

**Česká zemědělská univerzita v Praze**

Fakulta životního prostředí

Katedra prostorových věd

Využití pokročilých vegetačních indexů pro detekci plodin

Diplomová práce

Autor: Bc. Stanislav Herber

Vedoucí práce: Ing. Tomáš Klouček Ph.D.

2023

# ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

## ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Stanislav Herber

Prostorové vědy v životním prostředí

Název práce

**Využití pokročilých vegetačních indexů pro detekci plodin**

Název anglicky

**Use of advanced vegetation indices for crop detection**

---

### Cíle práce

Cílem diplomové práce je validace spektrální přesnosti hyperspektrální družice PRISMA na příkladu dat terénního spektrometru.

Dílejší cíle práce souvisí s těmito výzkumnými otázkami:

- S jakou přesností je možné detekovat a odlišit jednotlivé zemědělské plodiny pomocí vegetačních indexů vypočtených z hyperspektrálních družicových dat PRISMA?
- Liší se významně hodnoty pokročilých vegetačních indexů vypočtených z hyperspektrálních snímků PRISMA oproti terénnímu spektrometru?
- Odlišuje se přesnost standardního a pokročilého NDVI indexu vypočteného z hyperspektrálních dat družice PRISMA při rozlišování jednotlivých zemědělských plodin?
- Je možné pomocí hyperspektrální družice PRISMA odhadnout fluorescenci vegetace?

### Metodika

Rámcovou metodickou náplní práce bude:

- Příprava hyperspektrálního snímku (pre-processing);
- Výpočet standardních vegetačních indexů;
- Výpočet pokročilých vegetačních indexů;
- Odhad fluorescence vegetace pomocí poměrů pásem;
- Výpočet hodnot výsledných indexů pro referenční data;
- Zhodnocení korelace mezi indexy;
- Zodpovězení výše uvedených výzkumných otázek.

**Doporučený rozsah práce**

40-60 stran

**Klíčová slova**

Hyperspektrální družicová data, vysoké prostorové rozlišení, PRISMA, fluorescence

**Doporučené zdroje informací**

- Coppo, P., Taiti, A., Pettinato, L., Francois, M., Taccola, M., & Drusch, M. (2017). Fluorescence imaging spectrometer (FLORIS) for ESA FLEX mission. *Remote Sensing*, 9(7).  
<https://doi.org/10.3390/rs9070649>
- Irteza, S. M., & Nichol, J. E. (2016). MEASUREMENT OF SUN INDUCED CHLOROPHYLL FLUORESCENCE USING HYPERSPECTRAL SATELLITE IMAGERY. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B8.  
<https://doi.org/10.5194/isprs-archives-xli-b8-911-2016>
- Mangalraj, P., & Cho, B. K. (2022). Recent trends and advances in hyperspectral imaging techniques to estimate solar induced fluorescence for plant phenotyping. In *Ecological Indicators* (Vol. 137).  
<https://doi.org/10.1016/j.ecolind.2022.108721>
- Marshall, M., Belgiu, M., Boschetti, M., Pepe, M., Stein, A., & Nelson, A. (2022). Field-level crop yield estimation with PRISMA and Sentinel-2. *ISPRS Journal of Photogrammetry and Remote Sensing*, 187.  
<https://doi.org/10.1016/j.isprsjprs.2022.03.008>
- Meroni, M., Rossini, M., Guanter, L., Alonso, L., Rascher, U., Colombo, R., & Moreno, J. (2009). Remote sensing of solar-induced chlorophyll fluorescence: Review of methods and applications. In *Remote Sensing of Environment* (Vol. 113, Issue 10, pp. 2037–2051).  
<https://doi.org/10.1016/j.rse.2009.05.003>
- Tagliabue, G., Boschetti, M., Bramati, G., Candiani, G., Colombo, R., Nutini, F., Pompilio, L., Rivera-Caicedo, J. P., Rossi, M., Rossini, M., Verrelst, J., & Panigada, C. (2022). Hybrid retrieval of crop traits from multi-temporal PRISMA hyperspectral imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 187, 362–377. <https://doi.org/10.1016/j.isprsjprs.2022.03.014>
- Wang, N., Clevers, J. G. P. W., Wieneke, S., Bartholomeus, H., & Kooistra, L. (2022). Potential of UAV-based sun-induced chlorophyll fluorescence to detect water stress in sugar beet. *Agricultural and Forest Meteorology*, 323, 109033. <https://doi.org/10.1016/j.agrformet.2022.109033>

**Předběžný termín obhajoby**

2022/23 LS – FŽP

**Vedoucí práce**

Ing. Tomáš Klouček, Ph.D.

**Garantující pracoviště**

Katedra prostorových věd

Elektronicky schváleno dne 1. 3. 2023

**doc. Ing. Petra Šimová, Ph.D.**

Vedoucí katedry

Elektronicky schváleno dne 1. 3. 2023

**prof. RNDr. Vladimír Bejček, CSc.**

Děkan

V Praze dne 23. 03. 2023

## **Prohlášení**

Prohlašuji, že jsem závěrečnou práci na téma: Využití pokročilých vegetačních indexů pro detekci plodin vypracoval samostatně pod vedením Ing. Tomáše Kloučka, PhD. Všechny literární prameny, ze kterých jsem čerpal jsem citoval a rovněž uvedl na konci práce v seznamu použitých informačních zdrojů.

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

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

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

.....

V Janově dne 31. března 2023

## **Poděkování**

Nejdříve bych chtěl poděkovat vedoucímu práce Ing. Tomáši Kloučkovi, Ph.D. za jeho cenné rady a odborný přístup vedení. V neposlední řadě bych rád poděkoval svojí rodině a nejbližším za podporu a trpělivost při psaní této práce.

## **Abstrakt**

V dnešní době je možné konzistentně detekovat zemědělské plodiny na velkých oblastech pomocí metod dálkového průzkumu Země. Díky nedávnému vývoji satelitních hyperspektrálních misí je možné pracovat s podrobnějšími hodnotami elektromagnetického spektra a získat tak důležité informace, které by standardním multispektrálním snímáním viditelné nebyly. Hyperspektrální data jsou mnohem více citlivá na změny na povrchu Země. Výzkum proběhl v oblasti školního zemědělského podniku Amálie, Lány. Jedná se o oblast, která je často monitorována bezpilotními prostředky a dálkovým průzkumem Země. Cílem diplomové práce bylo validovat spektrální přesnost hyperspektrální družice PRISMA na příkladu dat terénního spektrometru ASD Fieldspec 4. Metodická část práce se zabývá nejprve předzpracováním hyperspektrálního snímku PRISMA. Dále je v této části popsán výpočet broadband vegetačních indexů a ruční výpočet narrowband indexů z dat PRISMA a také terénního spektrometru. Pro tuto práci jsem zvolil broadband NDVI index a narrowband NDVI, NPCI, NPQI index.

Výzkumem a následným výpočtem bylo prokázáno, že nejpřesnější index z dat PRISMA v porovnání s hodnotami z terénního spektrometru byl narrowband index NPQI, s hodnotou korelace 0,49. Při porovnání variant NDVI indexu byla nalezena korelace mezi oběma indexy s hodnotou 0,66. Nicméně v oblasti detekce zemědělských plodin se jeví nejpřesnější narrowband varianta NDVI indexu. Závěrem jsem v práci posuzoval, zdali je možné z hyperspektrálních dat PRISMA odhadnout hodnoty fluorescence. Pro výpočet jsem využil absorpční pásmo chlorofylu na úrovni 740 nm z důvodu častého výskytu v zahraničních výzkumech. Výsledné hodnoty fluorescence se statisticky porovnaly a prokázala se hypotéza, že hodnoty ze senzoru PRISMA a terénního spektrometru jsou velmi rozdílné. Výsledky mé práce dokazují, že při následném porovnání hodnot fluorescence s NDVI indexy byla korelace pouze na úrovni 0,27 s hodnotami narrowband NDVI a -0,46 s hodnotami broadband NDVI indexu.

## **Klíčová slova**

Hyperspektrální družicová data, vysoké prostorové rozlišení, PRISMA, fluorescence

## **Abstract**

Today it is possible to consistently detect agricultural crops over large areas due to remote sensing methods. Thanks to the recent development of satellite hyperspectral missions, it is possible to work with more detailed values of electromagnetic spectrum and thus obtain important information that would not be visible with standard multispectral sensing. Hyperspectral data are much more sensitive to changes on Earth's surface. This research was conducted in the area of university farm Amálie, in Lány. It is an area that is often monitored by UAVs and remote sensing. The aim of this thesis is to validate the spectral accuracy of the PRISMA hyperspectral satellite using data from ASD Fieldspec 4 spectrometer. The first part of methodology in this thesis deals with pre-processing of PRISMA hyperspectral image. This section also contains a description of automatic calculation of broadband index and manual calculation of narrowband indices from PRISMA and field spectrometer data. The following indices were chosen for this work: broadband NDVI, narrowband NDVI, NPCI and NPQI.

The results showed that the narrowband NPQI index with correlation of 0,49 was the most accurate index from PRISMA compared to values from the field spectrometer. When I compared two variants of NDVI index a correlation of 0,66 was found between the two indices. In terms of crop detection, it has been proven that, the most accurate was narrowband NDVI index. Finally, in the thesis I tested whether it is possible to estimate fluorescence values from PRISMA hyperspectral data. The absorption band of chlorophyll at the level of 740 nm was used for the calculation due to its frequent occurrence in foreign research. The resulting values were compared statistically and the hypothesis that the values from PRISMA sensor and field spectrometer are very different was proved. In the subsequent comparison of fluorescence values with both NDVI indices, a correlation of only 0,27 with narrowband NDVI and – 0,46 with broadband NDVI index values demonstrated.

## **Keywords**

Hyperspectral satellite data, high spatial resolution, PRISMA, fluorescence

## Obsah

1	ÚVOD.....	1
2	CÍLE PRÁCE.....	3
3	LITERÁRNÍ REŠERŠE .....	4
3.1	PODSTATA DÁLKOVÉHO PRŮZKUMU ZEMĚ.....	4
3.2	TYPY SATELITNÍCH DAT – SPEKTRÁLNÍ PÁSMA .....	4
3.2.1	<i>RGB data</i> .....	5
3.2.2	<i>Multispektrální data</i> .....	6
3.2.3	<i>Hyperspektrální data</i> .....	6
3.3	PŘEHLED HYPERSPEKTRÁLNÍCH SATELITŮ .....	8
3.3.1	<i>EO-1 Hyperion</i> .....	9
3.3.2	<i>GOME-2</i> .....	9
3.3.3	<i>OCO-2, OCO-3</i> .....	10
3.3.4	<i>TANSAT</i> .....	10
3.3.5	<i>SPARK-1</i> .....	11
3.3.6	<i>TECIS</i> .....	11
3.3.7	<i>EnMAP</i> .....	11
3.3.8	<i>CHIME</i> .....	12
3.3.9	<i>PRISMA</i> .....	12
3.4	MONITORING VEGETACE .....	14
3.4.1	<i>Spektrální projevy vegetace</i> .....	15
3.4.2	<i>Broadband vegetační indexy</i> .....	16
3.4.3	<i>Narrowband vegetační indexy</i> .....	20
3.4.4	<i>Metody detekce zemědělských plodin pomocí DPZ</i> .....	22
3.4.5	<i>Odhad fluorescence</i> .....	23
3.4.6	<i>Mise FLEX</i> .....	24
3.5	PRÁCE DALŠÍCH AUTORŮ .....	26
4	CHARAKTERIZACE ZÁJMOVÉHO ÚZEMÍ.....	28
5	METODIKA .....	30
5.1	VSTUPNÍ DATA .....	30
5.2	PRE-PROCESSING VSTUPNÍCH DAT .....	32
5.3	VÝPOČET BROADBAND NDVI INDEXU ZE SENZORU PRISMA.....	34
5.4	VÝPOČET NARROWBAND INDEXŮ ZE SENZORU PRISMA .....	34
5.5	VÝPOČET FLUORESCENCE ZE SENZORU PRISMA .....	34
5.6	VÝPOČET HODNOT VEGETAČNÍCH INDEXŮ ZE SPEKTROMETRU ASD FIELDSPec 4.....	35
5.7	STATISTICKÉ POROVNÁNÍ VEGETAČNÍCH INDEXŮ .....	36
6	VÝSLEDKY .....	38
7	DISKUSE.....	57
8	ZÁVĚR .....	64



9	PŘÍLOHY .....	66
9.1	SEZNAM TABULEK .....	66
9.2	SEZNAM OBRÁZKŮ .....	70
10	SEZNAM ZKRATEK .....	73
11	ZDROJE.....	74

## 1 Úvod

Neustálý rozvoj a vývoj techniky napomáhá dálkovému průzkumu Země (DPZ) a jejím uživatelům pracovat se širokou škálou dat. Lepší kvalita a dostupnost satelitních snímků urychluje rozvoj této technologie. Díky tomu je dnes možné zkoumat nejrůznější části zemského povrchu, v širších částech elektromagnetického spektra a na základě toho vyvíjet mnoho aplikací. Tyto metody lze využít například v oblasti lesnictví, vodního hospodářství, geologii, pedologii a v dalších.

Jednou z těchto oblastí je zemědělství. Kvůli zhoršujícímu se stavu klimatu dochází k negativnímu dopadu na růst vegetace, což je příčinou snížení produkce potravin. To by se mohlo v budoucnosti stát velmi vážným problémem. Když se k tomu přidá neustále rostoucí populace, je důležité nejen zvýšit efektivitu produkce potravin, ale také zvýšit její udržitelnost vůči životnímu prostředí. Světový summit o potravinové bezpečnosti v roce 2017 prohlásil, že „světová populace vzroste do roku 2050 na téměř 10 miliard, což bude mít významný dopad na zemědělství“ (Food and Agriculture Organization of the United Nations, 2017). Jelikož je zemědělství neodmyslitelně spjato s životním prostředím, je důležité brát v potaz, jaký má na životní prostředí vliv a jak ho ovlivňuje. Této tematice se dnes věnuje hlavně obor zvaný precizní zemědělství. Ve zkratce se jedná o metodu, kdy se hospodaří s ornou půdou tak, aby se maximalizovala rostlinná produkce a zároveň se minimalizovaly dopady na životní prostředí (Weiss et al., 2020a).

Rozmach možností DPZ lze pozorovat na vývoji nových senzorů a jejich postupném zasazení do zemědělství, například častější užívání metod hyperspektrálního snímání. Tato metoda hraje jednu z významných rolí při kvantitativní analýze a přesné klasifikaci vegetace. Pomocí hyperspektrálních dat je možné detekovat složení objektů, a to primárně díky snímání ve velkém množství užších částech elektromagnetického spektra. Hyperspektrální data mají mnoho využití v různých oborech, např. lesnictví, vodní hospodářství nebo zemědělství. A právě zemědělství je považováno za jednu z klíčových oblastí, kde tato data mohou poskytnout jedinečné informace o stavu a vývoji plodin. Tyto informace mohou indikovat například jejich zdravotní stav či jiné biochemické, strukturální nebo biofyzikální vlastnosti plodin. Pro porovnání, dnes již široce rozšířené multispektrální snímání tyto vlastnosti nedetekuje (Sahoo et al., n.d.).

Hyperspektrální data mohou sloužit také jako prostředek možného odhadu hodnoty fluorescence chlorofylu z vegetace či obsah fosforu v půdě. V současné době nejsou známy všechny možnosti využití hyperspektrálního dálkového průzkumu, protože se jedná o stále ne zcela objasněnou technologii (Candiani et al., 2022).

## 2 Cíle práce

Hlavním cílem diplomové práce je validovat spektrální přesnosti hyperspektrální družice PRISMA, a to pomocí referenčních dat pořízených v době přeletu družice nad zvoleným zájmovým terénním spektrometrem ASD FieldSpec 4.

Dílčí cíle závěrečné práce souvisí s těmito výzkumnými otázkami:

- (a) Odlišují se významně hodnoty pokročilých vegetačních indexů vypočtených z hyperspektrálních snímků PRISMA oproti terénnímu spektrometru?
- (b) S jakou přesností je možné detekovat a odlišit jednotlivé zemědělské plodiny pomocí vegetačních indexů vypočtených z hyperspektrálních družicových dat PRISMA?
- (c) Odlišuje se přesnost standardního a pokročilého NDVI indexu vypočteného z hyperspektrálních dat družice PRISMA při rozlišování jednotlivých zemědělských plodin?
- (d) Je možné pomocí hyperspektrální družice PRISMA odhadnout fluorescenci vegetace?

### **3 Literární rešerše**

#### **3.1 Podstata dálkového průzkumu Země**

Dálkový průzkum Země (DPZ) je metoda měření množství vyzářeného nebo odraženého elektromagnetického záření od zemského povrchu. V podstatě se jedná o techniku získávání informací o objektech bez přímého kontaktu, na dálku (Dobrovolný skripta, 1972). Jako zdroj tohoto záření je brán každý povrch na Zemi, který má teplotu větší, než je absolutní nula ( $-273,15\text{ }^{\circ}\text{C}$ ). Při dopadu elektromagnetického záření na povrch Země dojde k interakci mezi odraženým zářením a daným povrchem. Právě odražené záření umožňuje získat informace o fyzikálních vlastnostech konkrétního povrchu. Díky tomu jsme schopni určit o jaký typ povrchu se jedná a jaké má vlastnosti. Existují četné definice různých autorů. Zde bych rád zdůraznil definici od Cambell a Wynne (2011), kteří uvádí, že „Dálkový průzkum Země je způsob získávání informací o pevnině a vodní hladině pomocí snímků pořízených z ptačí perspektivy pomocí elektromagnetického záření v jednom nebo více intervalech elektromagnetického spektra které je odraženo nebo emitováno ze zemského povrchu“. Dálkový průzkum Země se dá rozdělit na metody aktivní a pasivní. U metody pasivního snímání je zdrojem energie Slunce, avšak u aktivního snímání je nutné použít vlastní zdroj záření (Rees G.W., 2012).

V neposlední řadě je DPZ také možné rozdělit do různých skupin na základě druhu nosiče senzoru. Typickými nosiči senzorů jsou letadla, drony nebo družice. Dále je možné data DPZ získat i pomocí pozemního měření, například užitím spektrometru pro sběr spektrálních charakteristik konkrétního objektu (Clay E. David & Chang Jiyul, 2016). V dnešní době roste popularita užití specifické třídy letadel lehké váhy tzv. Ultralight letadel. Například (Mozgeris et al., 2018) při detekci druhů listnatých stromů v městském prostředí města Kaunas v Litvě používali hyperspektrálním senzor umístěný právě na tomto typu letadla.

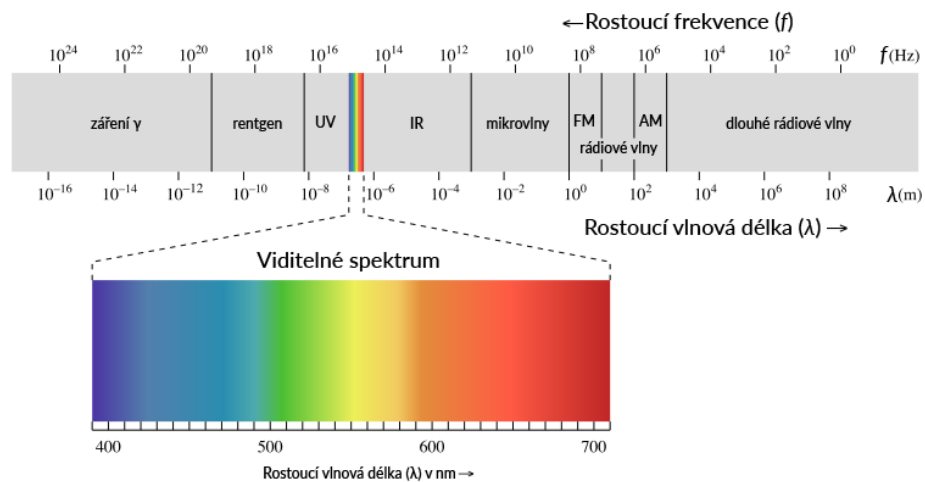
#### **3.2 Typy satelitních dat – spektrální pásma**

Měření dálkovým průzkumem Země se provádí na hodnotách elektromagnetického spektra. Elektromagnetické (EM) spektrum se vyskytuje v rozmezí od krátkých vlnových délek (jako je UV záření) až po dlouhé vlnové délky (např. rádiové vlny). Konkrétně se EM spektrum podle (Campbell & Wayne, 2011) rozkládá v oblasti menší než 10 mikrometrů (UV záření) až po 1 m vlnové délky (rádiové vlny) viz

obrázek č. 1. Rozsah využitelných hodnot EM spektra pro možnosti DPZ se udává do 6 základních intervalů:

- Ultrafialové záření (UV): 100 – 400 nm
- Viditelné záření (VIS): 400 – 750 nm
- Blízké infračervené záření (NIR): 750 – 1400 nm
- Krátkovlnné infračervené záření (SWIR): 1400 – 3000 nm
- Tepelné záření (TIR): 3000 nm – 1 mm
- Mikrovlnné záření: 1 mm – 1 m

Pořízená data se rozdělují podle množství snímaných pásem z celého spektra EM záření a také podle jejich šířky. Pásmo zde označuje malý segment spektra. Množství snímaných pásem a jejich šířka je označováno jako spektrální rozlišení. Díky různému spektrálnímu rozlišení se odlišuje praktické využití dat z dálkového průzkumu. Každý ze sensorů DPZ je omezen v množství spektrálních pásem, které může snímat, a proto rozlišujeme RGB, multispektrální a hyperspektrální senzory (Horning, 2008).



Obr. 1: Diagram elektromagnetického spektra

### 3.2.1 RGB data

Prvním typem dat, které je možné získat z DPZ jsou RGB data. Principem těchto dat je snímání úzkých částí oblastí červeného, zeleného a modrého elektromagnetického spektra. V těchto oblastech se ukládá spektrální reflektance objektu, na který dopadlo EM záření (Zhou et al., 2015). Specificky se jedná o oblast v rozsahu od 400 – 750 nm. Použitím těchto pásem v určité kombinaci lze výsledný snímek zobrazit v přirozených barvách. Nevýhodou RGB snímání je jeho velká náchylnost na

atmosférické vlastnosti jako je oblačnost. Dále je také velmi náročné na snímcích rozlišit od sebe oblačnost a sněž (Ashapure et al., 2019).

RGB snímání má v DPZ své pevné místo, které souvisí s historií tohoto oboru. RGB data lze proto využít pro mnohé aplikace, například k detekci oblačnosti na snímcích (Tayebi et al., 2023). Dále existují specifické vegetační indexy pracující pouze s třemi pásmy RGB, pomocí kterých lze odhadovat biomasa vegetace (Lussem et al., 2018).

### **3.2.2 Multispektrální data**

Multispektrální data jsou snímána senzory, které zaznamenávají množství vyzářeného nebo odraženého EM záření od objektů na povrchu ve více spektrálních pásmech. Některé senzory DPZ snímají data v oblastech, která jsou lidským okem nerozpoznatelná. Většina multispektrálních senzorů dokáže snímat od viditelné části spektra až po infračervené (Campbell & Wayne, 2011).

Data jsou ve formě tří a více snímaných pásem, které se kombinují do jednoho výsledného snímku. Jako příklad bych uvedl satelit Landsat 9, vypuštěný v roce 2020. Na palubě satelitu se nachází dva senzory, a to Operational Land Imager 2 (OLI – 2), který snímá odrazivost v 9 spektrálních pásmech. A dále má Landsat 9 k dispozici senzor Thermal Infrared Sensor-2 (TIRS – 2), který snímá termální radianci ve dvou pásmech. (Masek et al., 2020).

Snímaná pásma se často nachází v oblasti viditelné části, NIR a SWIR spektra. Původně bylo multispektrální snímání vyvinuto pro vojenské účely, k identifikaci cílů a průzkumu. Dnes se tato data používají v nejrůznějších aplikacích v oblastech zemědělství, lesnictví a dalších. Multispektrální data se dají využít pro detekci napadených stromů kůrovcem, což ukázali ve své studii například (Abdullah et al., 2019), kteří využili data z Landsat 8 pro včasnou detekci napadených stromů kůrovcem. Například je také možné využít multispektrální satelit MODIS, snímající v 19 různých pásmech, na měření kvality vzduchu (Hutchison, 2003).

### **3.2.3 Hyperspektrální data**

Posledním typem satelitních dat jsou hyperspektrální data. Právě tato data byla použita pro analýzu v diplomové práci. Největší rozdíl mezi dnes již široce rozšířenými multispektrálními daty a hyperspektrálním typem dat je v množství snímaných pásem a jejich šířce. Hyperspektrální data jsou snímána ve velkém množství spektrálních pásem s šířkou pouze několik nanometrů (kolem 10 až 20 nm). Často mají data desítky

až stovky pásem snímaných v kratších vlnových intervalech. Broadband (širokopásmé) data multispektrálního DPZ jsou omezeny tím, že využívají průměrné spektrální informace v širokých spektrálních pásmech. Kvůli tomu dochází ke ztrátám důležitých vlastností, které jsou přístupné pouze v úzkých pásmech (jako např. absorpční pásma) (Sahoo et al., 2015).


