířky pásma 10 nm pro vlnové délky 400-865 nm. Byla použita diskriminační analýza s kombinací pásem 515/675, 555/675, 805/815 nm a správnost klasifikace dosáhla 94 %. Při měření pšenice v růstové fázi Feekes 3 (3-5 výhonků na podzim) byla úspěšnost rozpoznání 94 %. U pšenice ve fázi Feekes 5 (rostliny vzpřímené, ale bod růstu je stále pod povrchem) byla úspěšnost (s kombinací vlnových délek 755 a 855/675 nm) pouze 66,7 %. V několika případech byl jílek klasifikován jako sveřep nebo jako pšenice. Sveřep byl několikrát hodnocen jako jílek, ale nikdy jako pšenice. Tato studie ukázala, že je možné identifikovat sveřep v pšenici v šířce pásma 10 nm a ve vlnových délkách od 500-860 nm (Girma et al. 2005).

Spolehlivou detekcí zaplevelení v porostech plodin by bylo možné výrazně snížit množství chemických vstupů – přesto nejsou v současné zemědělské praxi systémy pro rozpoznání plevelu běžně využívány. Hlavní nevýhody v současné době vidím zejména v časové náročnosti spojené se sběrem dat a vysokými pořizovacími náklady na přístroje, které by byly schopné v praxi detekovat plodiny od plevelu. Je možné předpokládat, že v budoucnu bude docházet k poklesu cen detekčních systémů a také k nárůstu jejich spolehlivosti. Kromě toho lze očekávat určitá legislativní opatření, která budou vyžadovat cílený přístup farmářů k jednotlivým pozemkům a jejím částem. To v budoucnu pravděpodobně povede k rychlejšímu prosazení různých detekčních systémů a dalších technologií precizního zemědělství do praxe.

## 7 Závěr

Cílem práce bylo analyzovat spektrální vlastnosti bílého hlávkového zelí a vybraných plevelů a identifikovat takové spektrální rozdíly, které bude možno využít pro rozlišení jednotlivých rostlinných druhů v porostech zelí při cílené regulaci zaplevelení v systému precizního zemědělství.

Na základě podrobných spektrálních křivek bylo vybráno 15 úzkých spektrálních pásem potenciálně využitelných pro odlišení plevelů od plodiny. Pro získání relevantních výsledků byla použita analýza komponent a následně lineární diskriminační analýza. Analýza hlavních komponent prokázala, že všechny zvolené vlnové délky se dostatečně podílí na variabilitě dat a jsou vhodné jako proměnné pro diskriminační analýzu. K první, třetí a čtvrté hlavní komponentě přispívají zejména pásma v kratších vlnových délkách, zatímco spektrální pásma s vlnovými délkami nad 1200 nm se vztahují zejména k druhé hlavní komponentě.

Chybová matice pro validační data ukázala, že většina měřených objektů byla pomocí lineární diskriminační analýzy přiřazena zcela bezchybně k rostlinným druhům, pouze jedno měření laskavce ohnutého a jedno měření ježatky kuří nohy byly chybně klasifikovány jako bažanka roční. Tomu odpovídají vysoké hodnoty dalších sledovaných parametrů. Senzitivita i specificita byla u všech klasifikačních tříd vyšší než 0,98 a korigovaná přesnost klasifikace byla pro všechny třídy vyšší než 0,99.

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. Při využití detekce zaplevelení s následnou cílenou aplikací herbicidů by došlo k výraznému snížení aplikace herbicidních přípravků, což by vedlo ke snížení ekonomických nákladů na chemické ošetření plodin a tím ke zlepšení ochrany životního prostředí a zvýšení bezpečnosti potravin.

## 8 Seznam literatury

Aggarwal S. 2004. Principles of remote sensing. Page 23-28 in Sivakumar MVK, Roy PS, Harmsen K, Saha SK, editors. Satellite remote sensing and GIS applications in agricultural meteorology. World Meteorological Organisation, Geneva.

Akkartal A, Türüdü O, Erbek FS. 2004. Analysis of changes in vegetation biomass using multisensor satellite data. Page 181-185 in Altan O, editor. Proceedings of the ISPRS Congress-Youth Forum, Istanbul.