Díky tomu, že jsou data snímána v tak úzkých pásmech, je možné získat velmi detailní informaci o odrazivosti v jednotlivých vlnových délkách EM spektra (Chander et al., 2020). Narozdíl od multispektrálního snímání, je zde obrázek tvořen pomocí tzv. hyperkrychlí (také známé jako datakrychle). Jedná se o datovou strukturu o třech dimenzích. Obsahuje prostorovou dimenzi x, y a také spektrální informaci  $\lambda$  (Pinkerton et al., 2016). Díky tomu je možné charakterizovat materiály v krajině. Jelikož mají hyperspektrální data vyšší spektrální rozlišení v oblasti od 400 – 2500 nm EM spektra je možné odhalit vlastnosti, které by jinými daty vidět nebyly. Například je možné detekovat molekulární absorpci. Mezi nevýhody používání těchto dat může být zařazena vyšší cena a složitost. Pro data je zapotřebí mít k dispozici větší uložště, jelikož jsou hyperkrychle datově rozměrné. Zpravidla s jedná o stovky megabitů až několik gigabitů v závislosti na zájmovém území. Proto je dobré s tím dopředu počítat. Dále se v datech vyskytuje více šumu a nepodstatných informací. Z toho důvodu je nutné před užitím hyperspektrálních dat tyto špatné informace odstranit (He et al., 2011).

Významnou oblastí využití těchto dat je geologie, kde je možné detekovat samotné minerály. Dále můžou být na lokální úrovni data použita k monitoringu pesticidů na polích, mapování záplav či k hodnocení vlastností půdy. Z hyperspektrálních dat je možné počítat narrowband indexy jako například Index listové plochy nebo také indexy zaměřené na biochemikální vlastnosti vegetace, mezi které spadá obsah dusíku či vody (Lausch A. et al., 2012). Existuje další řada využití v zemědělství. Jedním z možných využití je monitoring obsahu uhlíku a dusíku v plodinách, což prokázali ve studiích autoři (Guo et al., 2021; Pancorbo et al., 2021). Dále hyperspektrální data použili (F. Wang et al., 2021; W. Yang et al., 2021) k odhadům možných výnosů kukuřice a rýže. Nicméně se jedná o celkem novou techniku a proto stále ještě nejsou známé všechny oblasti možných užití těchto dat (Kumar et al., 2002).

Techniku hyperspektrálního snímání lze rozdělit podle způsobu snímání do 4 hlavních kategorií, Toto rozdělení je znázorněno na obr. č. 2. První metodou snímání je tzv. „Whiskbroom“ také známé jako bodové snímání, kdy se snímek zaznamenává



postupně bod po bodu ve směru x a y. Druhou metodou je „Pushbroom“. Zde probíhá snímání tak, že se postupně zaznamenává celý řádek prostorové informace s odpovídající hodnotou spektra každého bodu. Předposlední metodou je „Plane scanning“ známý také jako „Staring“, kdy se zaznamenává prostorová informace najednou, ale spektrum se snímá postupně. Jako poslední metoda hyperspektrálního snímání je „Snapshot“, která funguje tak, jak už název napovídá, že v jeden moment se nasnímá celý snímek v prostorovou a spektrální informaci (Adão et al., 2017).



Obr. 2: Porovnání způsobů hyperspektrálního snímání: (A) – Whiskbroom, (B) – Pushbroom, (C) – Plane scanning, (D) - Snapshot

### 3.3 Přehled hyperspektrálních satelitů

Tab. 1: Seznam hyperspektrálních satelitů

Název	Rok vypuštění	Autor	Pásma	Užití	Sp. Rozsah
EO-1 Hyperion	2000	NASA	220	Mapování minerálů	400 – 2500 nm
GOME-2	2006	ESA	12	Meteorologie	645 - 805 nm
OCO-2,3	2014	NASA	3	Meteorologie	760, 1610, 2060 nm
TANSAT	2016	CAS	5 + 3	Měření CO <sub>2</sub> a studie mraků	758 – 778 nm
SPARK-1	2016	GAC	160	/	420 – 1000 nm
PRISMA	2019	ASI	238	Mapování země, vegetace, vnitřních vod a pobřežních vod	350 – 2500 nm

TECIS	2022	GAC	/	Mapování obsahu uhlíku v ŽP	670 – 780 nm
EnMAP	2022	GFZ	246	Poskytnutí informací pro udržitelný management	350 – 2500 nm
FLEX	2024	ESA	/	Globální snímání fluorescence vegetace	500 – 780 nm
CHIME	2028	ESA	/	Management lesů, informace o půdě, změny v land cover	350 – 2500 nm

### 3.3.1 EO-1 Hyperion

Hyperion je hyperspektrální satelit provozovaný společností NASA. Satelit byl 21. listopadu 2000 vypuštěn do vesmíru a v provozu byl až do roku 2017, kdy se rozhodlo o konci mise. Jedná se o push-broom spektrometr snímající v části od 400 do 2500 nm v 220 úzkých pásmech, které jsou široké 10 nm. Hyperion snímá povrch Země v pásmech širokých 7,5 km. Satelit dosahuje prostorového rozlišení 30 m (Pearlman et al., 2001).

Mezi aplikace se řadí mapování minerálů, detekce požárů a vulkánů, nejrůznější užití v lesnictví a zemědělství či detekce povrchové vody nebo vody v canopy (Middleton et al., 2014). Tato satelitní mise byla první misí, která detekovala aktivní proudy lávy z vesmíru.

### 3.3.2 GOME-2

Global ozone monitoring experiment – 2 (GOME-2) je optický spektrometr, který je řízen společností ESA (Evropská kosmická agentura). Mise začala v roce 2006, kdy byl do vesmíru vypuštěn první MetOP-A satelit. Spektrometr je na palubě tohoto satelitu, který je součástí meteorologické mise EUMETSAT. Senzor snímá v rozmezí 240 – 790 nm EM spektra (od UV po VIS část EM spektra) ve 12 pásmech. Spektrální rozlišení je mezi 0,26 a 0,51 nm. Footprint (velikost povrchu, který senzor snímá najednou) senzoru je ve tvaru obdélníku o rozměrech 80 x 40 km. Primární užití je v oblasti meteorologie, kdy senzor měří obsah ozonu v atmosféře (Meyer, 2015). Další

produkty mise jsou hodnoty vodních výparů nebo hodnoty oxidů dusíku či síry v atmosféře (Callies et al., 2000).

### 3.3.3 OCO-2, OCO-3

Orbiting Carbon Observatory (OCO) je hyperspektrální mise řízena agenturou NASA. Spektrometr OCO-2 byl vypuštěn do vesmíru v červenci 2014. Je umístěný na experimentálním Japonském modulu JEM-EF, který se nachází na mezinárodní vesmírné stanici ISS. Tato mise se také zaměřuje na získání globálních hodnot distribuce CO<sub>2</sub>. Poté v roce 2019 byla vypuštěna nová generace spektrometru s názvem OCO-3. Rozdíl mezi druhou a třetí generací spektrometrů OCO je v metodě měření zdrojů CO<sub>2</sub> a jeho propadů. OCO-3 měří tyto hodnoty pomocí sofistikovaných počítačových modelů, které užívají molární zlomek CO<sub>2</sub> hodnot, kdežto OCO-2 měří tyto hodnoty přímo z atmosféry. Mezi další výstup ze spektrometru OCO-3 se řadí také globální hodnoty solárně indukované fluorescence (Doughty et al., 2022).

Narozdíl od OCO-2, který se nachází ve výšce zhruba 705 km, je, jak již bylo řečeno, OCO-3 umístěn na ISS, která je ve výšce typicky 404 km. Spektrometr měří absorpci kyslíku v oblasti O<sub>2</sub>-A pásma absorpce, kolem 0.76 μm. Dále se senzor zaměřuje na hodnoty ve dvou pásmech absorpce CO<sub>2</sub> nacházející se poblíž 1,6 a 2 μm. Konkrétně se zde užívají hodnoty ze slabého a ze silného absorpčního pásma CO<sub>2</sub> (Annmarie Eldering et al., 2018).

### 3.3.4 TANSAT

TanSat, který je také známý jako CarbonSat, je první čínskou misí zaměřenou na monitoring CO<sub>2</sub>. Mise začala v prosinci 2016 a skončila v lednu 2020. Satelit má na palubě dva hlavní senzory a to ACGS (Atmospheric Carbon dioxide Grating Spectrometer) a CAPI (Cloud and Aerosol Polarization Imager). ACGS se zaměřuje na měření absorpce CO<sub>2</sub> a CAPI na studium mraků a aerosolů ve vysokém prostorovém měřítku (*TanSat - Earth Online*, n.d.). Senzor ACGS snímá ve třech absorpčních pásmech, a to v O<sub>2</sub>-A (758 – 778 nm) poté ve slabém CO<sub>2</sub> pásmu (1594 – 1624 nm) a nakonec v pásmu silné absorpce CO<sub>2</sub> (2041 – 2081 nm) (Du et al., 2018). Satelit se nachází na heliosynchronní orbitě ve výšce 700 km. Výslednými výstupy jsou hodnoty aerosolů, množství oblačnosti, teplota vrchní vrstvy mraků a hodnoty CO<sub>2</sub> v atmosféře nebo globální hodnoty solárně indukované fluorescence (Yao et al., 2021).

### **3.3.5 SPARK-1**

Další hyperspektrální satelitní misí je SPARK-1, který spadá pod čínskou akademii věd. Jedná se o mikrosatelit s hyperspektrálním push-broom senzorem, se širokým záběrem. Spark satelity jsou lehké a relativně levné na výrobu. Výrobce je Shanghai Engineering Center for Microsatellites. V prosinci 2016 byl satelit vyslán do vesmíru, kde od té doby snímá data. Spark 1 a 2 byly vyslány společně s již zmíněnou čínskou hyperspektrální misí TanSat. Senzor snímá ve spektrální rozsahu od 400 do 1000 nm v pásce širokých 100 km. Dosahuje prostorového rozlišení 50 m. Výstupní produkt obsahuje celkem 160 pásem se spektrální rozlišením 4,5 nm. Snímaná data mohou být použita v zemědělství k predikcím výnosů nebo k monitoringu napadení škůdců (Zhong et al., 2021).

### **3.3.6 TECIS**

TECIS (Terrestrial Ecosystem Carbon Inventory satellite) je další hyperspektrální mise, která také spadá pod čínskou akademii věd. Cílem projektu je hodnocení lesní biomasy, měření množství aerosolů a detekce fluorescence. Tato měření budou poté použita při implementaci opatření, které povedou k zmírnění globálního oteplování. Satelit bude obsahovat více přístrojů. Například lidarový skener, multispektrální a polarizační senzor a hyperspektrální senzor. Satelit bude obíhat na helio-synchronní orbitě. Start mise byl zahájen v roce 2022 s předpokládanou životností satelitu kolem 8 let. Hyperspektrální senzor bude mít spektrální rozlišení 0,3 nm. Satelit bude snímat v pásce o velikosti 34 km s prostorovým rozlišením 2 km (Du et al., 2020a).

### **3.3.7 EnMAP**

EnMAP (Environmental Mapping and Analysis program) je německý hyperspektrální satelit vypuštěný do vesmíru v dubnu 2022. Satelit se nachází na heliosynchronní dráze a snímá s periodou 27 dní. Spektrální rozlišení se odlišuje v oblasti viditelného a NIR záření, kde je 6,5 nm a SWIR části, kde dosahuje 10 nm. Satelit snímá v pásce širokých 30 km. Konkrétně senzor snímá v oblasti od 420 do 2450 nm v 246 pásmech. Každé pásmo má prostorové rozlišení 30 m (*EnMAP - OHB System ENG*, n.d.). Německá mise si klade za cíl poskytnout detailní monitoring povrchu, extrakci hornin či analyzovat vegetaci, vnitrozemské a pobřežní vody na globálním měřítku (Kaufmann et al., 2015).

### 3.3.8 CHIME

Copernicus Hyperspectral Imaging Mission for the Environment (CHIME) je budoucí mise Evropské kosmické agentury. Plánovaný start mise je v roce 2028 a podle předpokladů by měla skončit v roce 2036. Satelit CHIME bude mít na palubě push-broom spektrometr HyperSpectral Imager (HSI). Ten snímá v rozmezí od 400 do 2500 nm, tedy v částech viditelného, blízkého infračerveného a krátkovlnného infračerveného spektra. Spektrálního rozlišení dosáhne méně než 10 nm. Prostorové rozlišení bude 30 m. Satelit CHIME se bude nacházet na heliosynchronní dráze ve výšce 632 km (*Chime (Copernicus Hyperspectral Imaging Mission for the Environment)*, 2020).

Hlavním cíle této mise bude podle ESA „Poskytovat rutinní hyperspektrální pozorování prostřednictvím programu Copernicus na podporu EU a souvisejících politik pro správu přírodních zdrojů, aktiv a výhod. Mezi aplikace bude patřit charakterizace vlastností půdy, udržitelné řízení zemědělství a biologické rozmanitosti, udržitelné těžební postupy a zachování ŽP“

### 3.3.9 PRISMA

Během této práce byly použity satelitní snímky ze satelitu PRecursoRE IperSpettrale della Missione Applicative (PRISMA). Jedná se o hyperspektrální satelit se středním rozlišením. Vlastníkem je italská kosmická agentura (ASI). Satelit byl ve vývoji od roku 2008 avšak až v roce 2019 byl vypuštěn do vesmíru. Plán mise je na 5 let, až do roku 2024. Satelit se skládá ze dvou přístrojů, a to z hyperspektrálního senzoru a panchromatické kamery. Další charakteristika mise je vidět v tabulce č. 2. Skener je založen na metodě push-broom. Technické parametry senzoru jsou nastíněny v tabulce č. 3. Sensory použité na satelitu snímají ve spektrálním rozmezí od 400 – 2505 nm (*PRISMA (Hyperspectral)*, 2012). PRISMA poskytuje produkty ve dvou hlavních úrovních zpracování. Level 1 jsou data bez atmosférických korekcí. Dále jsou dostupné snímky se zpracováním na level 2, ve 3 úrovních, a to Level 2B, kdy je produkt geolokován na pozemním záření. Level 2C, kdy je geolokován na odrazivost povrchu a Level 4D, kde jsou provedeny atmosférické korekce, geokódování na povrchovou reflektanci a ortorektifikace. Produkty PRISMA jsou v hierarchickém datovém formátu HDF5 (Lasaponara et al., 2020). Cílem mise je monitoring přírodních zdrojů a atmosférických charakteristik. V zemědělství a lesnictví lze data využít k monitoringu zdravotního stavu vegetace nebo odhadu stresu způsobeným

nedostatkem vody. Dále se aplikace soustředí na monitoring vodních ekosystémů a pobřežních systémů. Nakonec mezi využití dat ze satelitu PRISMA spadá také monitoring životního prostředí a přírodních rizik. Data lze také mimo jiné využít k vyhodnocení dopadů na vegetaci po přírodních katastrofách jako jsou erupce, sesuvy půdy či úniky ropy (*PRISMA ("PRekursore IperSpettrale Della Missione*, 2019).



Obr. 3: Satelit PRISMA

Tab. 2: Charakteristika satelitu PRISMA

Satelit PRISMA	
Start mise	22.3.2019
Délka mise	plán 5 let
Výška	614 m
Časová perioda	29 dní
Šířka záběru	30 km
Hmotnost	879 kg

Tab. 3: Charakteristika senzoru PRISMA

Senzor PRISMA			
Parametr	VNIR kanál	SWIR kanál	PAN kanál
Spektrální rozlišení	400-1010 nm	920-2505 nm	400-700 nm
Počet kanálů	66	171	1
SNR (signal to noise)	200	200	240
Prostorové rozlišení	30 m	30 m	5 m
Bitová hloubka	12 bit		
Frame rate	120 Hz		
Velikost senzoru	770 mm (L) x 590 mm (W) x 780 mm (H)		
Hmotnost senzoru	90 kg		
Chlazení	Pasivní radiátor		
Šířka pásma	10 nm		
Typ senzoru	založen na modelu push-broom skener		

### 3.4 Monitoring vegetace

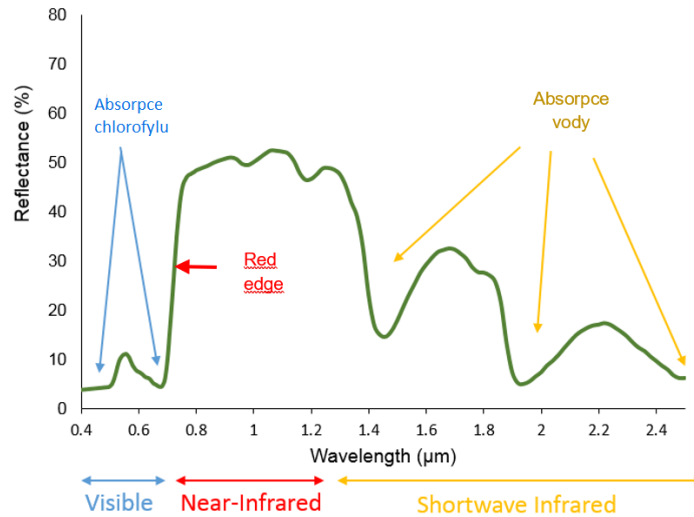
Pro dálkový průzkum je studium vegetace jednou z hlavních oblastí využití. Zemský povrch v oblastech bez ledovců je pokryt z 85 % vegetací (Hille, 2016). Z toho lze usuzovat, že se bude právě vegetace vyskytovat na většině snímků pocházejících z dálkového průzkumu. Díky možnostem DPZ je možné detekovat či kvantifikovat změny a trendy v životním prostředí, což je přímo spjato s člověkem. Například je možné monitorovat úbytek plochy deštných pralesů, které jsou klíčové pro udržování stabilního klimatu Země. Díky těmto informacím je možné následně provést

odpovídající opatření a vydávat další ochranné kroky. DPZ také umožňuje kvantifikovat, jak moc jsou tato opatření v praxi účinná. Nicméně se nemusí nutně jednat pouze o tuto oblast využití. DPZ nám poskytuje možnosti, jak sledovat vegetační ekosystémy na globální úrovni, což může poukázat na provázanost jednotlivých složek a faktorů, které na ně mají vliv (Campbell B. James et al., 1987).

### **3.4.1 Spektrální projevy vegetace**

Jak již bylo zmíněno, dálkový průzkum je založen na měření odraženého nebo emitovaného záření z těles na povrchu Země. Objekty na povrchu mohou sluneční záření odrážet nebo absorbovat několika způsoby. Tato odrazivost je přímo závislá na konkrétním materiálu objektu, na jeho fyzickém či chemickém stavu, drsnosti nebo i na geometrických okolnostech jako je např. úhel dopadu slunečního záření. Díky rozdílům v těchto hodnotách lze detekovat různé vlastnosti objektů na zemského povrchu (Lillesand et al., 2015). Pro analýzu vegetace metodami dálkového průzkumu je nutné mít znalost o funkci, struktuře vegetace a také o vlastnostech její reflektance (odrazivosti). Díky těmto znalostem je možné propojit strukturu vegetace a její stav s jejím odrazovým chováním (Asner, 1998). Spektrální projev vegetace není jednoduchý, je ale možné ho zobrazit jako výslednici odrazivých vlastností samostatných částí rostlin a také pozadí, což je většinou buď voda nebo půda. Díky různorodosti každé části vegetace se liší také jejich spektrální vlastnosti. Každá rostlina má svojí specifickou vegetační křivku. V praxi má největší podíl ze snímku spektrální příspěvky od listů. Listy se z pravidla skládají z nejrůznějších látek jako je celulóza, proteiny, cukry či buněčná tekutina. Spektrální charakteristika listů je proto výsledkem interakce elektromagnetického záření s těmito látkami. Výsledky se samozřejmě liší podle míry zastoupení těchto látek. Nicméně lze shrnout průběh spektrální vegetační křivky do 3 částí, a to na oblast absorpce pigmentů, poté na oblast vysoké odrazivosti (buněčné struktury) a nakonec na oblast vodní absorpce. Konkrétně se první oblast nachází v rozmezí od 400 do 700 nm. Oblast vyšší odrazivosti v buněčné struktuře je kolem 700 do 1300 nm a nakonec se vodní absorpce vyskytuje v části od 1300 do 3000 nm (Ing Jiří Horák, 2014). Tyto oblasti jsou znázorněny na obrázku 4 níže.





Obr.4: Spektrální křivka vegetace

Oblast pigmentační absorpce se vyskytuje ve viditelné části spektra. V této části se většina viditelného záření absorbuje povrchem listu. Část pak projde skrz až na druhou stranu a malé množství záření se od povrchu listu odrazí. Tento proces způsobují převážně pigmentační látky, které se nacházejí v listech. Pigmenty, které na tom mají největší podíl jsou karoten, xanthofyl a anthokyan. Nejdůležitějším pigmentem je pigment chlorofylu, protože celkový listový pigment tvořen ze 65 % právě pigmenty chlorofylu. Chlorofyl má významný vliv na spektrální odrazivost vegetace. Přímou určuje tvar spektrální vegetační křivky (Ing Jiří Horák, 2014).

### 3.4.2 Broadband vegetační indexy

Vegetační indexy se považují za metody zvýrazňování obrazu, kdy je hlavní cíl zvýraznit zeleň. Indexy jsou matematické operace se spektrálními pásmy, kdy nejčastěji dochází k použití červeného pásma a také blízkého infračerveného (NIR) pásma. Pro analýzu vegetace je právě pásmo NIR považováno za nejdůležitější. Je to hlavně proto, že v tomto pásmu vegetace velkou část záření odráží zpět. Díky tomu lze od sebe rozlišit jednotlivé druhy vegetace či odhadovat fyziologické vlastnosti. Vegetačních indexů se dá najít celá řada. Indexy se dělí na 3 hlavní typy, a to na poměrové, ortogonální a distanční (Pu et al., 2008). Dále se indexy dělí podle šířky spektrálních pásem, která do nich vstupuje, a to na širokopásmové (broadband) a na úzkopásmové (narrowband) indexy. Seznam několika vegetačních indexů je znázorněn v tabulce č. 4 níže. Tyto indexy budou blíže přiblíženy a vysvětleny v následující části.

Tab. 4: Vybrané broadband vegetační indexy v této práci

Index	Zkratka	Funkce	Vzorec	Reference
Normalizovaný rozdílový vegetační index	NDVI	Monitoring zeleně Monitoring sucha	NDVI $\frac{NIR - Red}{NIR + Red}$	[Kriegel et al. (1969)]
Green Normalized Difference Vegetation Index	gNDVI	Monitoring rostlinné zeleně s čímž je spojená fotosyntetická aktivita	GNDVI $\frac{NIR - Green}{NIR + Green}$	[Datt (1998)]
Index listové plochy	LAI	Množství listů na ploše	$LAI = (leaf\ area) / (ground\ area)$	[Running et al. (1999)]
Index chlorofylu v listech	LCI	Index pro posouzení obsahu chlorofylu	$LCI = (850\ nm - 710\ nm) / (850\ nm + 680\ nm)$	[Datt (1997)]
Moisture Stress Index	MSI	Měření zdravé vlhkosti	$MSI = \frac{R_{1600}}{R_{820}}$	[Hunt et al. (1989)]

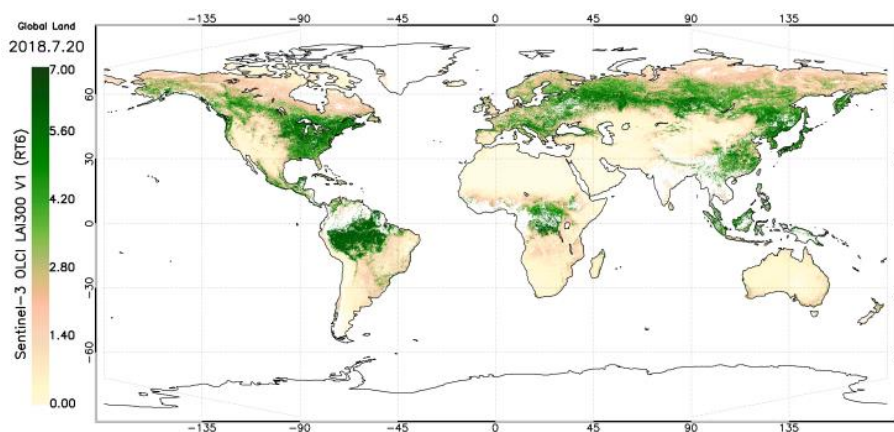
Dnes vůbec nejznámějším a nejužívanějším vegetačním indexem je Normalized Difference Vegetation Index (NDVI). NDVI index koreluje především s obsahem zelené hmoty v pixelu, což v realitě odpovídá hustotě vegetačního pokryvu. Index se používá k měření vegetační zeleně. Hodnoty se mohou pohybovat v intervalu od -1 do 1. Kladné hodnoty blíží se k uvedenému maximu odpovídají velmi husté vegetaci, což naznačuje vysoký podíl chlorofylu. Naopak nízké hodnoty odpovídají velmi řídké vegetaci. Hodnota 0 znamená, že daný pixel neobsahuje žádnou vegetaci. Ukázka příkladu typických hodnot NDVI indexu je vidět v tabulce č. 5 níže. Index je užitečný, jak bylo již zmíněno, k popisu denzity vegetace nebo k monitoringu změn zdravotního stavu vegetace (*Landsat Normalized Difference Vegetation Index | U.S. Geological Survey*, n.d.). V zemědělství má tento index mnoho aplikací např. (Tenreiro et al., 2021) prokázali ve svém výzkumu korelaci mezi indexem NDVI a zelenou canopy zemědělských plodin. Tento index je ale možné i využít k monitoringu reakcí zemědělských plodin na sucho, což ukázali (Ding et al., 2022) ve svém výzkumu, kdy potvrdili vztah mezi NDVI a fluorescencí vegetace vůči zmiňovaným stresovým

reakcím. NDVI se vypočítá jako podíl mezi červeným pásmem R a blízkým infračerveným pásmem NIR. Vzorec pro výpočet je uveden v tabulce č. 4.