Bannari A, Morin D, Huette AR, Bonn F. 1995. A review of vegetation indices. Remote Sensing Reviews **13**:95–120.

Brant V, et al. 2020. Implementace principů precizního zemědělství do rostlinné výroby. Kurent. České Budějovice.

Budd JTC. 1991. Remote sensing techniques for monitoring land-cover. Page 33-60 in Goldsmith B, editor. Monitoring for Conservation and Ecology. Chapman & Hall, London.

Clay D, Shanahan JF. 2011. GIS Applications in agriculture: Nutrient management for energy efficiency. CRC Press. Boca Raton.

Cocks T, Jenssen R, Stewart A, Wilson I, Shields T. 1998. The HyMAP airborne hyperspectral sensors: The system, calibration and performance. Page 37-42 in Schaepman M, Schlöpfer D, Itten KI, editors. Presented at 1st EARSEL Workshop on Imaging Spectroscopy, Zurich.

Daberkow SG, McBride WD. 1998. Socioeconomic profiles of early adopters of precision agriculture technologies. Journal of Agribusiness **16**:151–168.

Datt B. 1999. A new reflectance index for remote sensing of chlorophyll content in higher plants: Tests using Eucalyptus leaves. Journal of Plant Physiology **154**:30-36.

Datt B, Paterson M. 2000. Vegetation-soil spectral mixture analysis. Page 1936-1938 in IEEE International Geoscience and Remote Sensing Symposium, Honolulu.

Debuisson S, Germain C, Garcia O, Panigai L, Moncomble D. 2010. Using multiplex and GreenseekerTM to manage spatial variation of vine vigor in Champagne. Page 15 in Stafford J, Schepers J, editors. 10th International Conference on Precision Agriculture, Denver.

De Castro AI, López-Granados F, Jurado-Expósito M. 2013. Broad-scale cruciferous weed patch classification in winter wheat using QuickBird imagery for in-season site-specific control. Precision Agriculture **14**:392-413.

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.

Dobrovolný P. 1998. *Dálkový průzkum Země. Digitální zpracování obrazu*. Masarykova univerzita, Brno.

Dominguez JA, Kumhálová J, Novák P. 2015. Winter oilseed rape and winter wheat growth prediction using remote sensing methods. *Plant Soil and Environment* **61**:410-416.

Frampton WJ, Dash J, Watmough G, Milton EJ. 2013. Evaluating the capabilities of Sentinel – 2 for quantitative estimation of biophysical variables in vegetation. *ISPRS Journal of Photogrammetry and Remote Sensing* **82**:83-92.

Garcia-Ruiz FJ, Wulfsohn D, Rasmussen J. 2015. Sugar beet (*Beta vulgaris* L.) and thistle (*Cirsium arvensis* L.) discrimination based on field spectral data. *Biosystems Engineering* **139**:1-15.

Gerhards R, Oebel H. 2006. Practical experiences with a system for site-specific weed control in arable crops using real-time image analysis and GPS-controlled patch spraying. *Weed Research* **46**:185-193.

Girma K, Mosali J, Raun WR, Freeman KW, Martin KL, Solie JB, Stone ML. 2005. Identification of optical spectral signature for detecting cheat and ryegrass in winter wheat. *Crop Science* **45**:477-485.

Gitelson AA, Merzlyak MN. 1994. Spectral reflectance changes associated with autumn senescence of *Aesculus Hippocastanum* L. and *Acer Platanoides* L. leaves. *Journal of Plant Physiology* **143**:286-292.

Gitelson AA, Kaufman YJ, Merzlyak MN. 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment* **58**:289-298.

Gitelson AA, Merzlyak MN. 1998. Remote sensing of chlorophyll concentration in higher plant leaves. *Advances in Space Research* **22**: 689-692.

Groffman P. 1997. Ecological constraints on precision agriculture: Precision agriculture: spatial and temporal variability of environmental quality. Page 52-64 in Lake JV, Bock G, Goode J, editors. *Ciba Foundation symposium*, New York.

Haboudane D, Miller JR, Pattey E, Zarco-Tejada PJ, Strachan IB. 2004. Hyperspectral Vegetation Indices and Novel Algorithms for Predicting Green LAI of Crop Canopies: Modeling and Validation in the Context of Precision Agriculture. *Remote Sensing of Environment* **90**:337-352.



Hadjimitsis DG, Papadavid G, Agapiou A, Themistocleous K, Hadjimitsis MG, Retalis A, Michaelides S, Chrysoulakis N, Toullos L, Clayton CRI. 2010. Atmospheric correction for satellite remotely sensed data intended for agricultural applications: impact on vegetation indices. *Natural Hazards and Earth System Sciences* **10**:89-95.

Halounová L, Pavelka K. 2008. *Dálkový průzkum Země*. Vydavatelství ČVUT, Praha.

Hladíková L. 2012: *Monitorování chemických parametrů povrchových důlních vod z hyperspektrálních obrazových dat* [MSc. Thesis]. Charles University, Prague.

Hodášová T. 2011. *Aplikácia diskriminačnej analýzy* [MSc. Thesis]. Masaryk University, Brno.

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* **99**:1-10.

Huete AR. 1988. A soil-adjusted vegetation index (SAVI), *Remote Sensing of Environment* **25**: 295–309.

Huete AR, Didan K, Miura T, Rodriguez EP, Gao X, Ferreira LG. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment* **83**:195–213.

Jackson RD, Slater PN, Pinter PJ. 1983. Discrimination of growth and water stress in wheat by various vegetation indices through clear and turbid atmospheres. *Remote Sensing of Environment* **13**:187-208.

Jackson RD, Huete AR. 1991. Interpreting vegetation indices. *Preventive Veterinary Medicine* **11**: 185-200.

Jensen JR. 2007. *Remote Sensing of the Environment: An Earth Resource Perspective*. Pearson, New York.

Jiang Z, Huete AR, Didan K, Miura T. 2008. Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment* **112**:3833-3845.

Jones HG, Vaughan RA. 2010. *Remote sensing of vegetation: Principles, techniques and applications*. Oxford University Press, Oxford.

Joseph G. 2005. *Fundamentals of remote sensing*. Universities Press, Telangana.

Khanna M. 2001. Sequential adoption of site-specific technologies and its implications for nitrogen productivity: A double selectivity model. *American Journal of Agricultural Economics*. **83**:35–51.

Knipling EB. 1970. Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sensing of Environment* **1**:155-159.

Lamb DW, Weedon MM, Rew LJ. 1999. Evaluating the accuracy of mapping weeds in seedling crops using airborne digital imaging: *Avena* spp. in seedling triticale. *Weed Research* **39**:481-492.

Lillesand T, Kiefer RW, Chipman J. 2015. *Remote sensing and image interpretation*. Wiley, Boston.

Liverman D, Moran EF, Rindfuss RR, Stern PC. 1998. *People and pixels: Linking Remote Sensing and Social Science*. National Academies Press, Washington, D.C.

López-Granados F, Jurado-Expósito M, Peña-Barragán JM, García-Torres L. 2006. Using remote sensing for identification of late-season grass weed patches in wheat. *Weed Science* **54**:346-353.

Makisara K, Meinander M, Rantasuo M, Okkonen J, Aikio M, Sipola K. 1993. Airborne imaging spectrometer for application (AISA). Page 479-481 in *International Geoscience and Remote Sensing Symposium Digest*, Tokyo.

Málková H. 2010. *Klasifikace land cover z hyperspektrálních dat v rekultivovaných oblastech Sokolovské hnědouhelné pánve [MSc. Thesis]*. Charles University, Prague.

Matese A, et al. 2015. Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. *Remote Sensing* **7**:2971-2990.

Matsushita B, Zang W, Chen J, Onda Z, Qiu G. 2007. Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: A case study in high-density Cypress forest. *Sensors* **7**:2636-2651.