Tab. 5: Typické hodnoty NDVI indexu

Povrch	NDVI
Hustá vegetace	0,5
Středně hustá vegetace	0,140
Řídká vegetace	0,090
Holá půda	0,025
Oblačnost	0,002
Sníh a led	-0,046
Voda	-0,257

Další vegetační broadband index je možné uvést Index listové plochy (LAI). Tento index je definován jako polovina celkové plochy listů na jednotku plochy terénu (De Bock et al., 2023). Výsledek ukazuje, jaká je mocnost vegetačního pokryvu. Tento údaj je klíčový pro proměnné, které souvisí s pozitivním stavem ekosystémů. Mezi tyto proměnné patří fotosyntéza, respirace či množství srážek (Alton, 2016). Tento index je dnes často brán jako zásadní klimatická proměnná uvádí komunita pro výzkum globální změny klimatu. Vizualizaci globálních hodnot indexu LAI je možné vidět na obr. č. 5. Má své místo i v oblasti zemědělství, kdy např. (Qiao et al., 2022) odhadovali hodnoty LAI pro kukuřici z multispektrálních UAV snímků. Pro výpočet plochy pokryté listy existují různé typy měření. Přímá metoda je založena na destrukci rostliny, kdy se odstraní všechny listy z rostlin. Polopřímé metody jsou méně náročné, ale stále vyžadují přímý kontakt s listovým a kmeny či korunou stromu. Pro nepřímé metody je typická interakce sluneční radiance se strukturou koruny stromů (Pokorný, 2015).



Obr. 5: LAI index na globálním měřítku

Dále je možné v mnohých studiích vidat upravenou verzi NDVI indexu, která vznikne použitím zeleného pásma místo červeného užitím standardního vzorce pro výpočet NDVI indexu tzv. green NDVI (GNDVI) index. Tento index slouží jako indikátor fotosyntetické aktivity. Například (Rodríguez-López et al., 2020) využívají GDNVI index ze snímků Landsat k monitoringu koncentrace chlorofylu-a v jezeře Laja, Chile. V porovnání se standardní verzí NDVI je tato verze více citlivá na obsah chlorofylu ve vegetaci. Často se index využívá k odlišení starší vegetace. Příkladovou studií zde je možné uvést studii od (Tedesco et al., 2021) kdy se autoři snažili charakterizovat fenologické fáze růstu batátů na polích v Brazílii za použití vegetačních indexů NDVI, GNDVI a SAVI.

Index listového chlorofylu (LCI) se, jak již z názvu napovídá, zaměřuje na detekci chlorofylu. Konkrétně se počítá celkový obsah chlorofylu v listech vegetace. Při výpočtu vstupuje do podílu NIR a red-edge část spektra (*Vegetation Indices: A Key Tool in Precision Agriculture | Pix4D*, n.d.). Tyto pásma se používají, protože lineárně korelují s obsahem chlorofylu ve vegetaci. Tyto hodnoty odrazivostí jsou schopny odhalit malé rozdíly v obsahu chlorofylu i napříč mnoha druhy vegetace. Index LCI dnes má v zemědělství velmi významnou roli. Výsledné hodnoty indexu mají různé aplikace, mezi které patří např. identifikace živin v rostlinách, odhad množství dusíku nebo lze index využít k predikcím výnosů plodin. Listový chlorofyl je indikátorem zelenosti listů a je často užíván ke zkoumání změn v chlorofylu (Ali et al., 2017).

Posledním zmíněným index je Moisture stress index (MSI). Jedná se o index, který je senzitivní vůči obsahu vody ve vegetaci (Zhang & Zhou, 2019). Je to hlavně z důvodu použití absorpce na hodnotách reflektance 1599 nm. Do vzorce dále vstupuje reflektance 819 nm na úrovni absorpce, kdy tato hodnota slouží jako reference, jelikož není ovlivněna změnou obsahu vody. Narozdíl od ostatních indexů, zde je možné hodnoty indexu interpretovat tak, že čím vyšší hodnoty indexu jsou, tím menší obsah vody ve vegetaci je a tím jsou vyšší hodnoty stresu vegetace z nedostatku vody. Index dosahuje hodnot v rozmezí od 0 do více než 3 (Hunt & Rock, 1989). Vzorec výpočtu je opět vidět v tabulce č. 4.

Nicméně tento seznam ale neobsahuje všechny broadband indexy. Pro ukázkou všech dostupných indexů je možné navštívit stránku (*IDB - Index DataBase*, n.d.).

### 3.4.3 Narrowband vegetační indexy

Tab. 6: Vybrané narrowband vegetační indexy

Index	Zkratka	Funkce	Vzorec	Reference
Hyperspectral Normalized Difference Vegetation Index	hNDVI	Monitoring zeleně Monitoring sucha	$hNDVI = \frac{R_{827} - R_{668}}{R_{827} + R_{668}}$	[Oppelt (2002)]
Index fotochemické odrazivosti	PRI	Index pro posouzení aktivity pigmentu rostlin, cyklus xanthofylu	$PRI = (531 \text{ nm} - 570 \text{ nm}) / (513 \text{ nm} + 570 \text{ nm})$	[Gamon et al. (1992)]
Index modifikované absorpce chlorofylu v indexu odrazivosti	MCARI	Měřítka hloubky absorpce chlorofylu	$MCARI = ((700 \text{ nm} - 670 \text{ nm}) - 0,2 * (700 \text{ nm} - 550 \text{ nm})) * (700 \text{ nm}) / (670 \text{ nm})$	[Daughtry et al. (2000)]
Normalized Pigment Chlorophyll Index	NPCI	Měření hodnot pigmentu chlorofylu v listech	$NPCI = \frac{R_{680} - R_{430}}{R_{680} + R_{430}}$	[Penuelas et al. (1994)]
Normalized Phaeophytinization Index	NPQI	Degradace chlorofylu	$NPQI = \frac{R_{415} - R_{435}}{R_{415} + R_{435}}$	[Barnes (1992)]

Většina vegetačních indexů byla vyvinuta pro užití multispektrálních dat, která mají relativně široká pásma (jsou také proto nazývány jako broadband indexy) (Thorp et al., n.d.). Kromě těchto indexů existují ale i pokročilejší verze schopné pracovat s úzkými pásmy hyperspektrálních dat tzv. narrowband vegetačních indexy. Díky nim je možné detekovat a reagovat na řadu specifických přírodních jevů. Mezi tyto jevy například patří vlhkost vegetace, senescence živých organismů neboli stárnutí buněk nebo kvantifikace primární produkce (Anderegg et al., 2020). Podle některých studií se řadí tyto indexy jako klíčové v oblasti kvantifikace biofyzikálních charakteristik zemědělských plodin (Thenkabail et al., 1999). Jedním z předešlých výzkumů, který se zaměřil na porovnání detekce zemědělských plodin z multispektrálních a hyperspektrálních vegetačních indexů je výzkum od (Marshall et al., 2016). V této

diplomové práci bylo vybráno a porovnáno několik narrowband indexů viz tabulka č. 6.

Prvním použitým narrowband indexem byl v této práci verze NDVI upravená pro úzká pásma hyperspektrálních dat. Jedná se o index, který jako první použila (Oppelt & Mauser, 2004) na pásmech z leteckého hyperspektrálního snímání. Tento index a další využívali k monitoringu fyziologických vlastností pšenice během vegetační fáze. Tento index je velmi důležitý v zemědělství, kde se často používá k analýze variability půdy. Díky použití úzkých hyperspektrálních pásem je index citlivější na menší změny ve zdravé vegetaci v porovnání se standardními broadband indexy. To platí zejména pro oblasti velmi husté vegetace, kdy při použití broadband NDVI indexu, dochází k saturaci signálu (Xavier et al., 2006).

Dalším specializovaným vegetačním narrowband indexem je Photochemical Reflectance Index (PRI). Tento index slouží k odhadům úrovně stresu vegetace a také k odhadům primární produkce. Konkrétně se index zaměřuje na změny karotenoidních pigmentů, které jsou absorbovány vrchní vrstvou listů. Jedná se hlavně o pigmenty xantofylu. PRI index je také ovlivněn obsahem chlorofylu v listech. Tyto pigmenty je možné použít jako indikátor úrovně využití světla fotosyntézou pro rostliny (Porcar-Castell et al., 2012). V několika studiích byl prokázán vztah mezi PRI indexem a fotosyntetickou fenologií. Například se jedná o studie zaměřené na pozorování fenologie stálezelených a listnatých stromů od (Fréchette et al., 2015; Wong et al., 2020; Y. Yang et al., 2022). Index je schopný detekovat změny reflektance listů použitím úzkého spektrálního pásma v oblasti 531 nm vůči hodnotě referenčního pásma kolem 570 nm, které není ovlivněno stresovými událostmi. Vzorec je znázorněn v tabulce č. 6. Hodnoty indexu se udávají od  $-1$  do  $1$ . Zdravá vegetace spadá většinou do rozmezí  $-0,2$  až  $0,2$  (Drolet et al., 2005).

Index modifikované absorpce chlorofylu v indexech odrazivosti (MCARI) je dalším indexem, který reaguje na chlorofyl v listech. Vyšší hodnoty MCARI znázorňují nízký obsah chlorofylu v listech. Problém u tohoto indexu nastává v momentě, kdy vykazuje velmi nízkou koncentraci chlorofylu, protože vliv půdního signálu omezuje jeho funkčnost. Proto je důležité tento index interpretovat s dalšími vegetačními indexy jako je NDVI nebo LAI. (Nagler et al., 2000) Vzorec pro výpočet je uveden v tabulce č. 6. Do indexu vstupuje odrazivost v oblasti 700 nm EM spektra, kde se nachází předěl mezi oblastmi, kde dominují vegetační pigmenty a začátkem red-edge části, kde je možné vidět strukturální charakteristiky vegetace (Vincini & Frazzi, 2011).

Jako další byly vybrány indexy Normalized Pigment Chlorophyll Index (NPCI) a Normalized Phaeophytinization Index (NPQI), které již nejsou velmi běžné. Hodnoty indexu NPCI přímo korelují s pigmenty chlorofylu. Díky tomu je možné odhadnout obsah chlorofylu ve vegetaci. Dále je možné podílem celkového obsahu chlorofylu a karotenoidů získat hodnoty, které jsou přímo spojené se stresovými odezvami vegetace. Hodnoty chlorofylu mají tendence rapidně klesat, mnohem více než hodnoty karotenoidů, pokud je vegetace vystavena stresu (např. sucho) (Tong & He, 2017). Hodnot může index nabývat v rozmezí od -1 do 1. Pro výpočet je viz tabulka č. 6 potřeba červené a modré pásmo. Tento index je dobré používat v pozdějších fázích růstu vegetace (F. Li et al., 2010). Index NPQI dosahuje hodnot v rozmezí od 0,56 až 1,41. Oba indexy je možné využít v oblasti zemědělství. Například (Zarco-Tejada et al., n.d.) využívá právě tyto a další narrowband indexy k detekci stresu zemědělských plodin. (Tayade et al., 2022) uvádí, že NPQI index je také možné použít k detekci účinku roztočů na jabloních.

#### **3.4.4 Metody detekce zemědělských plodin pomocí DPZ**

V posledních několika letech je možné pozorovat technologický vývoj v zemědělství. Díky stále rostoucí dostupnosti satelitních dat s vysokým prostorovým, časovým a spektrálním rozlišením je dnes možné vyvíjet nové aplikace v tomto oboru (Benami et al., 2021). V dálkovém průzkumu v zemědělství hraje samotná detekce plodin významnou roli.

Díky tomu je možné pro farmáře pozorovat nejrůznější hodnoty na svých polích efektivně a poté provádět včasná rozhodnutí o správě svých plodin. Mezi příklady takových hodnot lze uvést, změny v krajinném pokryvu, monitoring vodního stavu, odhady možných výnosů polí či predikce počasí (Omia et al., 2023).

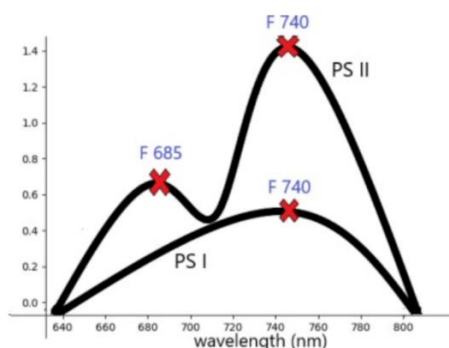
Konkrétně pro zemědělské plodiny lze například určit úroveň napadení škůdci, detekovat jednotlivé růstové fáze či odhalit plodiny s nedostatkem půdní vláhy. Pro precizní zemědělství je důležitý zejména monitoring půdy. Metodami DPZ je možné měřit a porovnávat hodnoty, které jsou zásadní pro správný stav půdy jako je úroveň pH, obsah vody a živin nebo obsah dusíku (Ge et al., 2011). Při monitoringu plodin patří dálkový průzkum Země k zásadním nástrojům. Dnes je již možné nalézt celou řadu provedených výzkumů, které se zaměřovali na různé cíle v této oblasti, jako např. predikce výnosů, monitoring zavlažování nebo detekce plevelů. Podle množství

publikací pro tuto problematiku lze pozorovat exponenciální trend od 2013 (Weiss et al., 2020b).

Na evropské úrovni hraje významnou roli projekt Sen4CAP, který se zaměřuje na zemědělský monitoring ve spolupráci s evropskou legislativou Společné zemědělské politiky. Ta si klade za cíl např. podporovat zemědělce v Evropě, zvýšit zemědělskou produktivitu či zachovat venkovské oblasti v EU (*Stručný Přehled SZP*, n.d.). Jedná se o významný projekt, který má jako primární cíl mapování plodin, trvalých travních porostů a monitoring zemědělských operací využitím dat Sentinel.

### 3.4.5 Odhad fluorescence

Solárně indukovaná fluorescence neboli SIF je signál elektromagnetického spektra, který je emitován chlorofylem u zelených rostlin. Při procesu fotosyntézy v praxi nedojde nikdy k použití veškeré energie přímo pro samotný proces. Malá část záření se emituje buď jako teplo, červená záře nebo fluorescence z rostliny ven. Fluorescence je tedy proces luminiscence. Konkrétně se vyzařuje na delších vlnových délkách v oblasti od 650 do 800 nm elektromagnetického spektra (Mohammed et al., 2019). Obrázek č. 6 zobrazuje dva vrcholy kde dochází k vyzařování tohoto jevu. Signál SIF se v praxi dá použít k odhadům zdravotního stavu, stresu a stavu fotosyntézy vegetace. Signál reaguje na změny ve světle či obsahu vody, což u rostlin poté vyvolává stres (Hong et al., 2022). Hodnoty fluorescence silně korelují s primární produktivitou ekosystému (Helm et al., 2020). Fluorescence se řadí mezi pokročilé metody detekce zemědělských plodin. Například (Siqueira et al., 2020) využívá hodnoty z pozemního fluormetru k detekci variability dusíku a draslíku v kukuřici.



Obr.6: Grafické znázornění oblastí emisí solárně indukované fluorescence



Fluorescence se standardně dá změřit laboratorně nebo pomocí pozemního fluormetru. Fluormetr využívali jako referenci (van der Tol et al., 2014) při výzkumu v roce 2014, kde se snažili poukázat na možné modely odhadu fluorescence. Pozemní spektrometr používali (Zarco-Tejada et al., 2003) při výzkumu, kde ze signálu odrazivosti určovali hodnoty fluorescence. Problém nastává při měření této hodnoty metodami DPZ, jelikož tento signál je pouhých 0,5 až 2 % radiance canopy. Z toho důvodu je složité signál SIF z DPZ vidět. Aby bylo možné fluorescenci vidět, je zapotřebí mít velké spektrální rozlišení. V praxi se SIF dá použít k odhadům hodnot a prostorového rozložení uhlíku. S těmito hodnotami je přímo spjata primární produkce nejen terestrických ekosystémů. Dále se hodnoty SIF ukazují jako indikátor efektivity fotosyntézy, díky čemuž je možné pozorovat reakce vegetace na stres a také odhadovat zdravotní stav (Berry et al., 2013).

V dnešní době se vyvíjí satelitní hyperspektrální mise zaměřená přímo na měření solárně indukované fluorescence. Například satelitní mise FLEX (viz kapitola č. 3.4.6) bude v budoucnu poskytovat hodnoty SIF dokonce i na globální úrovni (Meroni et al., 2009).

### **3.4.6 Mise FLEX**


Mise s názvem Fluorescence Explore neboli FLEX je budoucí mise Evropské kosmické agentury. Jedná se o již osmou výzkumnou misi. Mise byla již schválena a její předpokládaný termín startu je 30. dubna 2024. Měla by podle plánu trvat 3 roky s předpokládanou životností až 5 let. Satelit bude létat ve výšce 805 až 830 km. Bude opatřen spektrálním senzorem Fluorescence Imaging Spectrometer (FLORIS) s vysokým rozlišením. FLORIS je zobrazovací spektrometr, který snímá data v části 500 – 780 nm elektromagnetického spektra. Konkrétně v pásmech absorpce kyslíku, tedy v částech 686 – 697 nm a 759 – 769 nm elektromagnetického spektra, bude senzor snímat s vyšší frekvencí a to 0,1 nm. V ostatních částech bude snímat v 0,5 – 2 nm. Dále také budou přímým výstupem hodnoty PRI indexu. Bude se jednat o push-broom typ senzoru, který bude snímat informace v pásce o šířce 150 km (Kraft et al., 2013). FLEX bude létat v tandemové formaci se satelitem Sentinel-3, čímž bude možné zkombinovat výstupy z více senzorů. První senzor FLORIS, který bude na palubě satelitu FLEX a dále senzory Ocean and Land Colour Instrument (OLCI) a Sea and Land Surface Temperature Instrument (SLSTR), které jsou součástí satelitu Sentinel-3. Tento proces je zamýšlen z důvodu, že snímání samotné fluorescence v praxi není

dostačující pro přesnou kvantifikaci fotosyntézy vegetace. Proto se do výstupů také zahrnou hodnoty jako jsou Leaf Area Index, hodnoty obsahu chlorofylu a také teplota canopy, které jsou výstupem ze satelitu Sentinel-3 (*FLEX - Earth Online*, n.d.).



Obr.7: Logo mise FLEX

Cílem mise je umožnit globální snímání fluorescence vegetace (Schuettemeyer, n.d.). Díky tomu bude možné mapovat a kvantifikovat fotosyntetickou aktivitu na úrovni celých ekosystémů. Pomocí získané fluorescence bude možné zjistit aktuální stav vegetace a také vyhodnotit efektivitu fotosyntetických procesů, například hodnot globální primární produktivity. Díky fluorescenci bude možný také monitoring fenologii rostlin. Získané hodnoty budou sloužit jako vstup do nejrůznějších aplikací. Pro představu mezi ně může spadat monitoring zdravotního stavu lesa, včasné detekce stresu či sledování kvetení toxických mořských řas (Moreno Jose, 2017).



Obr. 8: Vizualizace satelitu FLEX

### 3.5 Práce dalších autorů

Mapování druhů plodin patří mezi nejnáročnější problém v oblasti zemědělství. V posledních několika letech se ukázalo, že by i dálkový průzkum mohl pomoci v detekci druhů na větší prostorové škále. Pomocí spektrální odrazivosti samotných plodin lze jednoznačně rozlišit jednotlivé druhy od sebe. Charakteristiky jednotlivých rostlin či skupin rostlin je možné použít k hodnocení jejich růstové fáze. Použití hyperspektrálních dat, které obsahují hodnoty kontinuálního spektra v úzkých pásech, se ukazuje jako lepší alternativa. Primárně je to, protože jsou tyto data spektrálně citlivější na změny v růstu plodin.

Nicméně v praxi stále nebylo uskutečněno velké množství výzkumů se zaměřením na tuto problematiku. Konkrétně v České republice s hyperspektrálními snímky PRISMA nepracoval nikdo. Následující kapitola je proto zaměřena na shrnutí některých prací, které se zaměřují na práci s hyperspektrálními daty. Budou zde v krátkosti zmíněny výzkumy, které se zaměřují konkrétně na možnou detekci zemědělských plodin z hyperspektrálních snímků. Jeden ze zahraničních článků, který se přibližuje mému tématu je nový článek „Hybridní metody detekce vlastností zemědělských plodin z multitemporálních hyperspektrálních snímků PRISMA“, kde autoři (Tagliabue et al., 2022) popisují možnosti detekce vlastností plodin z hyperspektrálních dat PRISMA. Zaměřují se na shrnutí postupů zpracování dat PRISMA pro mapování vlastností zemědělských plodin. Výzkum proběhl v zemědělské oblasti v severovýchodní Itálii. Autoři zde ukázali možnosti hybridního přístupu pro hyperspektrální satelitní data a terénní data naměřená spektrometrem. Výsledky prokázaly využitelnost snímků PRISMA k mapování prostorové a časové variability vlastností zemědělských plodin. Výsledky této práce budou sloužit jako inspirace pro mojí diplomovou práci. Další zahraniční výzkum provedli autoři (Marshall et al., 2022b). Výzkum s názvem „Odhad výnosů plodin na úrovni pole pomocí dat PRISMA a Sentinel-2“ byl v roce 2022 realizován na farmě poblíž města Emilia-Romagna v Itálii. Autoři porovnávali rozdíly ve spektrálních oblastech obou senzorů pro hlavní růstové fáze plodin, konkrétně kukuřici, rýži, sóju a pšenici. Rozdíly v plodinách hledali 3 metodami. Jedná se o metodu vegetačních indexů, částečnou regresí nejmenších čtverců a metodu Random forest. Výsledky ukázaly nejlepší hodnoty získané metodou Random forest, která průměrně vysvětlovala o 20 % více variability ve vegetační biomase a výnosech plodin. Vyhodnocením metodou RMSE se prokázaly hodnoty lepší přesnosti výnosů a biomasy z dat senzoru PRISMA.

Mezi nejdůležitější pásma pro detekci plodin patří pro hyperspektrální data krátkovlnná infračervená úzká spektrální pásma a pro multispektrální red-edge a NIR. Dále bych ještě rád zmínil výzkum po záštitou hyperspektrální laboratoře Univerzity Karlovy. V roce 2013 při zpracování diplomové práce s názvem „Využití hyperspektrálních dat k detekci a klasifikaci vybraných antropogenních materiálů“ použila (Novotná, 2013) data z hyperspektrálních senzorů APEX a AISA nasnímaná ve třech oblastech, Čáslavi, Rokytnici a Harrachova. Z analýzy potvrdila jako nejlepší klasifikační algoritmus pro detekci antropogenních materiálů z dat senzoru APEX byl SID. Nakonec je zde uveden výzkum od (Málková Hana, 2010). Práce se zaměřuje na tvorbu metodiky pro podrobnou klasifikaci vegetačního pokryvu z hyperspektrálních dat. Konkrétně se autorka zaměřuje na klasifikaci krajinného pokryvu v rekultivované oblasti Sokolovské hnědouhelné pánve. Z uvedených klasifikací krajinného pokryvu dosáhla nejvyšší přesnosti klasifikace algoritmem Neural networks s celkovou přesností 77 %. Další výzkumy zaměřené na detekci plodin jsou nastíněné v tabulce č. 16 v příloze.