Mishra P, Asaari MSM, Herrero-Langreo A, Lohumi S, Diezma B, Scheunders P. 2017. Close range hyperspectral imaging of plants: A review. *Biosystems Engineering* **164**:49-67.

National Research Council. 2008. *Earth observations from space: The first 50 years of scientific achievements*. The National Academies Press, Washington, D.C.

Neudert L, Lukas V. 2015. *Precizní zemědělství: technologie a metody v rostlinné produkci*. Mendelova univerzita, Brno.

- Oliver MA. 2010. Geostatistical applications for precision agriculture. Springer, London.
- Pearson RL, Miller LD. 1972. Remote mapping of standing crop biomass for estimation of the productivity of the shortgrass prairie, Pawnee National Grasslands, Colorado. Fort Collins, Colorado.
- Peña-Barragan JM, López-Granados F, Jurado-Expósito M, García-Torres L. 2007. Mapping *Ridolfia segetum* patches in sunflower crop using remote sensing. *Weed Research* **47**:164-172.
- Plánka L. 2007. Dálkový průzkum Země: Pořizování dat. Technická univerzita, Ostrava.
- Puliti S, Orka HO, Gobakken T, Naeset E. 2015. Inventory of small forest areas using an unmanned aerial system. *Remote Sensing* **7**:9632-9654.
- Qi J, Chehbouni A, Huete AR, Kerr YH. 1994. Modified soil adjusted vegetation index (MSAVI). *Remote Sensing of Environment* **48**:119-126.
- Rouse JW, Haas RS, Schell JA, Deering DW. 1973. Monitoring vegetation systems in the Great Plains with ERTS. Pages 48-62 in Freden SC, Mercanti EP, Becker MA editors. *Proceedings. Third Earth Resources Technology Satellite-1 Symposium*, Washington D.C.
- Rees WG. 1999. *The Remote sensing data book*. Cambridge University Press, Cambridge.
- Rees WG. 2012. *Physical principles of remote sensing*. Cambridge University Press, New York.
- Reddy MA. 2008. *Remote sensing and geographical information systems*. Adithya Art Printers, Hyderabad.
- Shippert P. 2003. Introduction to hyperspectral image analysis. *Online Journal of Space Communication* **1**:1-13.
- Schott JR. 2007. *Remote sensing*. Oxford University Press, Oxford.
- Schowengerdt RA. 2006. *Remote sensing: Models and methods for image processing*. Academic Press, Amsterdam.
- Slaughter DC, Giles DK, Downey D. 2008. Autonomous robotic weed control systems: A review. *Computers and Electronics in Agriculture* **61**:63-78.

Sims DA, Gamon J. 2002. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structure and development stages. *Remote Sensing of Environment* **81**:337-354.

Smith DP, Atkinson SF. 2001. Accuracy of rectification using topographic map versus GPS ground control points. *Photogrammetric Engineering & Remote Sensing* **67**:565-570.

Smith RB. 2012. *Introducing to hyperspectral imaging with TNTmips*. MicroImages, Raymond.

Štych P, Šandera J, Malíková L, Marcinowska-Ochtyra A, Jarocinska A, Zagajewski B. 2015. The use of vegetation indices in the evaluation of vegetation phenology based on MERIS data: the Czech Republic case study. *AUC Geographica* **50**:101-110.

Tempfli K, et al. 2009. *Principles of remote sensing: An introductory textbook*. International Institute for Geo-Information Science and Earth Observation, Enschede.

Thorp K, Tian LF. 2004. Performance study of variable – rate herbicide: Applications based on remote sensing imagery. *Biosystems Engineering* **88**:35-47.

Trnka M, et al. 2018. *Metodika pro praxi: Regionální předpověď výnosů pro lepší rozhodování v rostlinné výrobě*. Mendel University, Brno.

Vane G, Green RO, Chrien TG, Enmark HT, Hansen EG, Porter WM. 1993. The Airborne visible/infrared imaging spectrometer (AVIRIS). *Remote Sensing of Environment* **44**:127-143.

Vogelmann JE, Rock BN, Moss DM. 1993. Red edge spectral measurements from Sugar Maple leaves. *International Journal of Remote Sensing* **14**:1563-1575.

Vrindts E, De Baerdemaeker J, Ramon H. 2002. Weed detection using canopy reflection. *Precision Agriculture* **3**:63-80.

Weier J, Herring D. 2000. *Measuring vegetation (NDVI & EVI)*. Earth Observatory. NASA, Washington, D. C.

Whelan B, Taylor J. 2013. *Precision agriculture for grain production systems*. Csiro Publishing, Clayton.

Zarco-Tejada PJ, Hubbard N, Loudjani P. 2014. *Precision agriculture: An opportunity for EU farmers: Potential support with the CAP 2014-2020*. European Commission, Brussels.

Zemek F, et al. 2014. Letecký dálkový průzkum Země. Teorie a příklady hodnocení terestrických ekosystémů. Centrum výzkumu globální změny AV ČR, Brno.

### **Internetové zdroje**

ARCDATA. 2020. EO-1 a senzor Hyperion. Geografické informační systémy, Praha. Available from <https://www.arcdata.cz/produkty/geograficka-data/druzicova-data/hyperspektralni-data> (accessed April 2020).

ASD. 2016. FieldSpec4. PANanalytical Company. Available from [www.support.asdi.com](http://www.support.asdi.com) (accessed August 2019).

Copernicusa. 2020. Základní informace a principy DPZ. Available from <http://copernicus.gov.cz/zakladni-informace-a-princip-dpz> (accessed January 2020).

Copernicusb. 2020. Sentinel. Available from <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel> (accessed May 2020).

Farm Management. 2020. 5 practical uses for drones in precision agriculture. Available from [www.farmmanagement.pro](http://www.farmmanagement.pro) (accessed June 2020).

Geoimage. 2020. WorldView4. Available from [www.geoimage.com.au/satellite/worldview4](http://www.geoimage.com.au/satellite/worldview4) (accessed May 2020).

GISATa. 2020. Základní pojmy. Available from [www.gisat.cz](http://www.gisat.cz) (accessed July 2020).

GISATb. 2020. Přehled družicových systémů. Available from [www.gisat.cz](http://www.gisat.cz) (accessed March 2020).

HARRIS. 2020. Vegetation Indices. Exelis Visual Information Solutions. Boulder. Available from <http://www.harrisgeospatial.com/docs/VegetationIndices.html> (accessed January 2020).

Jamcopters. 2020. Precizní zemědělství. Available from [www.jamcopters.cz](http://www.jamcopters.cz). (accessed May 2020).

Michalopoulos S. 2016. Environment friendly agriculture: Europe entering the era of precision agriculture. Euractiv. Available from <http://www.euractiv.com/section/science-policy/news/europe-entering-the-era-of-precision-agriculture> (accessed July 2016).

NASA. 2016. TIROS. NASA, Washington, D. C. Available from <https://science.nasa.gov/missions/tiros> (accessed March 2017).

NASAA. 2020. LANDSAT. NASA, Washington, D.C. Available from <https://landsat.gsfc.nasa.gov/a-landsat-timeline/> (accessed February 2020).

NASAb, 2020. ASTER. NASA, Washington, D.C. Available from <https://terra.nasa.gov/about/terra-instruments/aster> (accessed February 2020).

NASAc, 2020. MODIS. NASA, Washington, D.C. Available from <https://modis.gsfc.nasa.gov/about/design.php> (accessed February 2020).

Photonics. 2020. Hyperspectral and Multispectral Imaging. Available from [www.photonics.com](http://www.photonics.com) (accessed May 2020).

Sebera M. 2012. Vícerozměrné statistické metody. Masarykova univerzita, Brno. Available from [www.fsps.muni.cz](http://www.fsps.muni.cz) (accessed July 2020).

SIC. 2020. Satellites. Satellite Imaging Corporation, Houston. Available from [www.satimagingcorp.com](http://www.satimagingcorp.com) (accessed June 2020).

Trimble. 2020. WeedSeeker 2 Spot Spray. Available from [www.agriculture.trimble.com](http://www.agriculture.trimble.com) (accessed June 2020).