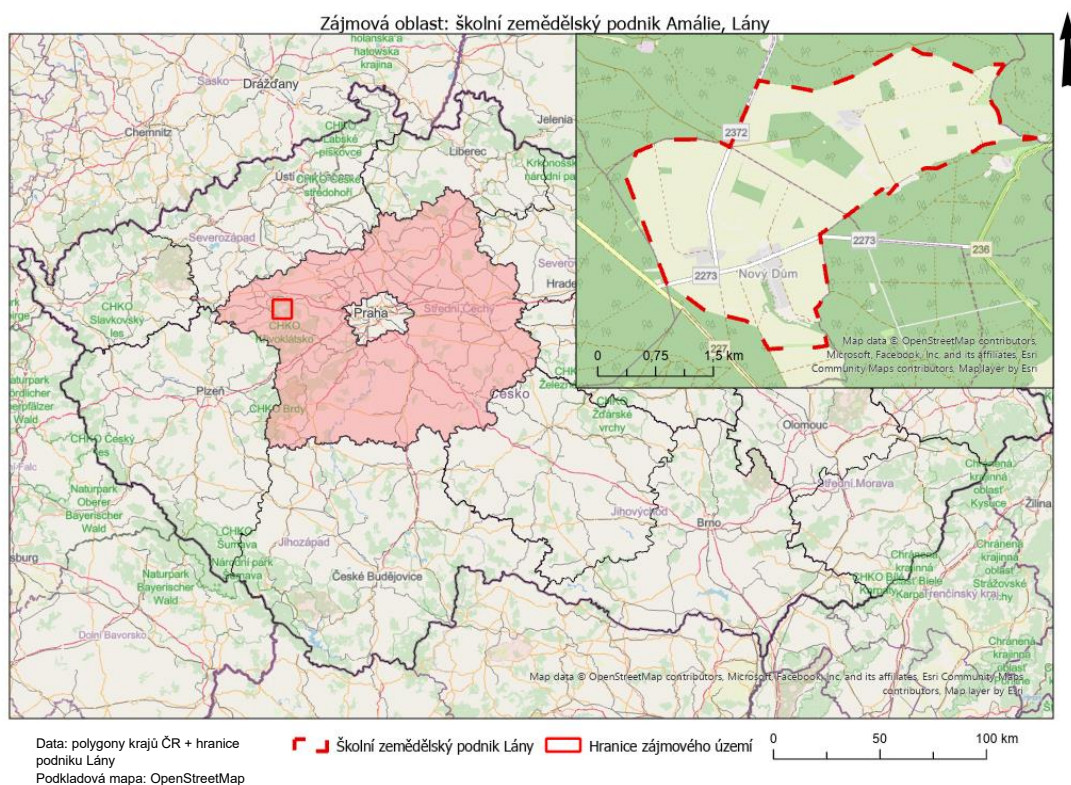
Nakonec je zde zmíněn pár výzkumů, který se zabývá metodami odhadů fluorescence vegetace pomocí právě hyperspektrálních dat. V roce 2017 provedli (Garzonio et al., 2017) výzkum zaměřený na „Měření povrchové odrazivosti a sluncem indukované fluorescenční spektroskopie pomocí malého hyperspektrálního UAS“. Používali k tomu hyperspektrální senzor umístěný na UAV. Fluorescenci zde autoři odhadovali metodou 3FLD v pásmu chlorofylové absorce O2-A 687 nm a tyto hodnoty porovnávali s vegetačními indexy NDVI, MTCI a PRI. Hodnoty fluorescence a vegetačních indexů sloužili k odlišení různých tříd krajinné pokryvu. Výsledky prokázaly, že se dá pomocí spektrometru na UAV odhadovat hodnoty fluorescence s chybou menší než 10 %.

Další výzkum se soustředil na hodnocení sezónních vzorců fotosyntézy na boreálních stromech. (Springer et al., 2017) provedli studii v Kanadě mezi lety 2015 až 2017. Autoři nejdříve spočítali hodnoty fluorescence pomocí terénního fluorometru a ty porovnávaly s vegetačními indexy NDVI, CCI, PRI. Nejlepších výsledků dosahovalo použití indexů NDVI a PRI. Dále autoři prokázaly, že pro listnaté stromy je vhodnější použít NDVI index. Pro stálezelené stromy je lepší index PRI.

Další vybrané výzkumy zaměřené na odhad fluorescence z hyperspektrálních dat jsou nastíněny v tabulce č. 17 v příloze.

#### 4 Charakterizace zájmového území

Výzkum probíhal v oblasti školního zemědělského podniku Lány, na území farmy Amálie. Zde se realizoval projekt Chytrá krajina pod záštitou univerzity ČZU. Dle studie proveditelnosti je cílem projektu “vybudování jednotlivých adaptačních opatření podporujících zadržení vody v krajině s využitím přírodně blízkých technických opatření a zajištění lokální stabilizace a vylepšení malého vodního cyklu v krajině”. Lokalita se nachází v obci Ruda, ve Středočeském kraji, jak je patrné na obr. č. 9. Pro realizaci projektu je oblast osázená senzory, které vyhodnocují realizované opatření, pravidelně zde dochází k náletům UAV, či zde dochází k budování retenčních nádrží a mokřadů. Zemědělský podnik hospodaří na zhruba 2800 ha půdy (*Amálie - Školní Zemědělský Podnik Lány - Fakulta Životního Prostředí ČZU v Praze, n.d.; Statky ČZU, n.d.*).

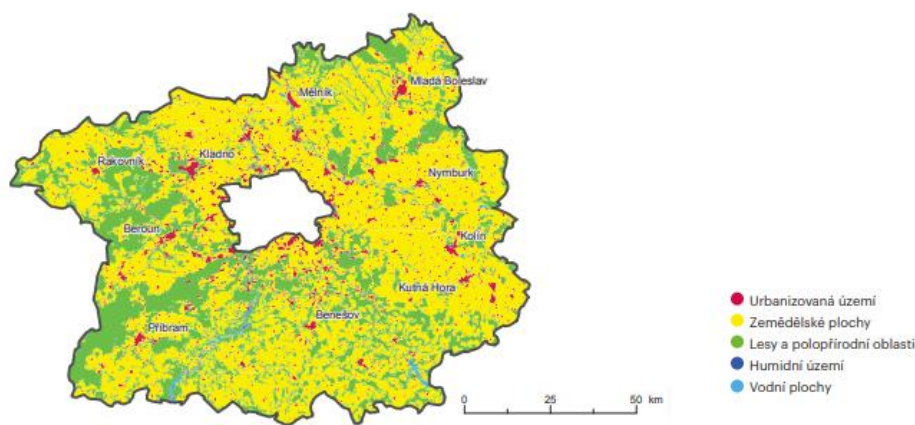


Obr. 9: Zájmová oblast výzkumu

Zemědělství má ve Středočeském kraji zásadní význam. V tomto kraji se na zhruba 3 % zemědělské půdy hospodaří ekologicky (*Ekologické Zemědělství ve Středočeském Kraji - Biofarmy: Poděbrady, n.d.*). V roce 2018 podle katastru nemovitostí zabírala orná půda zhruba 60,3 % z celkové rozlohy kraje. V České republice se Středočeský

kraj zařazuje na první místo s nejvyšším podílem zemědělské půdy. Zajímavé je pozorovat trend ve vývoji zemědělství, kdy od roku 2000 výměra zemědělské plochy klesla o pouhých 1,7 % (Kochová et al., 2018). Mezi nejvýznamnější plodiny patří obiloviny, konkrétně má největší zastoupení pšenice a ječmen (Krajská správa ČSÚ, 2021). Pro lepší představu je na obr. 10 zobrazeno rozdělení krajinné pokrývy ve Středočeském kraji a na obr. 11 je vidět pro znázornění celorepublikové rozdělení klimatických oblastí.


Krajinný pokryv dle databáze CORINE Land Cover, 2018



Zdroj dat: CENIA, EEA

Obr. 10: Zobrazení krajinného pokrývu ČR

Klimatické oblasti



Zdroj dat: VÚKOZ, v.v.i.

Obr. 11: Zobrazení klimatických oblastí ČR


## 5 Metodika

### 5.1 Vstupní data

Pro výzkum byl využit snímek z platformy PRISMA. Data byla nasnímaná 21. června 2022. Jedná se o hyperspektrální data obsahující viditelnou, blízkou infračervenou (VNIR) a krátkovlnnou infračervenou (SWIR) část spektra a dále také panchromatickou část s vyšším rozlišením viz tabulka 3. Celý hyperspektrální snímek má velikost na disku 2,2 GB a zabírá oblast o rozloze 729 km<sup>2</sup>. Data jsem obdržel již plně zkorigovaná na úrovni zpracování 4D, kdy na snímku byly provedeny atmosférické korekce a geolokace. Jedná se o hyperspektrální data v rozmezí od 400–2505 nm elektromagnetického spektra viz tabulka č. 3, nasnímaných ve třech samostatných hyperkrychlích, které jsou sjednoceny v jednom souboru dohromady. Souhrn spektrálních rozsahů jednotlivých hyperkrychlí je také uveden v tabulce č. 3. Vstupní raster představující hyperspektrální snímek je k nahlédnutí obrázku č. 13.

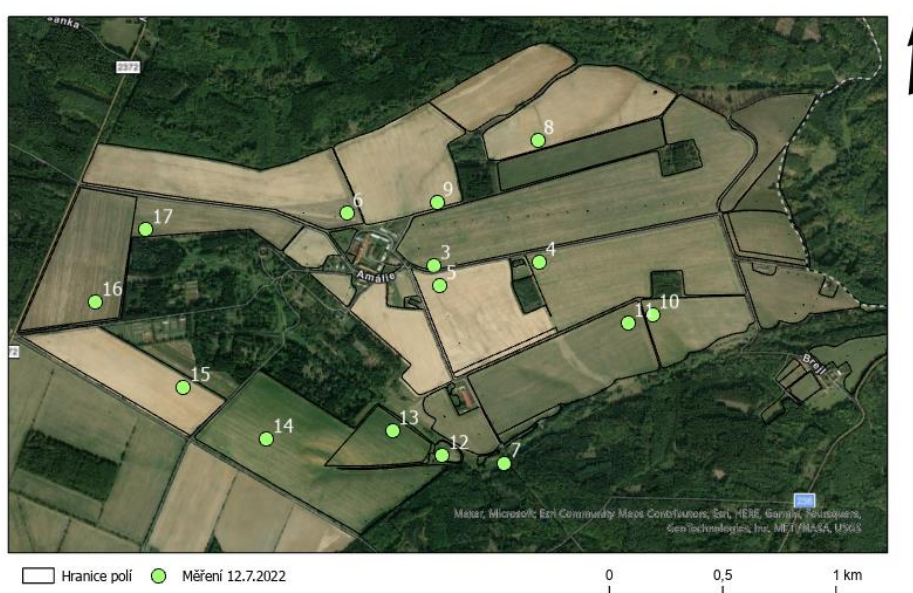


Obr. 12: Logo mise PRISMA



Obr. 13: Zobrazení vstupního hyperspektrálního snímku PRISMA

Dále bylo v terénu 12. 7. 2022 uskutečněno měření pozemním spektrometrem. Ve školním zemědělském podniku bylo vybráno a naměřeno několik bodů. Lokality měření v terénu jsou znázorněny na obr. č. 14. Toto měření probíhalo ve čtvercové oblasti o velikosti 30 x 30 m viz obr. č. 15, kde bylo naměřeno vždy 10 bodů. Konkrétně byl při měření použit přenosný spektrometr ASD Fieldspec 4 od firmy Malvern Panalytical. Před uskutečněním samotného měření byly tyto body zaměřeny užitím GNSS, přístrojem Trimble R8s. Zmíněný spektrometr je schopen měřit v oblasti celého elektromagnetického spektra, v rozsahu od 350 do 2500 nm s rozlišením v části VNIR 3 nm a ve SWIR části 10 nm. V tabulce č. 7 níže je zobrazen souhrn naměřených plodin.



Obr. 14: Lokality terénního měření

Tab. 7: Seznam lokalit bodů terénního měření

id bodu	X	Y	Plodiny
3	-783023	-1035251	Vojtěška
4	-782561	-1035299	Vojtěška
5	-783010	-1035343	Ječmen
6	-783376	-1034975	Pšenice
7	-782828	-1036157	Voda
8	-782499	-1034763	Vojtěška
9	-782975	-1034976	Strniště
10	-782095	-1035590	Tráva
11	-782209	-1035614	Vojtěška
12	-783096	-1036088	Pšenice
13	-783300	-1035951	Pšenice
14	-783855	-1035916	Řepka




15	-784188	-1035644	Pšenice
16	-784524	-1035220	Pšenice
17	-784264	-1034932	Strniště



Obr.15: Oblast terénního měření spektrometrem

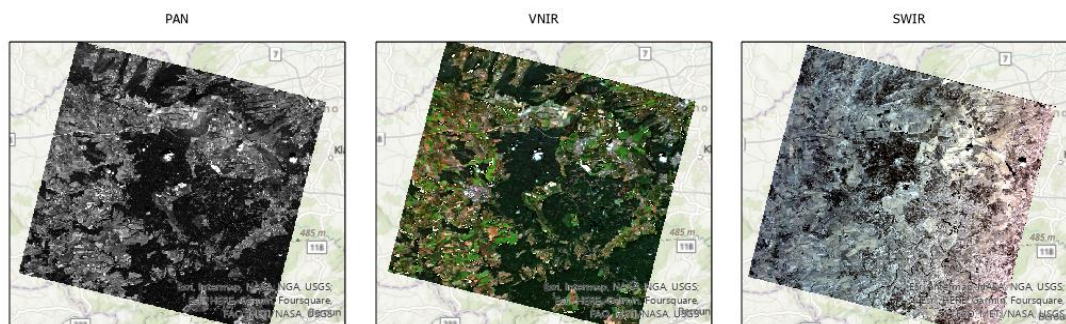
## 5.2 Pre-processing vstupních dat

Prvním krokem zpracování vstupních snímků PRISMA bylo jeho ořez na oblast zemědělského podniku Amálie. Ořez rasteru jsem provedl v software ENVI 5.6, kde jsem vybral čtvercovou trénovací plochu nástrojem ROI (Region of Interest), kterou jsem nastavil jako masku pro vstupní snímek viz obrázek č. 16. Zvolil jsem oblast, která zahrnovala i malou část okolních lesů.




Obr.16: Diagram ořezu vstupních snímků

Hyperspektrální snímek se po ořezání automaticky rozdělil na samostatné hyperkrychle a to na viditelnou a NIR (VNIR), krátkovlnnou infračervenou (SWIR) a panchromatickou, jak je vidět na obr. 17. Jednotlivé hyperkrychle jsem uložil samostatně ve formátu .dat (nativní formát software ENVI).

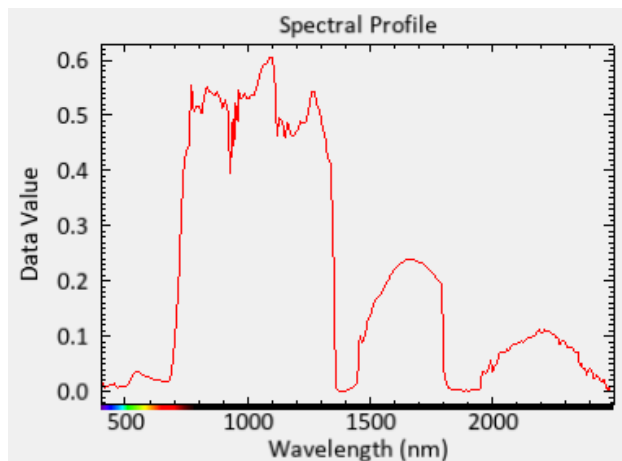


Obr. 17: Zobrazení jednotlivých hyperkrychlí ze snímku PRISMA

Následně jsem hyperkrychle VNIR a SWIR sjednotil do jednoho souboru nástrojem Build layer stack v programu ENVI. Tím vznikl sjednocený rastr, který obsahuje celkem 234 pásem pokrývajících oblasti viditelného, NIR a SWIR spektra viz obr. 18. Výsledný rastr je tedy v rozmezí od 400 do 2500 nm kontinuálního EM spektra. Ukázkový spektrální profil vytvořený z těchto dat je znázorněn na obrázku č. 19.



Obr. 18: Zobrazení sjednoceného souboru v RGB kombinaci (31-20-10) a v false color kombinaci (63-35-17)



Obr. 19: Výsledné kontinuální spektrum kompozitu (příklad spektra lesa)

### 5.3 Výpočet broadband NDVI indexu ze senzoru PRISMA

Pro analýzu zemědělských plodin jsem využil několik vegetačních indexů. Nejdříve jsem vypočítal broadband NDVI index, který je velmi užívaný v praxi. Detailní popis včetně samotného vzorce je popsán v podkapitole 3.4.2. Pro výpočet jsem použil software ENVI 5.3, kde jsem využil nástroj Spectral indices, který je součástí balíčku Band algebra. Tento nástroj disponuje celkem 27 základními broadband vegetačními indexy, které je schopen automaticky vypočítat (*Vegetation Indices*, n.d.).

### 5.4 Výpočet narrowband indexů ze senzoru PRISMA

Dále jsem se zaměřil na detekci zemědělských plodin pomocí pokročilých vegetačních indexů. Nejdříve jsem se soustředil na narrowband verzi NDVI indexu. Index jsem vypočítal ručně v programu ArcGIS Pro nástrojem Raster calculator. Poté jsem vybral další dva narrowband vegetační indexy ze seznamu indexů v kapitole 3.4.3., které reagují na pigmenty chlorofylu. Jedná se o indexy Normalized pigment chlorophyll index (NPCI) a Normalized Phaeophytinization index (NPQI). Vzorce vybraných pokročilých vegetačních indexů jsou znázorněny v tabulce č. 6.

### 5.5 Výpočet fluorescence ze senzoru Prisma

Jako poslední jsem z hyperspektrálních dat PRISMA odhadoval hodnoty fluorescence vegetace. Fluorescence byla odhadnuta také jako narrowband vegetační index. Vzorec pro výpočet fluorescence byl založen na metodě Continuum removal, což je způsob normalizace spekter odrazivosti. Díky tomu je pak možné porovnávat jednotlivé absorpční vlastnosti s hodnotami ze společné základní linie. Prakticky jsem vybral pásma, která se nachází po okrajích oblasti, ve kterém dochází k absorpci

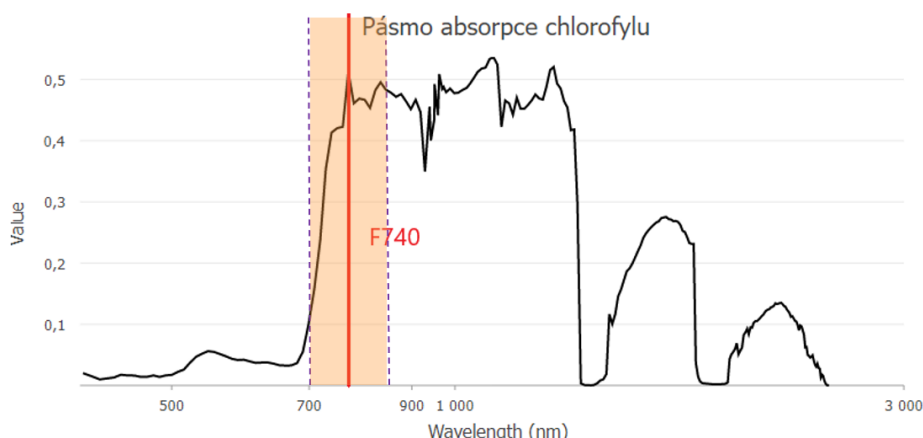
chlorofylového spektra a dále pásma uvnitř této oblasti. Zvolil jsem pouze absorpci chlorofylu v pásmu O2-A, konkrétně hodnotu absorpce v části 740 nm. Poté jsem vybíral pásma, která se nachází mimo toto absorpční pásmo. Z toho důvodu jsem vybral dvě pásma na okrajích absorpční oblasti chlorofylu s nejbližší hodnotou reflektance 730 a 750 nm. Hodnoty fluorescence jsem poté z hyperspektrálních dat PRISMA i terénního spektrometru vypočítal pomocí obecného vzorce:

$$F = (730 \text{ nm} + 750 \text{ nm}) / (2 * 740 \text{ nm})$$

V případě senzoru PRISMA vzorec vypadal následovně:

$$F = (b(40) + b(42)) / (2 * b(41))$$

K výpočtu jsem využil v ArcGIS Pro nástroj Raster calculator. Na obrázku č. 20 je zobrazeno pásmo absorpce chlorofylu, které bylo použito pro výpočet.



Obr. 20 Pásmo absorpce chlorofylu

## 5.6 Výpočet hodnot vegetačních indexů ze spektrometru ASD FieldSpec 4

Vybrané vegetační indexy bylo dále nutné spočítat i z nasnímaných hodnot reflektance terénním spektrometrem. Jednotlivé výpočty jsem provedl v Excelu. Před samotným výpočtem bylo zapotřebí udělat pár kroků. Jako první jsem pro každou lokalitu zprůměroval 10 provedených měření, aby vznikla jedna hodnota reflektance pro každé pásmo v každé lokalitě měření. Jakmile jsem získal hodnotu pro každé nasnímané pásmo, vybral jsem hodnoty reflektance kolem vstupních hodnot do samotných indexů (např. pokud do indexů vstupovala hodnota reflektance 420 nm vybral jsem hodnoty 418 a 422 nm). Tyto hodnoty jsem zprůměroval mezi sebou, a nakonec dle vzorců v kapitole 3.4.1 a 3.4.2 jsem vypočítal hodnoty jednotlivých vegetačních indexů. Díky

tomu jsem finálně získal 14 hodnot z terénního měření pro všechny vybrané vegetační indexy. Pro detekci plodin bylo zapotřebí nakonec zprůměrovat hodnoty pro vojtěšku a pšenici z výsledků vegetačních indexů. Proto se hodnoty indexů z 5 bodů (body z terénního měření č. 3,4,8,11,17) zprůměrovaly, čímž vznikla jedna průměrná hodnota indexů pro vojtěšku. Stejným způsobem se zprůměrovaly hodnoty indexů v 5 bodech (jednalo se o body č. 6,12,13,15,16) na polích, kde se vyskytovala pšenice.

## **5.7 Statistické porovnání vegetačních indexů**

Pro porovnání jednotlivých vypočítaných vegetačních indexů ze senzoru PRISMA a spektrometru jsem provedl několik statistických testů. Z rasterů vegetačních indexů jsem vybral pouze hodnoty, které se vztahovali k lokalitám, ve kterých proběhlo terénní měření. Proto jsem hodnoty z rastrů indexů funkcí Extract values to points (software ArcGIS Pro) vypsal přímo do konkrétních bodů měření. Díky tomu jsem mohl porovnat a určit, jestli se hodnoty indexů ze satelitu a ze spektrometru liší nebo ne.

Ze získaných hodnot vegetačních indexů jsem nejprve porovnával jejich rozdělení. Z toho důvodu jsem zvolil testování Shapiro-Wilk testem, jehož výpočet jsem provedl v programu R Studio. Jako další statistickou metodu pro porovnání hodnot indexů mezi satelitem PRISMA a terénním spektrometrem jsem využil dvou výběrový t.test a také vizuální porovnání rozložení hodnot vegetačních indexů pomocí density plotu. Při porovnání t.testy jsem musel využít jeho neparametrickou verzi, tzv. Wilcox test.

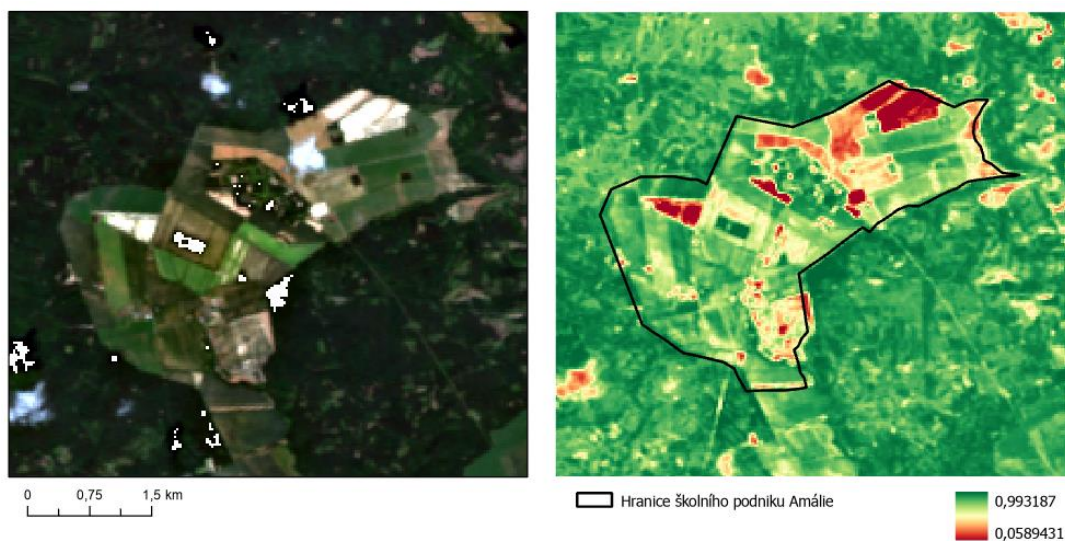
Dále jsem se zaměřil na přesnost detekce zemědělských plodin. Proto jsem hodnoty samotných vegetačních indexů ze senzoru PRISMA zprůměroval podle frekvence výskytu jednotlivých plodin na polích (z terénního spektrometru jsem to udělal v přechodí kapitole 5.6). Tyto průměrné hodnoty jsem zobrazil ve sloupcovém grafu, tak aby bylo na první pohled zřejmé porovnání výsledků detekce plodin vegetačními indexy z obou platforem.

Nakonec jsem zjišťoval, zdali existuje mezi vegetačními indexy ze satelitu PRISMA a terénního spektrometru korelace a poté jak moc je silná. Korelace indexů byla testována v Excelu pomocí nástroje „Korelace“ v balíčku nástrojů Analýza dat. Do nástroje vstupovaly hodnoty indexu každého bodu ze satelitu PRISMA a spektrometru. Výstupem byla matice s hodnotami korelace vyjádřených koeficientem determinace ( $R^2$ ) pro každou skupinu indexů.

Stejnými kroky byly testovány mezi sebou i rozdíly broadband a narrowband verzích NDVI indexů. Tedy při porovnání rozdílnosti broadband a narrowband NDVI indexů byla opět nejdříve zkontrolována normalita dat. Poté byl vypočítaný t.test a nakonec spočtena korelace.

## 6 Výsledky

Jako první jsou zobrazeny výsledné vizualizace vypočítaných rasterů z hyperspektrálního senzoru PRISMA. Index je vždy zobrazen vedle původního hyperspektrálního snímku PRISMA, který je zobrazený v přirozených barvách. Nejdříve je níže na obr. č. 21 vidět vizualizace broadband rastru NDVI indexu pro zájmové území Školního zemědělského podniku Lány (Amálie).

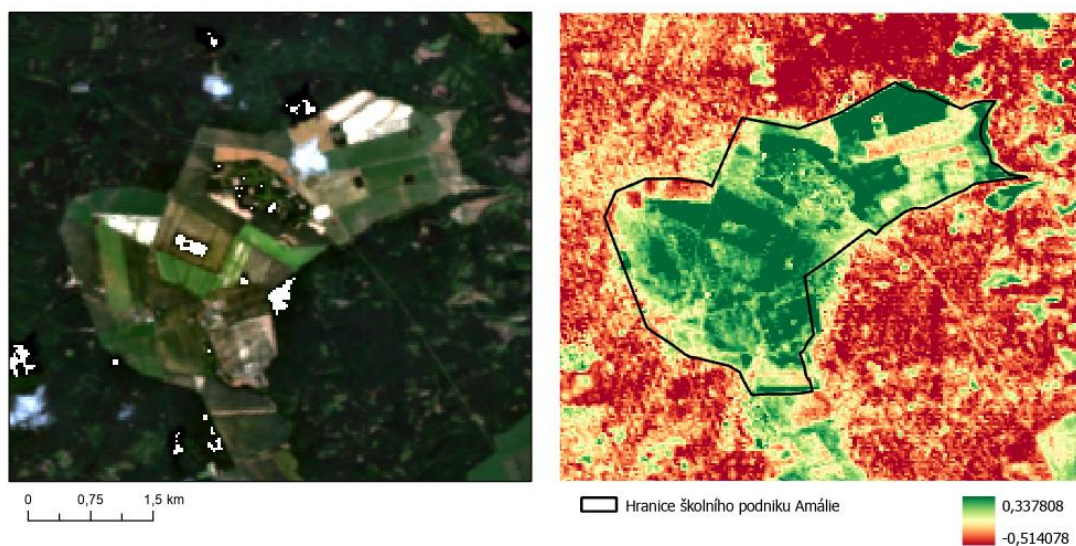


Obr. 21: Výsledný broadband NDVI index ze senzoru PRISMA

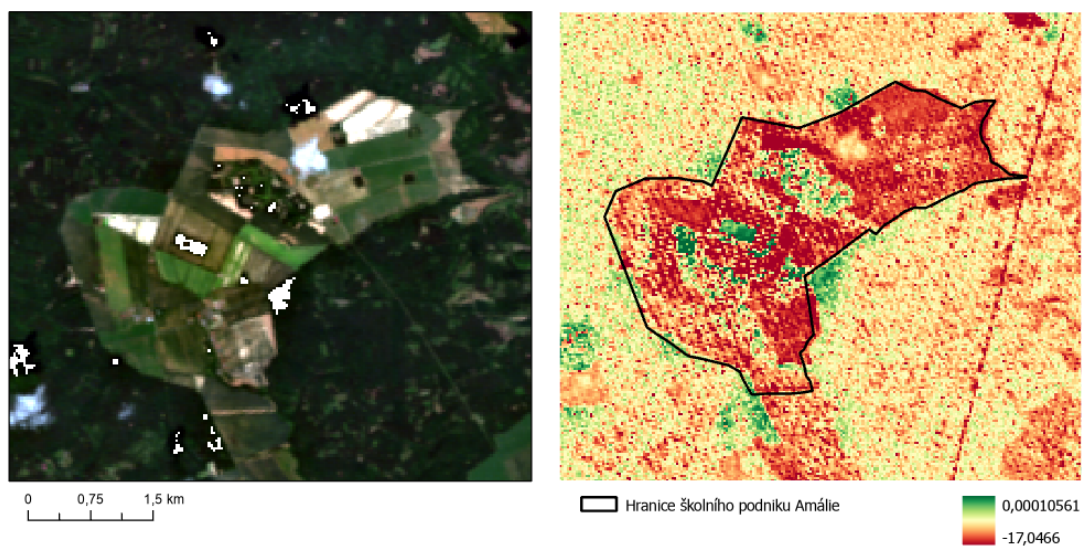
Dále jsou zobrazeny na obr. 22, 23 a 24 výsledky narrowband indexů. Nejdříve je zobrazený výsledný raster narrowband NDVI indexu a dále je možné vidět narrowband indexy NPCI a NPQI. Indexy jsou opět zobrazeny vedle původního snímku PRISMA.



Obr. 22: Výsledný narrowband NDVI index ze senzoru PRISMA



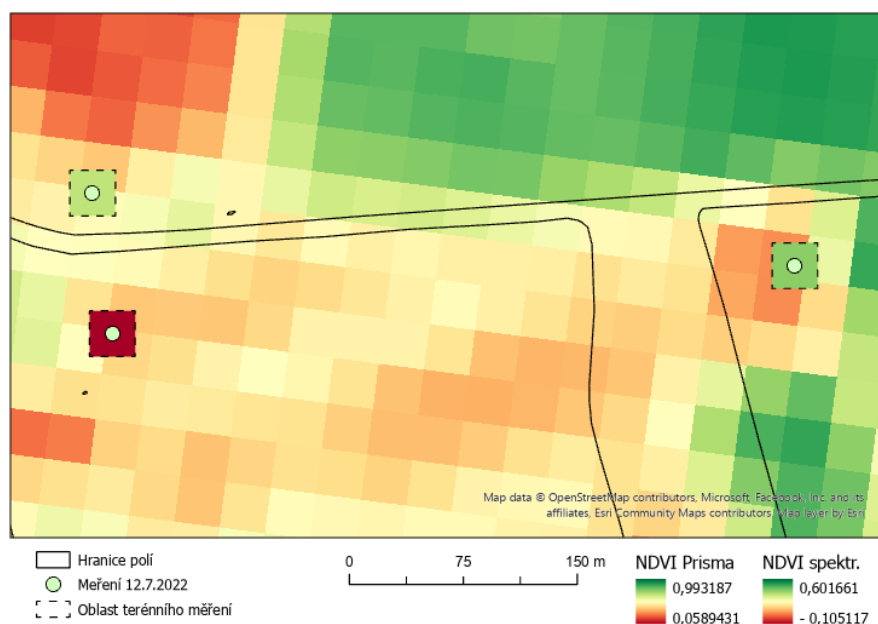
Obr. 23: Výsledný narrowband NPCI index ze senzoru PRISMA



Obr. 24: Výsledný narrowband NPQI index ze senzoru PRISMA

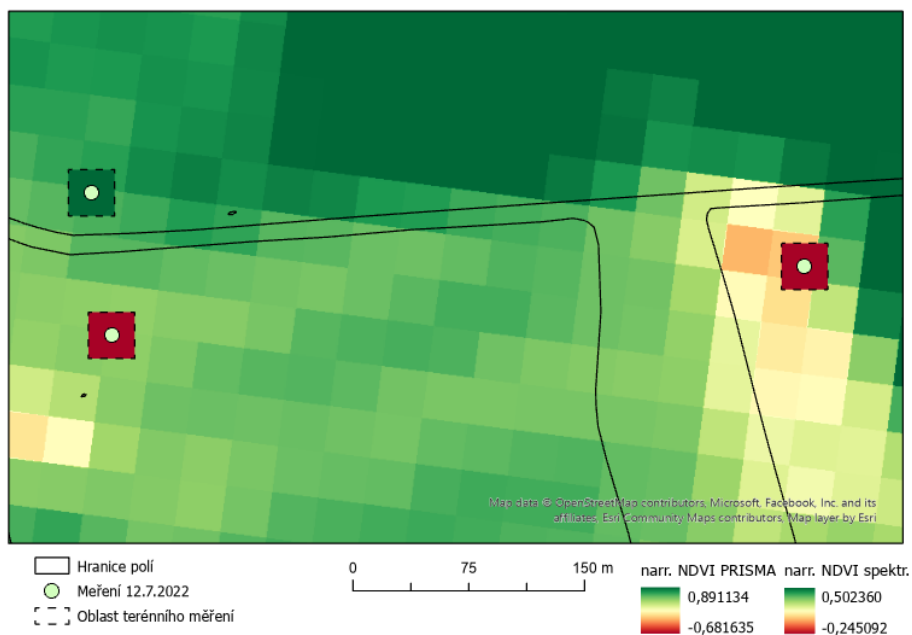


V další části je možné vidět porovnání hodnot vypočítaných broadband a narrowband vegetačních indexů ze senzoru PRISMA s daty naměřenými terénním spektrometrem. Nejdříve je na obr. 25 znázorněn rozsah hodnot broadband NDVI indexu. Nad rastrem indexů jsou zobrazeny fyzické hranice polí (zdroj: LPIS). NDVI index z dat spektrometru je vizualizován v čtvercích o velikosti 30 x 30 metrů, ve kterých došlo k terénnímu měření.




Obr. 25: Porovnání hodnot PRISMA a spektrometru – broadband NDVI index

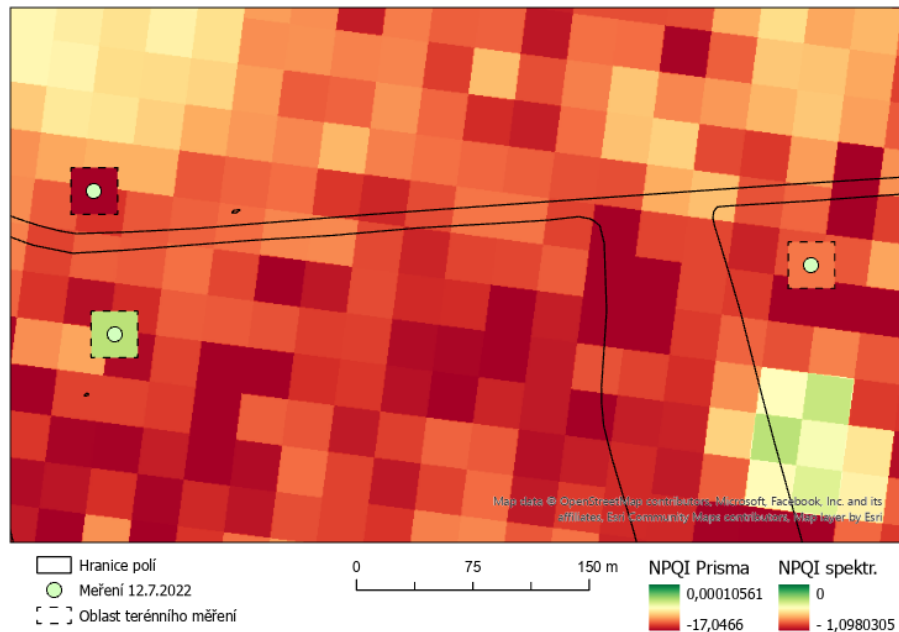
Dále jsou na obr. 26, 27 a 28 vizualizovány rozsahy hodnot narrowband indexů z dat PRISMA a terénního spektrometru. Opět jsou nad rastry indexů vizualizovány hranice polí. Hodnoty indexů z dat terénního spektrometru jsou vizualizovány ve čtvercích, kde proběhlo terénního měření.



Obr. 26: Porovnání hodnot PRISMA a spektrometru – narrowband NDVI index

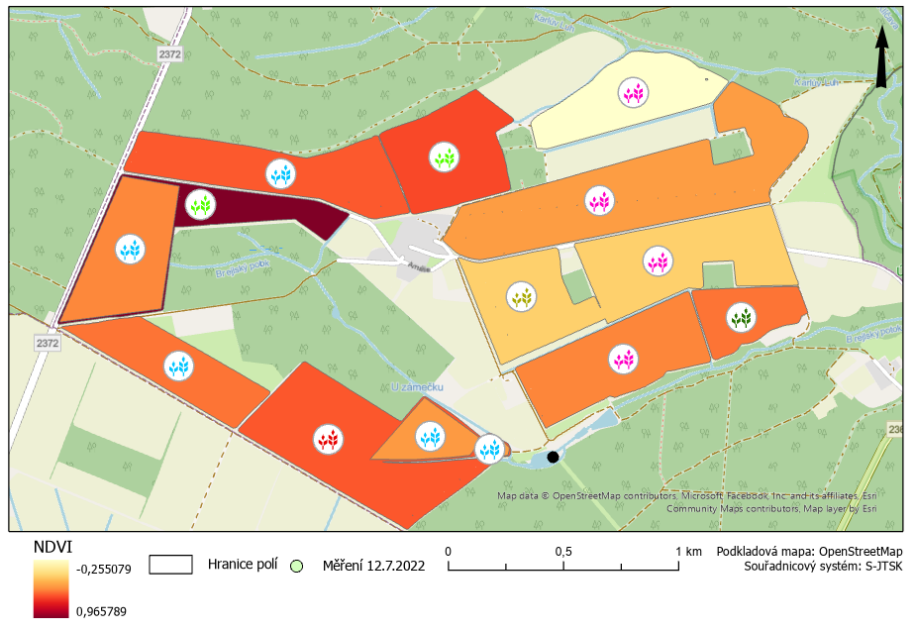


Obr. 27: Porovnání hodnot PRISMA a spektrometru – narrowband NPCI index

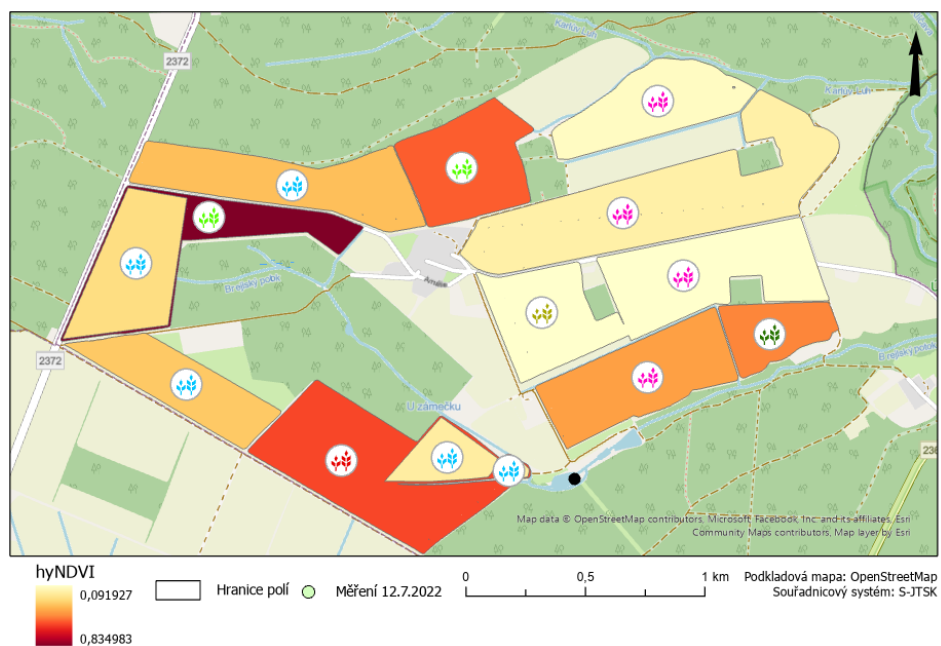


Obr. 28: Porovnání hodnot PRISMA a spektrometru – narrowband NPQI index

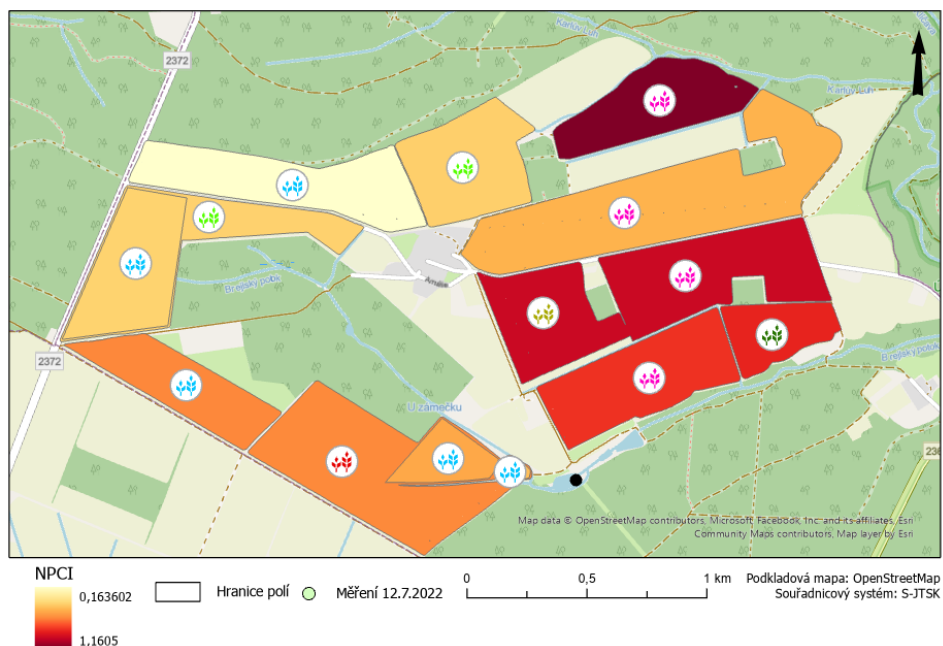
Níže je možné vidět rozdíly v hodnotách vypočítaných broadband (NDVI) a narrowband indexů (NDVI, NPCI, NPQI). V polygonech polích, které se nachází v zemědělském podniku Amálie, jsou vidět hodnoty rozdílu z vypočítaných indexů ze senzoru PRISMA a terénního spektrometru. Jednotlivá pole jsou barevně označena symbolem podle toho, jaká plodina na poli roste. Samotné barvy jsou vysvětleny v popisu obrázku. Rozdíly broadband NDVI indexu jsou zobrazeny na obr. 29. Na obr. 30 až 32 je možné vidět rozdíly narrowband indexů. Kdyby v hodnotách broadband a narrowband NDVI indexů nebyly rozdíly, v grafu by byly tyto pole znázorněny oranžově. V tomto případě by hodnota odpovídala 0. Při porovnání narrowband NDVI index má více ploch, kde jsou minimální rozdíly v hodnotách z dat PRISMA a spektrometru. Na většině z těchto ploch roste vojtěška. Naopak oba indexy velmi rozdílně detekují řepku.



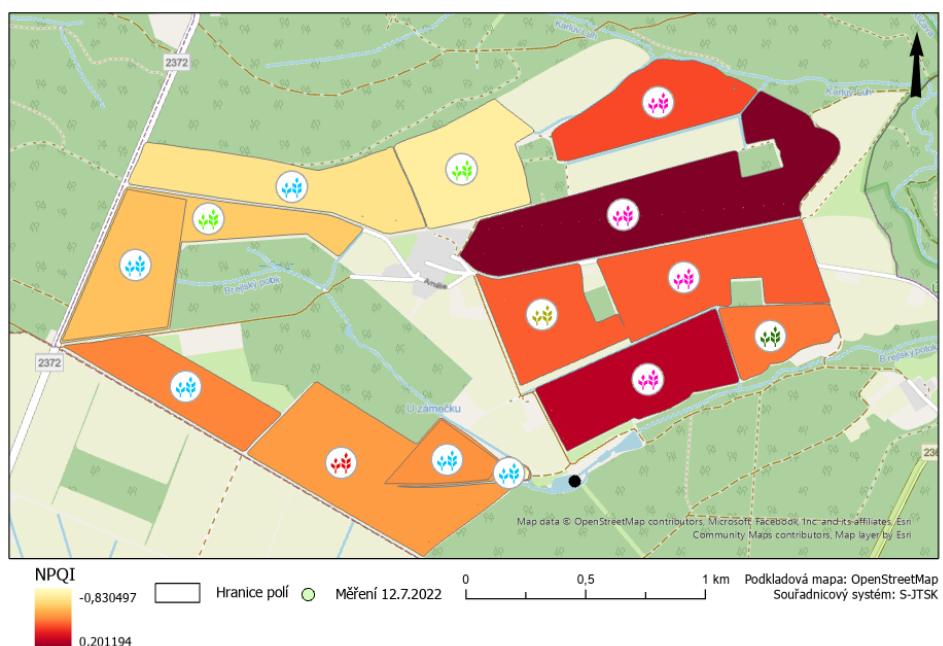
Obr. 29: Rozdíl v hodnotách broadband indexů NDVI ze senzoru PRISMA a spektrometru, barva piktogramu určuje typ plodiny: Ječmen (žlutá) , Pšenice (modrá) , Strniště (světle zelená) , Tráva (tmavě zelená) , Vojtěška (růžová) , Řepka (červená)



Obr. 30: Rozdíl v hodnotách narrowband indexů NDVI ze senzoru PRISMA a spektrometru, barva piktogramu určuje typ plodiny: Ječmen (žlutá) , Pšenice (modrá) , Strniště (světle zelená) , Tráva (tmavě zelená) , Vojtěška (růžová) , Řepka (červená)



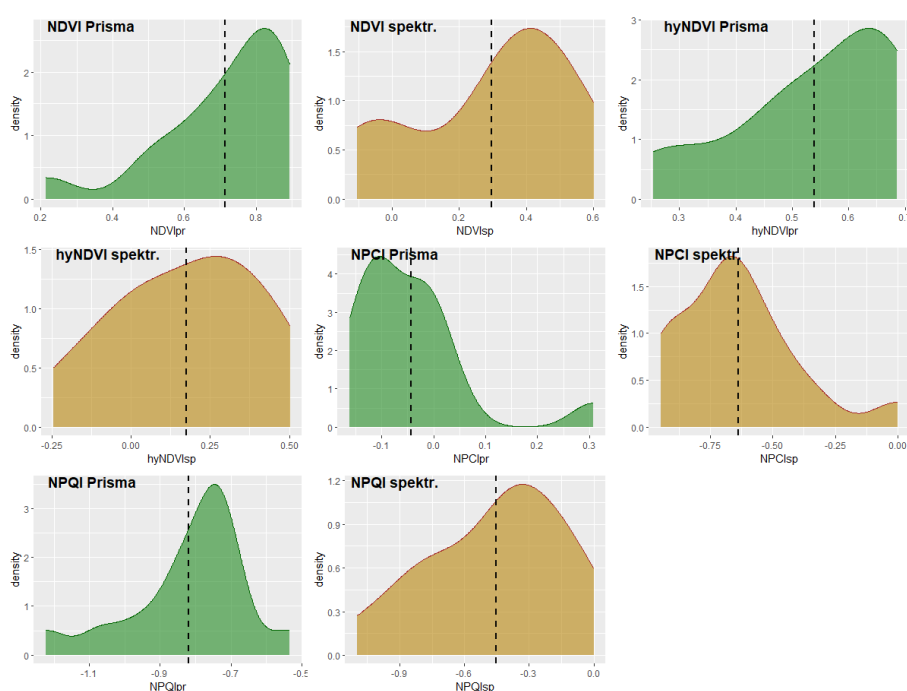
Obr. 31: Rozdíl v hodnotách narrowband indexů NPCI ze senzoru PRISMA a spektrometru, barva piktogramu určuje typ plodiny: Ječmen (žlutá), Pšenice (modrá), Strniště (světle zelená), Tráva (tmavě zelená), Vojtěška (růžová), Řepka (červená)



Obr. 32: Rozdíl v hodnotách narrowband indexů NPQI ze senzoru PRISMA a spektrometru, barva piktogramu určuje typ plodiny: Ječmen (žlutá), Pšenice (modrá), Strniště (světle zelená), Tráva (tmavě zelená), Vojtěška (růžová), Řepka (červená)

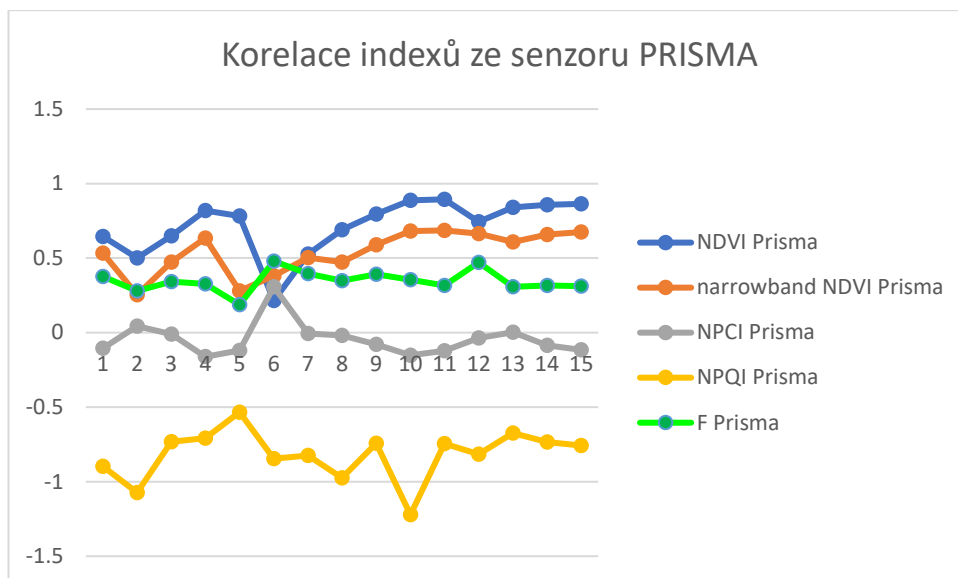
Níže jsou nastíněny výsledky statistických analýz nad hodnotami broadband a narrowband vegetačních indexů. Nejdříve je na obrázku č. 33 vidět rozložení a

vzájemné porovnání hodnot použitých vegetačních indexů. V grafu je vidět znázornění hodnot indexu ze senzoru PRISMA a terénního spektrometru vedle sebe užitím Density plotu. Zelená barva je vždy pro senzor PRISMA a hnědá pro spektrometr. Na první pohled je zřejmé, že nejvíce podobný průběh hodnot má broadband NDVI index. Hodnoty toho indexu ze senzoru Prisma se velmi přibližují hodnotám NDVI indexu ze spektrometru. Na druhou stranu je průměrná hodnota obou indexů rozdílná. To platí i pro minimální a maximální hodnoty indexů.



Obr. 33: Rozdělení hodnot vegetačních indexů ze senzoru PRISMA a spektrometru

Dále jsou představeny výsledky analýzy hledání korelace mezi hodnotami broadband a narrowband indexů ze senzorů PRISMA a hodnot získaných z terénního spektrometru. Na obrázku č. 34 jsou znázorněny nejdříve korelace vybraných vegetačních indexů užitých v této práci. Zde jsou zobrazeny jednotlivé indexy z dat PRISMA formou křivek, které ukazují rozdělení dat indexů. V tabulce č. 8 jsou vidět hodnoty korelačních koeficientů pro jednotlivé indexy. Z grafu je patrné, že nejvíce podobný průběh mají indexy broadband a narrowband NDVI. To potvrzuje i hodnota korelačního koeficientu (viz. Tabulka č. 8). Korelace mezi indexy byla zhodnocena na 0,66. Naopak nejméně korelovanými indexy ze dat PRISMA jsou narrowband NDVI a NPQI s korelací 0.01388178 mezi sebou.

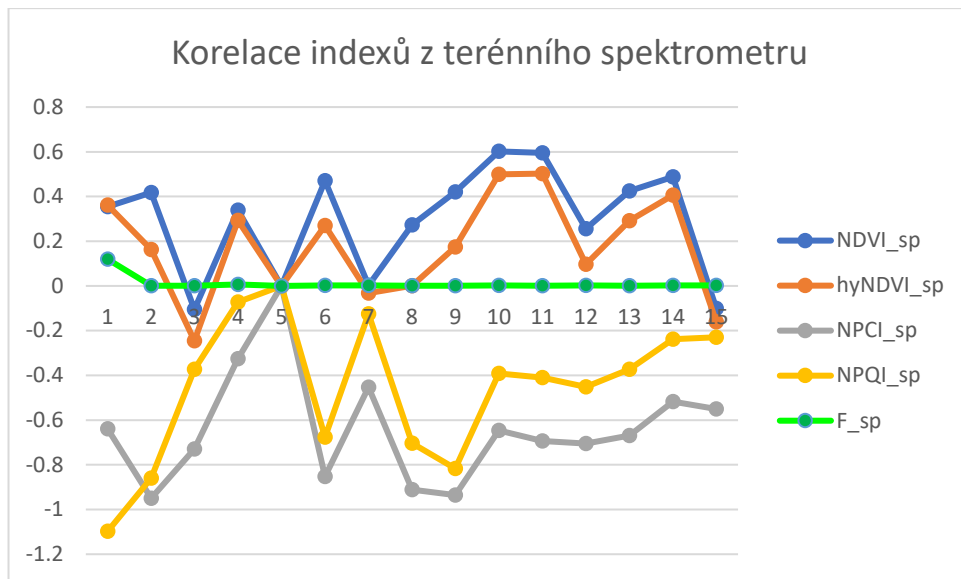


Obr. 34: Korelace vegetačních indexů ze senzoru PRISMA

Tab. 8: Výsledné hodnoty korelace mezi indexy z dat PRISMA

	NDVI_pr	Narr.NDVI_pr	NPCI_pr	NPQI_pr	F_pr
NDVI_pr	1				
narr.NDVI_pr	0.667639	1			
NPCI_pr	-0.88014	-0.5002461	1		
NPQI_pr	0.20845	0.01388178	-0.10285	1	
F_pr	-0.46102	0.27250741	0.496725	-0.2856375	1

Poté je stejným způsobem hodnocena korelace mezi broadband a narrowband indexy, které vznikly z dat terénního spektrometru. Opět jsou hodnoty korelačního koeficientu znázorněny v tabulce č. 9. Grafické znázornění průběhů hodnot jednotlivých indexů je patrné na obr. 35. V tomto případě jsou opět nejvíce korelované indexy z dat spektrometru broadband a narrowband NDVI indexy s korelací 0.9255 mezi sebou. Na druhou stranu indexy, mezi kterými byla určena nejmenší korelace byly narrowband NPCI a fluorescence. V tomto případě byla určena hodnota korelace mezi indexy na 0.017038.



Obr. 35: Korelace vegetačních indexů z terénního spektrometru

Tab. 9: Výsledné hodnoty korelace mezi indexy z dat terénního spektrometru

	NDVI_sp	Narr.NDVI_	NPCI_sp	NPQI_sp	F_sp
NDVI_sp	1				
narr.NDVI_sp	0.9255	1			
NPCI_sp	-0.39469	-0.0795965	1		
NPQI_sp	-0.39556	-0.2074356	0.767215	1	
F_sp	0.07763	0.24301473	0.017038	-0.5421514	1

Nakonec byl celý rozsah hodnot broadband a narrowband indexů ze senzoru PRISMA a ze spektrometru porovnán statistickým testováním. Jako první je v tabulkách č. 10 a 11 zobrazeno, zdali mají data normální rozdělení hodnot. Poté jsou v tabulce č. 12 zobrazeny výsledné hodnoty provedených t.testů, které porovnávaly, jak moc se liší střední hodnoty obou datových sad. Do t.testu vždy vstupovaly nejdříve hodnoty broadband a narrowband indexů ze senzoru PRISMA a poté ze spektrometru. Dále jsou v této tabulce znázorněny i výsledné hodnoty korelace mezi indexy. Nejdříve byla prokázána normální distribuce hodnot pro narrowband indexy NDVI, NPCI a NPQI ze terénního spektrometru. Zbytek indexů ze spektrometru a dále všechny broadband a narrowband indexy ze senzoru PRISMA nejsou normálně rozděleny.



Tab. 10: Výsledky testování normality pro data ze senzoru PRISMA

Index – PRISMA	Hodnota	Normalita
NDVI	0.01733	NE
narr. NDVI	0.04286	NE
NPCI	0.002573	NE
NPQI	0.2059	NE
Fluorescence	0.404	NE

Tab. 11: Výsledky testování normality pro data ze terénního spektrometru

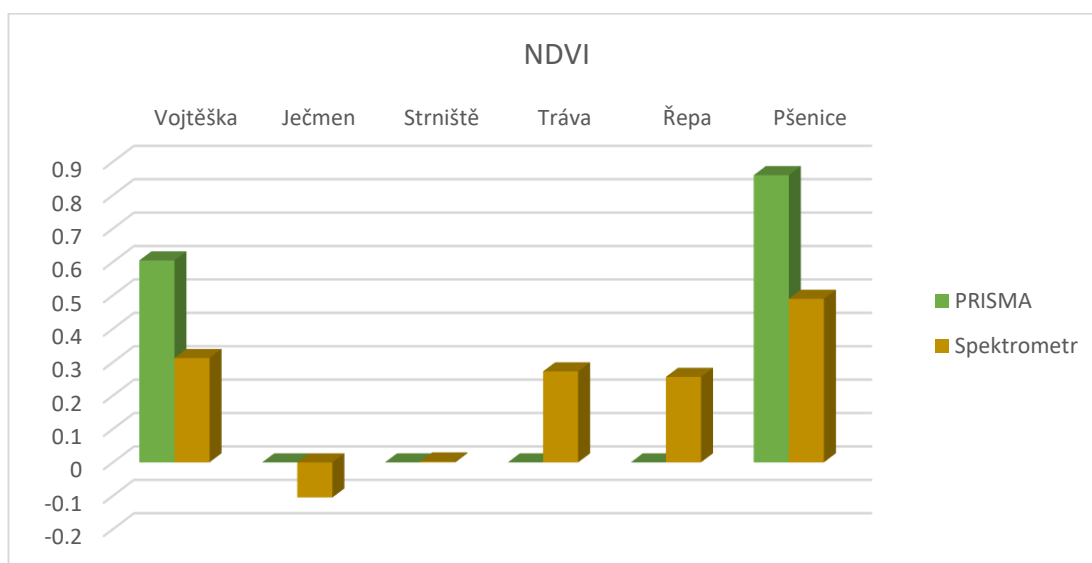
Index – spektrometr	Shapiro-Wilk test	Normalita
NDVI	0.07256	NE
narr. NDVI	0.7345	ANO
NPCI	0.168	ANO
NPQI	0.5943	ANO
Fluorescence	0.0000001858	NE

Tab. 12: Výsledné hodnoty porovnání indexů za dat PRISMA a terénního spektrometru

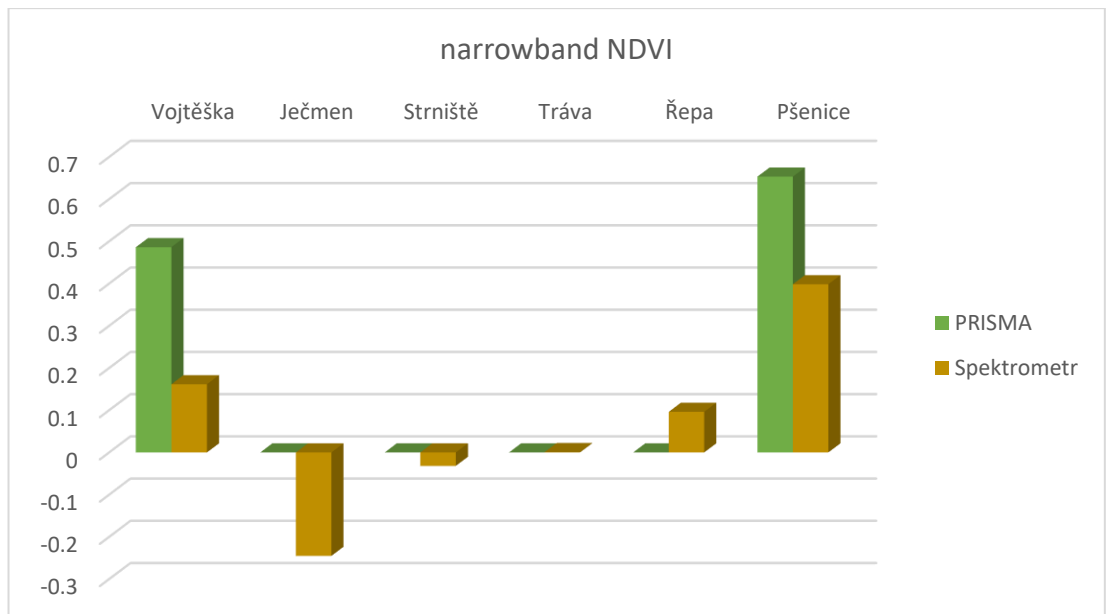
Porovnání	Wilcox test	Korelace
NDVI_pr, NDVI_sp	0.000008819	0,078
narr. NDVI_pr, narr. NDVI_sp	0.00003432	0,355
NPCI_pr, NPCI_sp	0.000003507	-0,462
NPQI_pr, NPQI_sp	0.001408	0,492
F_pr, F_sp	0.00000001289	0,119

Z rozsahů hodnot vypočtených t.testů lze zamítnout nulovou hypotézu na zadané hladině významnosti u všech provedených testů. Všechny p hodnoty jsou menší než 0,05 z čehož lze usuzovat, že jsou střední hodnoty broadband a narrowband indexů ze senzorů PRISMA a terénního spektrometru převážně rozdílné. Již díky této informaci, je možné tvrdit, že se jednotlivé indexy mezi sebou liší. Po testování bylo patrné, že nejnižší výslednou p hodnotu mělo testování narrowband indexu NPQI ze senzoru PRISMA a ze spektrometru. Test určil hodnotu na 0.001408. Sice se zde jedná o nejlepší výsledek, ale prakticky je tato hodnota pořád menší než 0,05. To naznačuje že si nejsou střední hodnoty obou narrowband indexů z obou senzorů, vůbec podobné. Nejvíce podobný průběh mezi sebou měly broadband a narrowband NDVI indexy z dat PRISMA. Indexy spolu velmi silně pozitivně korelovali (korelační koeficient byl v tomto případě 0,66). Mezi vegetačními indexy, vypočítanými přímo z dat terénního spektrometru, opět nejvíce korelovaly broadband a narrowband NDVI

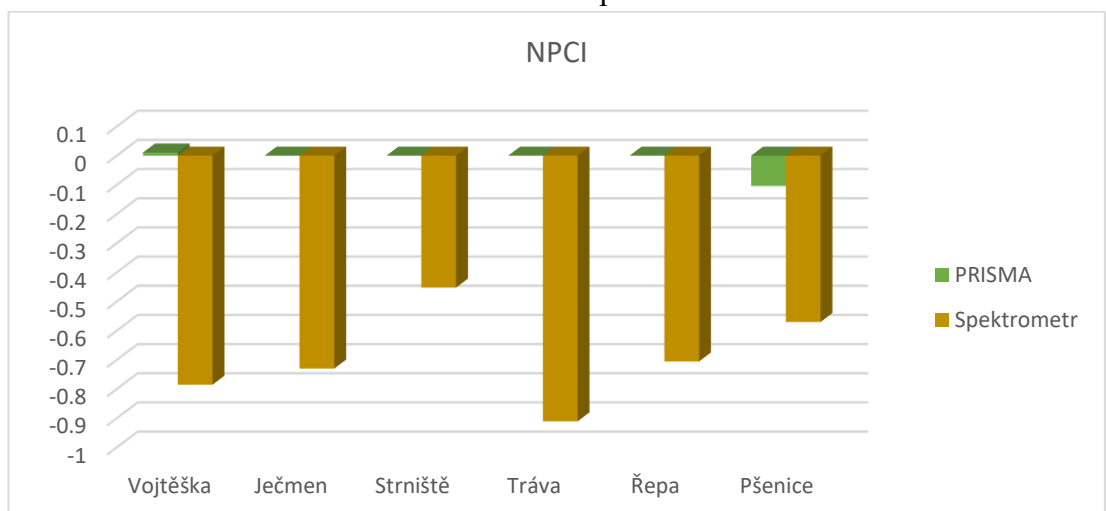
indexy celkovou hodnotou korelace 0,92. Tyto indexy spolu velmi silně korelovaly. Hodnoty korelace mezi indexy z terénního spektrometru je možné vidět v tabulce č. 9. V další části jsou shrnuty výsledky analýz broadband a narrowband vegetačních indexů pro možnou detekce a odlišení zemědělských plodin. Průměrné hodnoty vegetačních indexů jsou pro každou plodinu srovnány ve sloupcových grafech níže. Vždy v zelené barvě jsou hodnoty vegetačních indexů ze senzoru PRISMA a hnědá barva zobrazuje hodnoty indexů ze spektrometru. Jako první jsou vidět na obr. 36 průměrné hodnoty broadband NDVI indexu pro detekci zemědělské plodin. Dále jsou na obr. 37 – 39 graficky znázorněny průměrné hodnoty narrowband indexů opět pro jednotlivé zemědělské plodin. Jako nejpřesnější vegetační index pro detekci plodin byl vyhodnocen narrowband NDVI index. Na druhou stranu nejméně přesným indexem byl narrowband index NPCI.



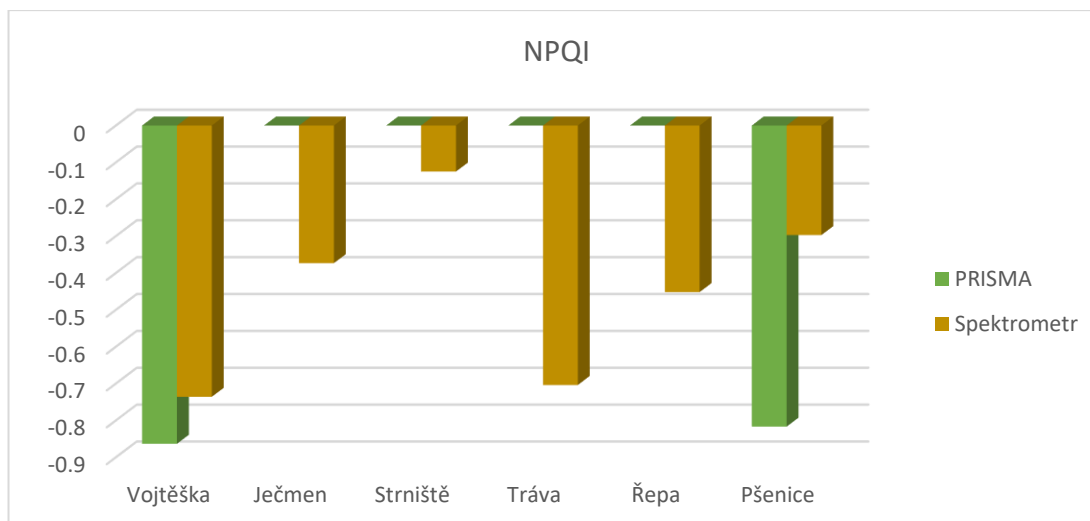
Obr. 36: Porovnání detekce plodin pomocí broadband indexů NDVI ze senzoru PRISMA a terénního spektrometru



Obr. 37: Porovnání detekce plodin pomocí narrowband indexů NDVI ze senzoru PRISMA a terénního spektrometru




Obr. 38: Porovnání detekce plodin pomocí narrowband indexů NPCI ze senzoru PRISMA a terénního spektrometru



Obr. 39: Porovnání detekce plodin pomocí narrowband indexů NPQI ze senzoru PRISMA a terénního spektrometru

Pro potřeby detekce plodin prokázal nejslibnější výsledek narrowband verze NDVI indexu. Nejpresněji index dokázal detekovat a rozlišit travu, strniště a řepku. Tráva z dat PRISMA dosáhla hodnoty indexu 0 a ze spektrometru 0,00073. Stejně tak velmi přesně bylo detekované strniště. Index pro trávy z dat PRISMA byl odhadován na 0 v porovnání se spektrometrem, který hodnotu trávy určil na -0,03. Nakonec velmi podobných hodnot dosahovala i řepka. Z dat PRISMA měla řepka průměrnou hodnotu indexu 0, kdežto terénní spektrometr hodnotu indexu určil na 0,096. Na druhou stranu nejméně přesně detekovanou plodinou v tomto případě byl ječmen, kdy index z dat PRISMA určil jeho hodnotu na 0, ale spektrometr na -0,245. Hůře rozlišitelnou plodinou byla také vojtěška, kdy hodnota indexu NDVI ze senzoru PRISMA byla 0,48, ale při využití spektrometru tato hodnota spadla na 0,16. Na druhou stranu nejméně přesným indexem pro detekci plodin byl narrowband index NPCI.

V další části se se nachází výsledky porovnání broadband a narrowband verzí NDVI indexů. Bylo testováno, jestli se odlišuje přesnost obou indexů vypočítaných ze senzoru PRISMA při rozlišování jednotlivých zemědělských plodin. Přesnost detekce plodin byla porovnána s průměrnými hodnotami obou indexů z dat terénního spektrometru. Nejdříve je možné vidět graficky na obr. 40, jestli mají indexy z obou datových skupin podobný průběh. Dále jsou v tabulce č. 13 znázorněny výsledné hodnoty korelací mezi jednotlivými indexy.

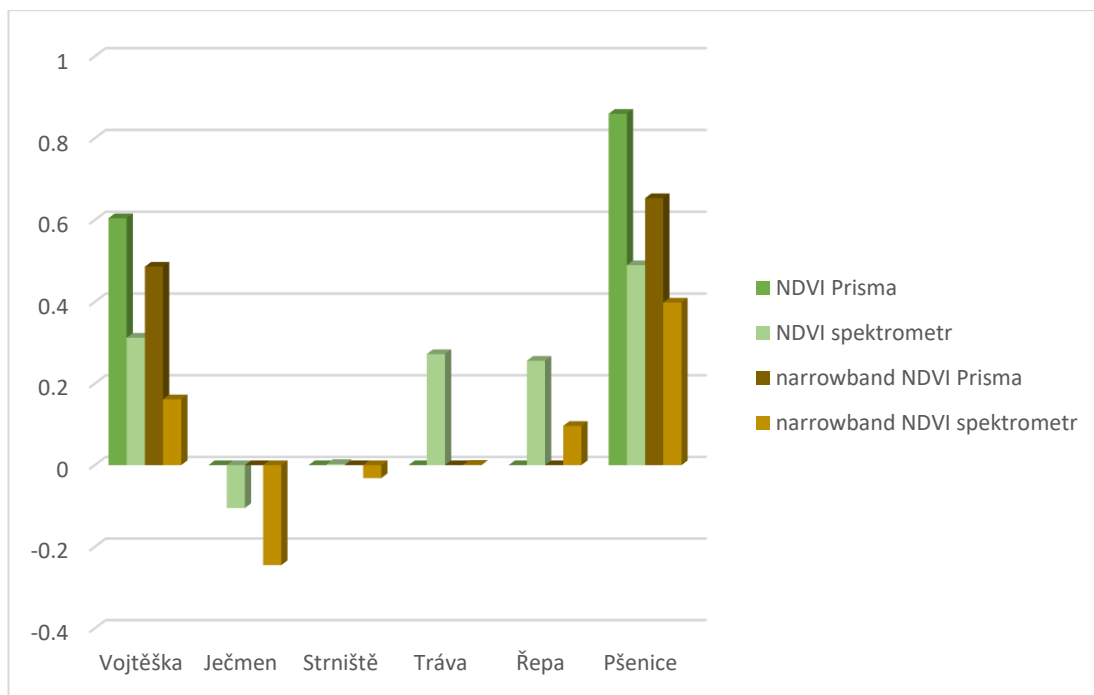


Obr. 40: Korelace broadband a narrowband NDVI indexů z dat PRISMA a spektrometru

Tab. 13: Hodnoty korelace broadband a narrowband NDVI indexů z dat PRISMA a spektrometru

	NDVI_pr	narr.NDVI_pr	NDVI_sp	narr.NDVI_sp
NDVI_pr	1			
narr. NDVI_pr	0.66763943	1		
NDVI_sp	0.078252444	0.255259	1	
narr. NDVI_sp	0.206962988	0.355706	0.9254999	1

Dále jsou průměrné hodnoty NDVI indexů z obou senzorů přiřazeny jednotlivým plodinám v oblasti. Tyto průměrné hodnoty jsou zobrazeny ve sloupcovém grafu na obrázku 41. Zde jsou hodnoty broadband NDVI indexu z obou senzorů znázorněny dvěma odstíny zelené barvy a dále narrowband NDVI index, pocházející z obou senzorů, znázorněn odstíny hnědé barvy.

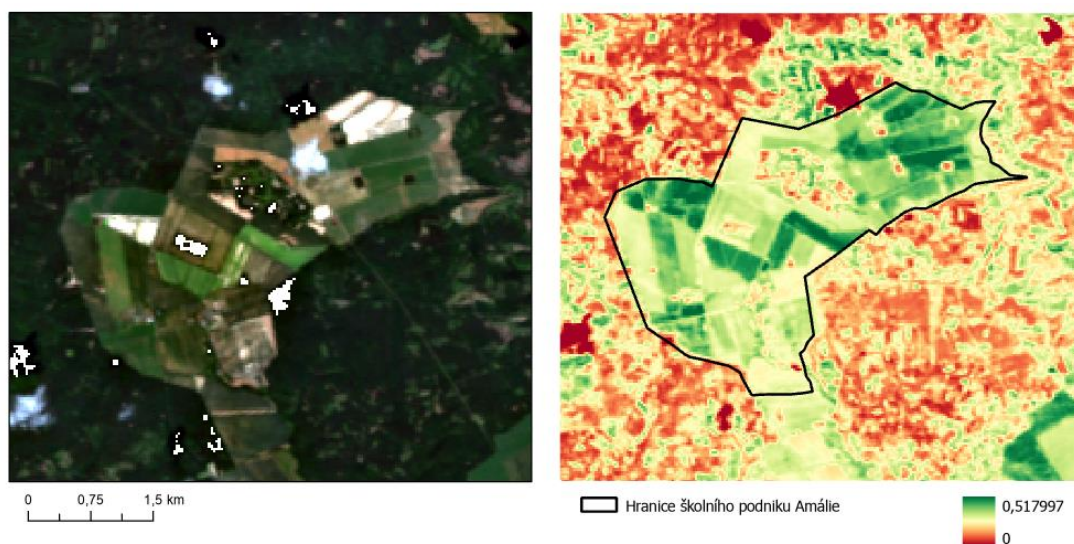


Obr. 41: Porovnání detekce plodin pomocí broadband a narrowband indexů NDVI ze senzoru PRISMA a terénního spektrometru.

Při porovnání hodnot broadband NDVI indexu a narrowband NDVI verze z dat PRISMA jsou vidět četné rozdíly. Oba rastry jsou zobrazeny na obr. 21 a 22. Na první pohled je vidět rozdílný rozsah hodnot samotných rastrů indexů. Broadband NDVI index je v rozmezí hodnot od 0,05 po 0,99, kdežto narrowband NDVI je od -0,68 do 0,89. Mezi oběma indexy z dat PRISMA je korelace 0,66 a indexy ze spektrometru mají mezi sebou korelaci 0,92, jak je vidět v tabulkách 8 a 9. Korelaci mezi NDVI indexy ze spektrometru lze považovat tedy za velmi silnou. Ze senzoru PRISMA je hodnota korelace mezi NDVI indexy spíše středně silná. Toto tvrzení je patrné i z obr. 35.


Na obr. 41 jsou vidět rozdíly detekce plodin mezi jednotlivými indexy. Nejpřesněji byla detekována tráva z narrowband NDVI indexu. Tyto výsledky jsou již popsány výše. V porovnání s broadband NDVI indexem jsou hodnoty pro trávu z narrowband indexu mnohem lepší (broadband NDVI index má více než dvojnásobný rozdíl v hodnotě PRISMA oproti spektrometru). Užitím broadband NDVI indexu bylo velmi přesně detekováno strniště, nicméně hodnoty obou indexů byly velmi podobné. Velmi podobně oba indexy detekovaly pšenici. Průměrně dosahovala pšenice a vojtěška nižších hodnot narrowband NDVI indexu a vyšších hodnot broadband NDVI indexu.

V poslední části jsou znázorněny výsledky analýzy možné detekce fluorescence vegetace ze satelitních hyperspektrálních dat PRISMA. Na obr. 42 je zobrazen výsledek výpočtu fluorescence vegetace použitím tohoto senzoru. Hodnoty fluorescence se pomocí stejného narrowband indexu vypočítaly i z dat terénního spektrometru. Rozdílný rozsah fluorescence z dat PRISMA a ze spektrometru je možné vidět na obr. 43.

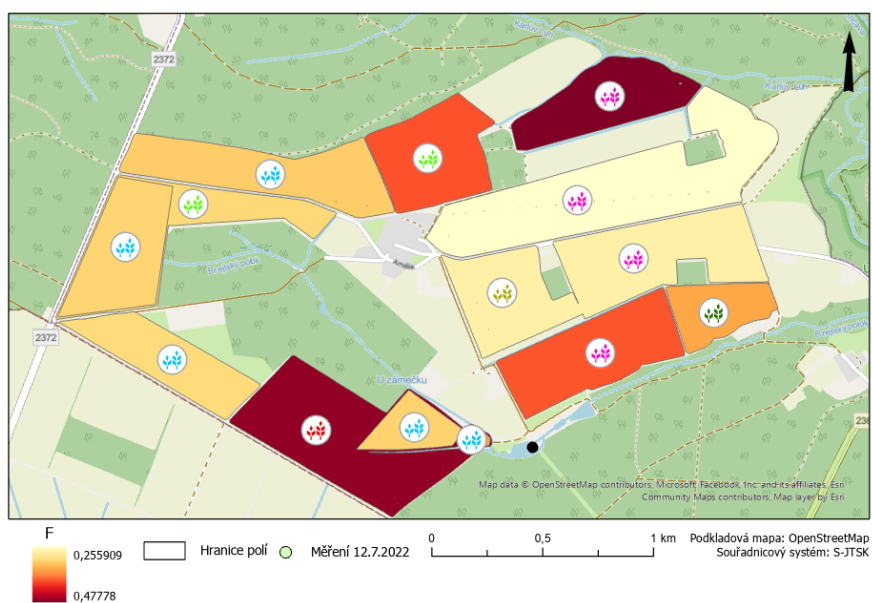


Obr. 42: Výsledný narrowband index fluorescence ze senzoru PRISMA

Vizualizace rozdílu v hodnotách indexů z jednotlivých vstupních dat je zobrazena na obr. 44. V polygonech polí, které se nachází v zemědělském podniku Amálie, jsou vidět hodnoty rozdílu indexů ze senzoru PRISMA a terénního spektrometru. Jednotlivé pole jsou barevně označeny symbolem podle toho, jaká plodina na poli roste. Jednotlivé barvy jsou vysvětleny v popisu obrázku.




Obr. 43: Porovnání hodnot PRISMA a spektrometru – narrowband index fluorescence



Obr. 44: Rozdíl v hodnotách narrowband indexů fluorescence ze senzoru PRISMA a spektrometru barva piktogramu určuje typ plodiny: Ječmen (žlutá) , Pšenice (modrá) , Strniště (světle zelená) , Tráva (tmavě zelená) , Vojtěška (ružová) , Řepa (červená)


Dále jsou průměrné hodnoty fluorescence přiřazeny jednotlivým plodinám v oblasti. Tyto průměrné hodnoty jsou zobrazeny ve sloupcovém grafu na obrázku 45. Opět zelená barva je pro hodnoty narrowband indexu ze satelitu PRISMA a hnědá pro terénní spektrometr.





Obr. 45: Porovnání detekce plodin pomocí fluorescence ze senzoru PRISMA a terénního spektrometru

Na závěr jsou níže zobrazeny výsledky statistických analýz fluorescence vegetace pocházející z narrowband indexu. Nejdříve je na obr. 46 opět vidět rozdíl v rozsahu hodnot fluorescence ze satelitu PRISMA a ze spektrometru pomocí density plotu.



Obr. 46: Rozdělení hodnot fluorescence ze senzoru PRISMA a spektrometru


Nakonec byl index fluorescence z obou datových zdrojů porovnán vůči hodnotám broadband a narrowband NDVI indexů. Jako první byly na obr. 47 porovnány hodnoty indexů ze senzoru PRISMA. Dále jsou v tabulkách 14 a 15 znázorněny výsledky korelace a t.testů mezi indexy.

Z tabulky č. 14 je patrné, že fluorescence s broadband NDVI indexem negativně koreluje, s hodnotou  $-0.46$ . Dále index koreluje s narrowband NDVI indexem s hodnotou  $0,27$ . Z těchto výsledků je možné říci, že hodnota fluorescence nemá podobný průběh jako NDVI indexy. S broadband NDVI indexem jsou hodnoty středně silně a negativně korelované. Dále jsou v tabulce č. 15 znázorněny výsledky testování jednotlivých dat t.testy. Střední hodnoty narrowband a broadband NDVI indexů z dat PRISMA se v porovnání s hodnotami fluorescence velmi lišily. P hodnota testů byla

při porovnání hodnot s oběma indexy velmi odlišná (broadband NDVI dosahoval p hodnotu  $3.744e-05$  a  $0,0008$  narrowband NDVI). Nejvíce podobných středních hodnot dosáhlo testování fluorescence a narrowband NDVI ze spektrometru. Testování vykazalo p hodnotu  $0,014$ . Dále byla mezi těmito daty nalezena pozitivní korelace na úrovni  $0,24$ .

Z výsledků porovnání indexů lze tvrdit, že:

- Nejvíce spolu koreluje fluorescence a narrowband NDVI index dat PRISMA i spektrometru. Hodnota korelace byla  $0,27$  pro senzor PRISMA a  $0.24$  pro spektrometr
- Střední hodnoty jsou nejvíce podobné mezi fluorescencí narrowband NDVI indexem ze spektrometru. P hodnota byla v tomto případě  $0,014$
- Střední hodnoty fluorescence a broadband NDVI indexu ze sezoru PRISMA jsou velmi odlišné. To stejné platí i pro střední hodnoty narrowband NDVI indexu a fluorescence



Obr. 47: Korelace NDVI indexů a fluorescence

Tab. 14: Hodnoty korelace mezi broadband a narrowband NDVI indexy a fluorescencí z dat PRISMA

Index	NDVI_pr	narr.NDVI_pr	F_pr
NDVI_pr	1		
narr. NDVI_pr	0.66	1	
F_pr	-0.46	0.27	1

Tab. 15: Výsledné hodnoty porovnání fluorescence z broadband a narrowband NDVI indexy

Index	korelace	t.test
F_p, NDVI_p	-0.46	3.744e-05
F_p, narr. NDVI_p	0.27	0.0008777
F_sp, NDVI_sp	0.07	0.0003747
F_sp, narr. NDVI_sp	0.24	0.01491

## 7 Diskuse

Tato diplomová práce se zaměřuje na možnou detekci zemědělských plodin z hyperspektrálních snímků PRISMA v oblasti školního podniku Lány. K predikci plodin byly použity broadband a narrowband typy vegetačních indexů, které byly porovnány mezi sebou. Jako broadband index zde byl zvolen standardní vegetační index NDVI. Primárně se ale práce soustředila na detekci plodin z narrowband indexů. Těmito indexy jsou NDVI index upravený pro úzká pásma hyperspektrálních dat, chlorofylové indexy NPCI a NPQI, a nakonec index pro odhad hodnot fluorescence vegetace. Na základě provedené literární rešerše je zřejmé, že se jedná o první práci v České republice zaměřenou na využití narrowband indexů v oblasti detekce zemědělských plodin vypočítaných z dat pořízených družicí PRISMA. Doposud bylo publikováno několik zahraničních studií, které se zaměřovaly na podobnou tematiku. Data ze stejného senzoru využívali například Marshall et al. (2022a), kteří porovnávali 3 různé metody pro detekci plodin, a to dvoupásmové vegetační indexy, částečnou regresi nejmenších čtverců a metodu random forest. Na rozdíl od této diplomové práce mezi sebou autoři porovnávali více způsobů využitelných pro detekci. Moje práce byla oproti tomu zaměřena na detailní porovnání vybraných vegetačních indexů. Další relativně starší výzkum provedl Liu et al. (2017), kde autoři využívali vegetační indexy pro výpočet procentuálního arktického vegetačního pokryvu v Kanadě, na Melville Island. Při výzkumu využívali multispektrální snímky ze satelitu WorldView-3, hyperspektrální data ze senzoru Hyperion a dále naměřené hodnoty spektrální radiance z terénního spektrometru ASD FieldSpec. K detekci autoři využili mnoho různých vegetačních indexů. Dle závěrů této studie vyplývá, že narrowband indexy korelují s procentem vegetačního pokryvu zelenou vegetace. Použitá data Hyperion mají stejné spektrální rozlišení jako senzor PRISMA, a to 10 nm. Nicméně výsledky broadband a narrowband indexů zde není možné přímo porovnávat s mojí prací, jelikož, jak sami autoři tvrdí, je arktická tundra velmi odlišným prostředím od ostatních biotopů. V dalším výzkumu se Marshall & Thenkabail (2015) snaží nastínit výhody užití hyperspektrálních dat Hyperion EO-1 oproti multispektrálním datům IKONOS, GeoEye-1, WorldView-2, Landsat ETM+ a MODIS pro odhady biomasy plodin. Konkrétně při tomto výzkumu se odhadovala biomasa vojtěšky, bavlny, kukuřice a rýže. Autoři prokázali, že vyšší spektrální rozlišení senzoru Hyperion umožňuje využít narrowband vegetační indexy, kterými lze lépe odhadovat biomasu plodin. V tomto výzkumu je uvažováno i různé časové rozlišení vstupních dat. Výsledky prokázaly, že

i když má v porovnání s multispektrálními senzory Hyperion horší časové rozlišení, je stále lepší variantou pro odhad biomasy plodin, primárně kvůli vyššímu spektrálnímu rozlišení. Nakonec zde je uveden výzkum, ve kterém se autoři snaží prokázat využitelnost senzoru PRISMA i v jiné oblasti, než je odhad biomasy a detekce plodin. (Chabrilat et al., 2022) provedli výzkum, při kterém se zaměřili na možnosti odvození úrodnosti půdy v severním Maroku právě z tohoto senzoru. Autoři potvrdili využitelnost senzoru k tomuto účelu a dokonce tvrdí, že může poskytnout i úplně nové metody určení úrodnosti půdy.

Pro diplomovou práci bylo vytyčeno několik výzkumných cílů. Prvním z nich bylo porovnání hodnot broadband a narrowband vegetačních indexů vypočítaných ze senzoru PRISMA a terénního spektrometru a určení, zdali se mezi sebou liší.

Na základě výsledků dosažených v závěrečné práci lze konstatovat, že při porovnání hodnot broadband a narrowband indexů z dat PRISMA a z terénního spektrometru, nebyla prokázána korelace na dostatečně vysoké úrovni. Jelikož jsou hodnoty z terénního spektrometru brány jako referenční, nelze broadband a narrowband indexy z dat PRISMA považovat za stoprocentně věrohodné. Výrazně se totiž odlišují, jak od terénního měření, tak mezi sebou, což může mít i případný vliv na možnou aplikaci těchto indexů. Dále byla porovnána přesnost detekce zemědělských plodin oběma indexy. Z výsledků lze konstatovat, že detekce plodin je pomocí narrowband indexu NDVI proveditelná. Dokonce je i přesnější než broadband NDVI vegetačním indexem. Nicméně rozdíly v hodnotách hůře detekovaných plodin, jako jsou vojtěška nebo ječmen, oproti terénnímu spektrometru jsou stále velmi vysoké, díky čemuž by bylo na místě zvážit případnou alternativní metodu detekce.

Dalším cílem bylo porovnání hodnot broadband a narrowband NDVI indexů z dat PRISMA a zhodnocení přesnosti detekce zemědělských plodin. Výsledky prokázaly, že jsou mezi indexy četné rozdíly. To je dáno především užitím úzkých pásem hyperspektrálních dat oproti broadband NDVI indexu. Již v rozsahu hodnot obou indexů je znatelný rozdíl. Při porovnání hodnot obou indexů byla prokázána silná korelace oběma indexy z dat terénního spektrometru, kdežto mezi oběma indexy ze senzoru PRISMA byla korelace spíše střední. Samotné indexy se lišily i v přesnosti detekce jednotlivých zemědělských plodin. Narrowband index detekoval nejpřesněji travu, naopak strniště bylo velmi přesně detekováno broadband indexem. V tomto případě, ale hodnoty obou indexů byly podobné. Přesnost je dána opět díky užití užších

hyperspektrálních pásem. Tyto pásma jsou zvláště citlivá na změny obsahu chlorofylu a strukturálních vlastností canopy. Indexy byly schopné stejně dobře rozlišit pšenici na polích. Rozdíl byl, ale v průměrných hodnotách, kdy pšenice měla vyšší hodnotu z broadband NDVI indexu. I když byl broadband index v tomto případě užitečný, v praxi je lepší pro detekci plodin použít právě narrowband indexy. Hlavním důvodem je jejich větší citlivost na biofyzikální a chemické parametry. To má vliv na detekci plodin v jednotlivých růstových fázích. Tyto parametry by broadband indexy nebylo možné získat.

Jedním z limitů použití senzoru PRISMA je nižší prostorové i spektrální rozlišení. 30 m velký pixel nemusí být pro některé zemědělské aplikace dostačující a to stejné platí také o šířce spektrálních pásem. Nedostatečné prostorové rozlišení by mohlo být překonáno například kombinací hyperspektrálních dat s některými multispektrálními daty s vyšším prostorovým rozlišením. Dalším omezením detekce plodin byl způsob snímání dat. Při terénním měření spektrometrem se snímaly jednotlivé listy plodin, kdežto hyperspektrální satelit snímá vždy celou plochu pole na úrovni canopy. Proto nejsou ve spektrální odezvě z dat PRISMA pouze hodnoty plodin. Z pravidla jsou k těmto informacím přimíchány hodnoty odrazivosti z půdy nebo také sousední vegetace.

Posledním cílem práce bylo prokázat možnost detekce fluorescence vegetace pomocí hyperspektrálních dat PRISMA. Fluorescence byla odhadnuta pomocí narrowband indexu z vybraných pásem PRISMA. Do indexu vstupovaly hodnoty kolem reflektance uvnitř pásma absorpce chlorofylu O2-A (740 nm), která se podělila hodnotami reflektance v okolí tohoto pásma viz kapitola 5.5. Emise fluorescence může nastat ve dvou specifických vrcholech, a to v části červeného pásma 685 nm a dále v části tzv. far-red, oblast 740 nm spektra viz obr. č. 6 (Kováč et al., 2022). Hodnota pásma v oblasti 740 nm zobrazená obr. 20, byla pro výzkum vybrána z důvodu častého užití mnoha dalšími autory, kteří detekovali fluorescenci vegetace. Jako příklad těchto studií zde uvedu jen několik výzkumů. Jedná se například o výzkumy od Krämer et al. (2021), Longmire et al. (2022) a Wang et al. (2022). Podle Du et al. (2020b) je v tomto absorpčním pásmu vyšší hodnota možné fluorescence, čímž je snazší ji detekovat satelitním DPZ. Výsledky prokázali velkou odlišnost odhadnutých hodnot fluorescence z hyperspektrálních dat PRISMA a terénního spektrometru.

Určitě je na místě zmínit několik potenciálních nedostatků při detekci fluorescence zvolenou metodou. Standardně se fluorescence detekuje užitím radiative transfer modelů, které jsou pro měření mnohem vhodnější. Jejich použití však přesahuje stanovený rozsah diplomové práce, a proto bylo od této metody upuštěno. Ve zkratce se jedná o modely, které popisují komplexní interakce záření v momentě, kdy prochází atmosférou. Teoretické modely určují, jaký mají vliv na záření složky atmosféry, vody, vegetace a půdy (Svendsen et al., 2021). Dalším nedostatkem je možno považovat použitou referenční hodnotu, která byla vypočítaná z dat terénního spektrometru. Spektrometr se často neuvádí jako nejvhodnější metoda detekce fluorescence. Přesnost detekce fluorescence se odvíjí podle spektrálního rozlišení senzoru. Pro možnou detekci je nutné použít senzor s velmi vysokým spektrálním rozlišením (S. Li et al., 2021). I když spektrometr nedosahuje nejdělnějšího rozlišení v zájmové oblasti spektra jako například fluorometr (hodnoty menší než 1 nm), je jeho rozlišení podstatně lepší než rozlišení senzoru PRISMA. Nejpřesnějším způsobem, jak získat hodnoty fluorescence z terénu je použitím již dříve zmíněného fluorometru. To při mém výzkumu nebylo možné, jelikož Fakulta životního prostředí na ČZU tímto přístrojem nedisponuje. Na závěr chci zmínit, že přesnost fluorescence z dat PRISMA tedy není díky využití referenčních dat naměřených spektrometrem stoprocentně ověřena. Pro dosažení věrohodnějších výsledků by bylo třeba její porovnání s hodnotami terénního měření pozemním fluorimetrem. Pro detekci fluorescence je nutné použít hyperspektrální družicové senzory, které budou mít současně vyšší prostorové rozlišení (alespoň 20 m) a také dostatečně vysoké spektrální rozlišení (0,3 nm). Přesnost senzoru PRISMA pro tuto aplikaci není dostačující a je potřeba výsledné hodnoty vždy porovnat s terénní referencí. V budoucnu by bylo zajímavé výsledek fluorescence z této práce porovnat s hodnotami z terénního fluorometru.

Je dobré zmínit určitou úroveň nepřesnosti při práci se senzorem PRISMA a s terénním spektrometrem. V návaznosti na porovnání indexů mezi těmito daty je potřeba mít na paměti, jakého prostorového rozlišení dosahují oba senzory. Senzor PRISMA poskytuje prostorové rozlišení jednoho pixelu 30 metrů, kdežto data ze spektrometru jsou v rozlišení cca 20 cm. Oba tyto senzory mají rozdílné také spektrální rozlišení. PRISMA dosahuje spektrálního rozlišení  $\leq 12$  nm v porovnání s terénním spektrometrem který má 3 – 10 nm. Tento rozdíl nebyl v metodice diplomové práci nijak ošetřen. Při výzkumu od Moravec et al. (2021), kde se autoři soustředili na vlivy

atmosférických korekcí na NDVI index a dále na možnou porovnatelnost UAV a satelitních snímků. Spektrální rozdílnost jednotlivých senzorů rovněž nebyla brána v potaz a z tohoto důvodu, jsem se v této práci tímto problémem detailněji nezabýval.

Podle mého názoru jsou hyperspektrální data budoucností dálkového průzkumu Země. Tyto data obsahují více environmentálně smysluplných informací než multispektrální snímky. Řekl bych, že hyperspektrální snímání bude hrát významnou roli v oceánografii, lesnictví, ekologii i zemědělství. Díky vyššímu spektrálnímu rozlišení bude možné zachytit a rozlišit jemné rozdíly mezi jednotlivými plodinami a dále bude možné data využít k vysvětlení biochemických a biofyzikálních vlastností zemědělských plodin. V budoucnu bude hrát významnou roli i miniaturizace snímacích senzorů. Další pokroky v metodách strojového učení a cloudového zpracování dramaticky změní a zjednoduší možnosti využití těchto dat. Pokroky v hyperspektrálním snímání také kompletně změní způsob klimatických předpovědí.



## 8 Závěr

Satelitní hyperspektrální data jsou v dnešní době velmi užitečným nástrojem pro monitoring zemědělských plodin. Díky vývoji technologie v oblasti dálkového průzkumu Země je dnes možné pozorovat velký rozmach hyperspektrálních satelitních misí. Tato data jsou kvůli užším spektrálním pásmům více citlivá na případné změny v samotných zemědělských plodinách v porovnání se standardními širokopásmovými multispektrálními daty. Do dnešní doby bylo publikováno několik studií potvrzujících využitelnost senzoru PRISMA v oblasti zemědělství a k bližšímu pochopení této tematiky přispívají i výsledky této diplomové práce.

Cílem diplomové práce bylo validovat spektrální přesnosti hyperspektrální družice PRISMA, a to pomocí referenčních dat pořízených v době přeletu družice nad zvoleným zájmovým územím terénním spektrometrem ASD FieldSpec 4. V diplomové práci byla porovnána přesnost na příkladu broadband a narrowband vegetačních indexů, které byly dále využity k potenciální detekci zemědělských plodin. Mimo hodnocení vegetačních indexů se práce zabývala možností detekce fluorescence vegetace ze senzoru PRISMA. Diplomová práce byla uspořádána do pěti navazujících částí.

První část se zaměřuje na stručný popis problematiky detekce zemědělských plodin metodami DPZ. Ve druhé části je popsáno před-zpracování hyperspektrálního snímku pomocí software ENVI. V další části proběhl automatický výpočet broadband NDVI indexu a dále ruční výpočet narrowband indexů z dat PRISMA. Na tuto část navazuje výpočet stejných vegetačních indexů z dat terénního spektrometru. Poté byla ze snímku PRISMA odhadnuta hodnota fluorescence vegetace. Poslední část práce se zabývá statistickým zhodnocení indexů získaných z dat PRISMA s hodnotami indexů vypočítaných z dat terénního spektrometru.

Na základě výsledků diplomové práce je možné zodpovědět v zadání stanovené výzkumné otázky:

- a) Hodnoty pokročilých vegetačních indexů vypočítaných z hyperspektrálních dat PRISMA se oproti pokročilým indexům vypočítaných z dat terénního spektrometru velmi odlišují. Nejvíce podobný byl narrowband index NPQI se střední korelací 0,49. Při dalším porovnání středních hodnot z dat PRISMA a spektrometru tohoto indexu byla prokázána velká rozdílnost. Hodnota t.testu byla 0,001408. Na druhou stranu nejméně podobným indexem byl narrowband

index fluorescence. Při porovnání středních hodnot tohoto indexu dosáhl Wilcoxonův test výsledku 0,00074.

- b) Vyhodnocení využitelnosti z hyperspektrálních dat PRISMA pro detekci plodin je nejednoznačná. Hodnoty pro jednotlivé plodiny vypočítané z dat PRISMA a ze spektrometru se totiž velmi odlišují. Nicméně nejvíce podobných průměrných hodnot z dat PRISMA a terénního spektrometru dosáhl narrowband index NDVI pro detekci trávy. Dále lze mezi lépe detekované plodiny považovat strniště a řepku.
- c) Hodnoty broadband a narrowband NDVI indexů vypočítaných z hyperspektrálních dat PRISMA se rovněž odlišují. Podobných hodnot obou indexů bylo dosaženo pro detekci strniště a řepky. Mezi samotnými indexy je středně silná korelace 0,66. Střední hodnoty obou indexů se také velmi liší. Výsledek Wilcoxova testu byl 0.003674.
- d) Pomocí hyperspektrálních dat ze senzoru PRISMA je možné detekovat fluorescenci vegetace, nicméně i za použití spektrometru jako referenčních hodnot, je tato detekce velmi nepřesná. Hodnoty fluorescence z dat PRISMA a spektrometru mají mezi sebou velmi nízkou korelaci. Korelační koeficient byl určen na 0,11. Při porovnání průběhu hodnot fluorescence s narrowband indexem NDVI byla prokázána korelace na úrovni 0,27. Proto nejsou hyperspektrální data ze senzoru PRISMA tím nejvhodnější datovým zdrojem pro detekci fluorescence vegetace.

Hlavní přínos práce spočívá v prokázání možností aplikace hyperspektrálního snímání v zemědělství. Dále práce prokázala kvalitnější detekci plodin užitím narrowband NDVI indexu. V návaznosti na toto téma je momentálně v přípravě nová hyperspektrální mise CHIME umožňující mimo jiné detailní klasifikaci krajinného pokryvu a nová mise FLEX zaměřená na globální detekci fluorescence.

## 9 Přílohy

### 9.1 Seznam tabulek

Tabulka 1: Seznam hyperspektrálních satelitů

Tabulka 2: Charakteristika satelitu PRISMA, zdroj:

<https://www.eoportal.org/satellite-missions/prisma-hyperspectral#mission-status>

Tabulka 3: Charakteristika senzoru PRISMA, zdroj:

<https://www.eoportal.org/satellite-missions/prisma-hyperspectral#mission-status>

Tabulka 4: Vybrané broadband vegetační indexy v této práci

Tabulka 5: Typické hodnoty NDVI indexu, zdroj: Dobrovolný, 1998 – senzor AVHRR

Tabulka 6: Vybrané narrowband vegetační indexy

Tabulka 7: Seznam lokalit bodů terénního měření

Tabulka 8: Výsledné hodnoty korelace mezi indexy z dat Prisma

Tabulka 9: Výsledné hodnoty korelace mezi indexy z dat terénního spektrometru

Tabulka 10: Výsledky testování normality pro data ze senzoru Prisma

Tabulka 11: Výsledky testování normality pro data ze terénního spektrometru

Tabulka 12: Výsledné hodnoty porovnání indexů za dat Prisma a terénního spektrometru

Tabulka 13: Hodnoty korelace broadband a narrowband NDVI indexů z dat Prisma a spektrometru

Tabulka 14: Hodnoty korelace mezi broadband a narrowband NDVI indexy a fluorescencí z dat Prisma

Tabulka 15: Výsledné hodnoty porovnání fluorescence z broadband a narrowband NDVI indexy

Tabulka 16

Výzkumy zaměřené na metody detekce plodin z hyperspektrálních dat			
Název	Autor	Data	Detekce plodin
1. Detekce stresu v plodinách pomocí hyperspektrálního DPZ a modelů fyzikální simulace (2004)	P.J. Zarco-Tejada et al	Hodnoty terénního spektrometru	Indexy CARI, MCARI, SAVI, OSAVI Použití modelu PROSPECT
2. Klasifikace land cover z hyperspektrálních dat v rekultivovaných oblastech Sokolovské hnědouhelné pánve (2010)	H. Málková et al	Senzor HyMap	Klasifikace povrchu – Max. Like., Min. Dist., Mahal. Dist.
3. Detekce časných reakcí rostlin na stres pomocí hyperspektrálních snímků (2014)	J. Behman et al	Laboratorní hyperspektrální senzor SOC-700	Velké množství vegetačních indexů, klasifikace SVM (dobré pro sucho, detekuje senescenci)
4. Hybridní možnosti získávání vlastností plodin z multitemporálních hyperspektrálních snímků PRISMA (2022)	G. Tagliabu et al	Snímky PRISMA	Indexy LAI, leaf nitrogen content, leaf chlorophyll index, leaf water content
5. Odhad výnosů plodin na úrovni polí pomocí dat PRISMA a Sentinel-2 (2022)	M.Marshall et al	Snímky PRISMA a Sentinel - 2	Index TBVI, částečná regrese nejmenších čtverců, Random Forest
6. Hyperspektrální snímání chorob rostlin: Principy a metody (2022)	L. Wan et al	X	Shrnutí různých dostupných metod detekce chorob rostlin

7. Detekce stresu u rajčat vyvolaný plísni v Kalifornii, USA, pomocí hyperspektrálního dálkového průzkumu	M. Zhang et al	Letecké snímky AVIRIS, terénní spektrometr	MNF transformace a následně klasifikace SAM, včasná detekce těžko detekovatelná
---	----------------	--	---

Tabulka 17

Výzkumy zaměřené na detekci fluorescence			
Název	Autor	Data	Fluorescence
1. Vztahy mezi čistou (celkovou) fotosyntézou a ustálenou fluorescencí chlorofylu získanou z leteckého hyperspektrálního zobrazení (2012)	P.J.Zarco.Tejada, A.Catalin, M.R. Gonzalez, P.Martín	UAV + Micro-Hyperspec	FLD
2. Paralelní sezónní vzorce fotosyntézy, fluorescence a indexů odrazivosti na boreálních stromech (2015 – 2017)	K.R.Springer, R. Wang, J.A.Gamon	Spektrometr UniSpec-DC Fluormetr Mini-PAM	Indexy NDVI, PRI + Metoda CCI
3. Měření povrchové odrazivosti a sluncem indukované fluorescenční spektroskopie pomocí malého hyperspektrálního UAS (2017)	R. Garzonio, B. Di Mauro et al.	UAV + senzor HyUAS	Indexy NDVI, MTCI, PRI + 3FLD
4. Fluorescenční zobrazovací spektrometr FLORIS pro ESA FLEX misi (2017)	P. Coppo, A.Taiti et al.	Senzor FLORIS (Popis FLEX)	Nízké rozlišení: 500-677 nm & 697-740 nm O2B: 677-697 nm O2A: 740-780 nm

5. Odrážejí denní a sezónní trendy ve fluorescenci listů indukované slunečními paprsky změny ve fotosyntéze, růstu nebo vystavení světlu? (2017)	R.Wyber, Z.Malenovsk ý, et al.	UAV: použití tripodu Senzor LIFT Senzor QE Pro	Indexy NDVI, PRI, SIF Pozemní fluormetr MDS analýza
6. An Unmanned Aerial System (UAS) pro souběžná měření slunečním zářením indukované fluorescence chlorofylu a hyperspektrální odrazivosti za účelem zlepšení monitorování plodin (2019)	Christine Y. Chang, Ruiqing Zhou et al.	Vlastní UAV + termální QE-pro senzor	Indexy NDVI, WDRI, PRI, L  SFM
7. Nedávné trendy a pokroky v technikách hyperspektrálního snímání pro odhad slunečním zářením indukované fluorescence pro fenotypování rostlin (2022)	P.Mangalraj, Byoung- Kwan Cho	X	Metody založené na reflektanci (RR,DI,II) Metody založené na radianci (FLD,SFM)

## 9.2 Seznam obrázků

Obr. 1: Diagram elektromagnetického spektra, zdroj: <https://cs.khanacademy.org>

Obr. 2: Porovnání způsobů hyperspektrálního snímání: (A) – Whiskbroom, (B) – Pushbroom, (C) – Plane scanning, (D) – Snapshot, zdroj:

[https://dspace.cvut.cz/bitstream/handle/10467/95287/F3-DP-2021-Ruzicka-Miroslav-Parametry\\_hyperspektralnich\\_snimacich\\_systemu.pdf?sequence=1&isAllowed=y](https://dspace.cvut.cz/bitstream/handle/10467/95287/F3-DP-2021-Ruzicka-Miroslav-Parametry_hyperspektralnich_snimacich_systemu.pdf?sequence=1&isAllowed=y)

Obr.3: Satelit PRISMA, zdroj: <https://www.asi.it/scienze-della-terra/prisma/>

Obr. 4: Spektrální křivka vegetace, zdroj: [https://www.researchgate.net/figure/The-spectral-reflectance-curve-of-vegetation-The-major-absorption-and-reflectance\\_fig4\\_315797574](https://www.researchgate.net/figure/The-spectral-reflectance-curve-of-vegetation-The-major-absorption-and-reflectance_fig4_315797574)

Obr. 5: LAI index na globálním měřítku, zdroj:

<https://land.copernicus.eu/global/products/lai>

Obr. 6: Grafické znázornění oblastí emisí solárně indukované fluorescence, zdroj:

<https://www.sciencedirect.com/science/article/pii/S1470160X22001923>

Obr. 7: Logo mise FLEX, zdroj:

[https://www.esa.int/Applications/Observing\\_the\\_Earth/FutureEO/FLEX](https://www.esa.int/Applications/Observing_the_Earth/FutureEO/FLEX)

Obr. 8: Vizualizace satelitu FLEX, zdroj:

<https://earth.esa.int/eogateway/missions/flex>

Obr. 9: Zájmová oblast výzkumu

Obr. 10: Zobrazení krajinného pokryvu ČR, zdroj: [https://www.cenia.cz/wp-content/uploads/2022/01/Kraje\\_2020\\_STC.pdf](https://www.cenia.cz/wp-content/uploads/2022/01/Kraje_2020_STC.pdf)

Obr. 11: Zobrazení klimatických oblastí ČR, zdroj: [https://www.cenia.cz/wp-content/uploads/2022/01/Kraje\\_2020\\_STC.pdf](https://www.cenia.cz/wp-content/uploads/2022/01/Kraje_2020_STC.pdf)

Obr. 12: Logo mise PRISMA, zdroj:

[https://www.enea.it/it/seguici/events/telerilevamento\\_25-26giu2019/ASIPRISMA\\_Guarini.pdf](https://www.enea.it/it/seguici/events/telerilevamento_25-26giu2019/ASIPRISMA_Guarini.pdf)

Obr. 13: Zobrazení vstupního snímku PRISMA

Obr. 14: Lokality terénního měření

Obr. 15: Oblast terénního měření spektrometrem

- Obr. 16: Diagram ořezu vstupních snímků
- Obr. 17: Zobrazení jednotlivých hyperkrychlí ze snímku PRISMA
- Obr. 18: Zobrazení sjednoceného souboru v RGB kombinaci (31-20-10) a v false color kombinaci (63-35-17)
- Obr. 19: Výsledné kontinuální spektrum kompozitu (příklad spektra lesa)
- Obr. 20: Pásmo absorpce chlorofylu
- Obr. 21: Výsledný broadband NDVI index ze senzoru PRISMA
- Obr. 22: Výsledný narrowband NDVI index ze senzoru PRISMA
- Obr. 23: Výsledný narrowband NPCI index ze senzoru PRISMA
- Obr. 24: Výsledný narrowband NPQI index ze senzoru PRISMA
- Obr. 25: Porovnání hodnot PRISMA a spektrometru – broadband NDVI index
- Obr. 26: Porovnání hodnot PRISMA a spektrometru – narrowband NDVI index
- Obr. 27: Porovnání hodnot PRISMA a spektrometru – narrowband NPCI index
- Obr. 28: Porovnání hodnot PRISMA a spektrometru – narrowband NPQI index
- Obr. 29: Rozdíl v hodnotách broadband indexů NDVI ze senzoru PRISMA a spektrometru, barva piktogramu určuje typ plodiny: Ječmen (žlutá) , Pšenice (modrá) , Strniště (světle zelená) , Tráva (tmavě zelená) , Vojtěška (růžová) , Řepa (červená)
- Obr. 30: Rozdíl v hodnotách narrowband indexů NDVI ze senzoru PRISMA a spektrometru barva piktogramu určuje typ plodiny: Ječmen (žlutá) , Pšenice (modrá) , Strniště (světle zelená) , Tráva (tmavě zelená) , Vojtěška (růžová) , Řepa (červená)
- Obr. 31: Rozdíl v hodnotách narrowband indexů NPCI ze senzoru PRISMA a spektrometru, barva piktogramu určuje typ plodiny: Ječmen (žlutá) , Pšenice (modrá) , Strniště (světle zelená) , Tráva (tmavě zelená) , Vojtěška (růžová) , Řepa (červená)
- Obr. 32: Rozdíl v hodnotách narrowband indexů NPQI ze senzoru PRISMA a spektrometru, barva piktogramu určuje typ plodiny: Ječmen (žlutá) , Pšenice (modrá) , Strniště (světle zelená) , Tráva (tmavě zelená) , Vojtěška (růžová) , Řepa (červená)
- Obr. 33: Rozdělení hodnot vegetačních indexů ze senzoru PRISMA a spektrometru
- Obr. 34: Korelace vegetačních indexů ze senzoru PRISMA
- Obr. 35: Korelace vegetačních indexů z terénního spektrometru



Obr. 36: Porovnání detekce plodin pomocí broadband indexů NDVI ze senzoru PRISMA a terénního spektrometru

Obr. 37: Porovnání detekce plodin pomocí narrowband indexů NDVI ze senzoru PRISMA a terénního spektrometru

Obr. 38: Porovnání detekce plodin pomocí narrowband indexů NPCI ze senzoru PRISMA a terénního spektrometru

Obr. 39: Porovnání detekce plodin pomocí narrowband indexů NPQI ze senzoru PRISMA a terénního spektrometru

Obr. 40: Korelace broadband a narrowband NDVI indexů z dat PRISMA a spektrometru

Obr. 41: Porovnání detekce plodin pomocí broadband a narrowband indexů NDVI ze senzoru PRISMA a terénního spektrometru

Obr. 42: Výsledný narrowband index fluorescence ze senzoru PRISMA

Obr. 43: Porovnání hodnot PRISMA a spektrometru – narrowband index fluorescence

Obr. 44: Rozdíl v hodnotách narrowband indexů fluorescence ze senzoru PRISMA a spektrometru, barva piktogramu určuje typ plodiny: Ječmen (žlutá) , Pšenice (modrá) , Strniště (světle zelená) , Tráva (tmavě zelená) , Vojtěška (růžová) , Řepa (červená)

Obr. 45: Porovnání detekce plodin pomocí fluorescence ze senzoru PRISMA a terénního spektrometru

Obr. 46: Rozdělení hodnot fluorescence ze senzoru PRISMA a spektrometru

Obr. 47: Korelace NDVI indexů a fluorescence

## 10 Seznam použitých zkratek

PRISMA	PRecursore IperSpettrale della Missione Applicativa
NDVI	Normalized Difference Vegetation Index
DPZ	Dálkový průzkum Země
EM	Elektromagnetické
UV	Ultraviolet
VIS	Visible
NIR	Near infrared
VNIR	Visible + Near infrared
SWIR	Shortwave infrared
TIR	Thermal infrared
RGB	Red green blue
MODIS	Moderate Resolution Imaging Spectroradiometer
NASA	National Aeronautics and Space Administration
ESA	European Space Agency
CAS	Chinese Academy of Sciences
ASI	Agenzia Spaziale Italiana
GFZ	Deutsches GeoForschungsZentrum
GNDVI	Green Normalized Difference Vegetation Index
LAI	Leaf Area Index
LCI	Leaf Chlorophyll Index
MSI	Moisture Stress Index
UAV	Unmanned Aerial Vehicle
SAVI	Soil-Adjusted Vegetation Index
PRI	Photochemical Reflectance Index
NPCI	Normalized Pigment Chlorophyll Ratio Index
NPQI	Normalized Phaeophytinization Index
EU	Evropská Unie
SIF	Solar-Induced Fluorescence
FLEX	Fluorescence EXplorer
APEX	Airborne Prism EXperiment
ČZU	Česká zemědělská univerzita

## 11 Zdroje

- Abdullah, H., Darvishzadeh, R., Skidmore, A. K., & Heurich, M. (2019). Sensitivity of Landsat-8 OLI and TIRS Data to Foliar Properties of Early Stage Bark Beetle (*Ips typographus*, L.) Infestation. *Remote Sensing*, *11*(4).  
<https://doi.org/10.3390/RS11040398>
- Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R., & Sousa, J. J. (2017). Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry. *Remote Sensing 2017, Vol. 9, Page 1110*, *9*(11), 1110. <https://doi.org/10.3390/RS9111110>
- Ali, M. M., Al-Ani, A., Eamus, D., & Tan, D. K. Y. (2017). Leaf nitrogen determination using non-destructive techniques—A review. <Http://Dx.Doi.Org/10.1080/01904167.2016.1143954>, *40*(7), 928–953.  
<https://doi.org/10.1080/01904167.2016.1143954>
- Alton, P. B. (2016). The sensitivity of models of gross primary productivity to meteorological and leaf area forcing: A comparison between a Penman–Monteith ecophysiological approach and the MODIS Light-Use Efficiency algorithm. *Agricultural and Forest Meteorology*, *218–219*, 11–24.  
<https://doi.org/10.1016/J.AGRFORMET.2015.11.010>
- Amálie - Školní zemědělský podnik Lány - Fakulta životního prostředí ČZU v Praze. (n.d.). Retrieved March 6, 2023, from <https://www.fzp.czu.cz/cs/r-6899-projekty-a-spoluprace-s-praxi/r-6923-projekty/r-13951-swamp/r-15801-projektove-lokality/r-15802-amalie-skolni-zemedelsky-podnik-lany>
- Anderegg, J., Yu, K., Aasen, H., Walter, A., Liebisch, F., & Hund, A. (2020). Spectral Vegetation Indices to Track Senescence Dynamics in Diverse Wheat Germplasm. *Frontiers in Plant Science*, *10*, 1749.  
<https://doi.org/10.3389/FPLS.2019.01749/BIBTEX>
- Annamarie Eldering, Tommy E. Taylor, Chris W. O'Dell, & Ryan Pavlick. (2018). *The OCO-3 mission; measurement objectives and expected performance based on one year of simulated data*. 54.  
[https://ocov3.jpl.nasa.gov/documents/2/eldering\\_etal\\_amt-2018-357.pdf](https://ocov3.jpl.nasa.gov/documents/2/eldering_etal_amt-2018-357.pdf)
- Ashapure, A., Jung, J., Chang, A., Oh, S., Maeda, M., & Landivar, J. (2019). A Comparative Study of RGB and Multispectral Sensor-Based Cotton Canopy Cover Modelling Using Multi-Temporal UAS Data. *Remote Sensing 2019, Vol. 11, Page 2757*, *11*(23), 2757. <https://doi.org/10.3390/RS11232757>

- Asner, G. P. (1998). Biophysical and Biochemical Sources of Variability in Canopy Reflectance. *Remote Sensing of Environment*, 64(3), 234–253.  
[https://doi.org/10.1016/S0034-4257\(98\)00014-5](https://doi.org/10.1016/S0034-4257(98)00014-5)
- Benami, E., Jin, Z., Carter, M. R., Ghosh, A., Hijmans, R. J., Hobbs, A., Kenduywo, B., & Lobell, D. B. (2021). Uniting remote sensing, crop modelling and economics for agricultural risk management. *Nature Reviews Earth & Environment* 2021 2:2, 2(2), 140–159. <https://doi.org/10.1038/s43017-020-00122-y>
- Berry, J. A., van der Tol, C., Frankenberg, C., Joiner, J., & Guanter, L. (2013). Understanding Solar Induced Fluorescence: Building up from Leaf Scale Measurements (Invited). *AGUFM*, 2013, B11I-02.  
<https://ui.adsabs.harvard.edu/abs/2013AGUFM.B11I..02B/abstract>
- Callies, J., Corpaccioli, E., Eisinger, M., Hahne, A., & Lefebvre, A. (2000). *GOME-2-Metop's Second-Generation Sensor for Operational Ozone Monitoring*.
- Campbell B. James, H. Wynne Randolph, & Thomas A. Valerie. (1987). *Introduction to Remote Sensing Fifth Edition* (5th ed.).
- Campbell, J. B., & Wayne, R. H. (2011). *Introduction to Remote Sensing, Fifth Edition - James B. Campbell, Randolph H. Wynne - Google Books*. 667.
- Candiani, G., Tagliabue, G., Panigada, C., Verrelst, J., Picchi, V., Caicedo, J. P. R., & Boschetti, M. (2022). Evaluation of Hybrid Models to Estimate Chlorophyll and Nitrogen Content of Maize Crops in the Framework of the Future CHIME Mission. *Remote Sensing* 2022, Vol. 14, Page 1792, 14(8), 1792.  
<https://doi.org/10.3390/RS14081792>
- Chabrillat, S., Ganci, G., Kereszturi, G., Kopačková-Strandová, V., Gasmi, A., Gomez, C., Chehbouni, A., Dhiba, D., & El Gharous, M. (2022). Using PRISMA Hyperspectral Satellite Imagery and GIS Approaches for Soil Fertility Mapping (FertiMap) in Northern Morocco. *Remote Sensing* 2022, Vol. 14, Page 4080, 14(16), 4080. <https://doi.org/10.3390/RS14164080>
- Chander, S., Gujrati, A., Krishna, A. V., Sahay, A., & Singh, R. P. (2020). Remote sensing of inland water quality: a hyperspectral perspective. *Hyperspectral Remote Sensing: Theory and Applications*, 197–219.  
<https://doi.org/10.1016/B978-0-08-102894-0.00017-6>
- Chime (Copernicus Hyperspectral Imaging Mission for the Environment)*. (2020).  
<https://www.eoportal.org/satellite-missions/chime-copernicus>

- Clay E. David, & Chang Jiyul. (2016). (PDF) *Matching Remote Sensing to Problems*.  
[https://www.researchgate.net/publication/310751847\\_Matching\\_Remote\\_Sensing\\_to\\_Problems](https://www.researchgate.net/publication/310751847_Matching_Remote_Sensing_to_Problems)
- De Bock, A., Belmans, B., Vanlanduit, S., Blom, J., Alvarado-Alvarado, A. A., & Audenaert, A. (2023). A review on the leaf area index (LAI) in vertical greening systems. *Building and Environment*, 229, 109926.  
<https://doi.org/10.1016/J.BUILDENV.2022.109926>
- Ding, Y., He, X., Zhou, Z., Hu, J., Cai, H., Wang, X., Li, L., Xu, J., & Shi, H. (2022). Response of vegetation to drought and yield monitoring based on NDVI and SIF. *CATENA*, 219, 106328.  
<https://doi.org/10.1016/J.CATENA.2022.106328>
- Doughty, R., Kurosu, T. P., Parazoo, N., Köhler, P., Wang, Y., Sun, Y., & Frankenberg, C. (2022). Global GOSAT, OCO-2, and OCO-3 solar-induced chlorophyll fluorescence datasets. *Earth System Science Data*, 14(4), 1513–1529. <https://doi.org/10.5194/ESSD-14-1513-2022>
- Drolet, G. G., Huemmrich, K. F., Hall, F. G., Middleton, E. M., Black, T. A., Barr, A. G., & Margolis, H. A. (2005). A MODIS-derived photochemical reflectance index to detect inter-annual variations in the photosynthetic light-use efficiency of a boreal deciduous forest. *Remote Sensing of Environment*, 98(2–3), 212–224. <https://doi.org/10.1016/J.RSE.2005.07.006>
- Du, S., Liu, L., Liu, X., Zhang, X., Gao, X., & Wang, W. (2020a). The solar-induced chlorophyll fluorescence imaging spectrometer (SIFIS) onboard the first terrestrial ecosystem carbon inventory satellite (TECIS-1): Specifications and prospects. *Sensors (Switzerland)*, 20(3). <https://doi.org/10.3390/S20030815>
- Du, S., Liu, L., Liu, X., Zhang, X., Gao, X., & Wang, W. (2020b). The Solar-Induced Chlorophyll Fluorescence Imaging Spectrometer (SIFIS) Onboard the First Terrestrial Ecosystem Carbon Inventory Satellite (TECIS-1): Specifications and Prospects. *Sensors (Basel, Switzerland)*, 20(3), 815.  
<https://doi.org/10.3390/S20030815>
- Du, S., Liu, L., Liu, X., Zhang, X., Zhang, X., Bi, Y., & Zhang, L. (2018). Retrieval of global terrestrial solar-induced chlorophyll fluorescence from TanSat satellite. *Science Bulletin*, 63(22), 1502–1512.  
<https://doi.org/10.1016/J.SCIB.2018.10.003>

- Ekologické zemědělství ve Středočeském kraji - Biofarmy: Poděbrady.* (n.d.). Retrieved March 6, 2023, from <https://www.mesto-podebrady.cz/ekologicke-zemedelstvi-ve-stredoceskem-kraji-biofarmy/d-24753>
- EnMAP - OHB System ENG.* (n.d.). Retrieved March 6, 2023, from <https://www.ohb-system.de/enmap-english.html>
- FLEX - Earth Online.* (n.d.). Retrieved March 6, 2023, from <https://earth.esa.int/eogateway/missions/flex>
- Food and Agriculture Organization of the United Nations. (2017). *The future of food and agriculture and challenges.* <https://www.fao.org/3/i6583e/i6583e.pdf>
- Fréchette, E., Wong, C. Y. S., Junker, L. V., Chang, C. Y. Y., & Ensminger, I. (2015). Zeaxanthin-independent energy quenching and alternative electron sinks cause a decoupling of the relationship between the photochemical reflectance index (PRI) and photosynthesis in an evergreen conifer during spring. *Journal of Experimental Botany*, 66(22), 7309–7323. <https://doi.org/10.1093/JXB/ERV427>
- Garzonio, R., di Mauro, B., Colombo, R., & Cogliati, S. (2017). Surface Reflectance and Sun-Induced Fluorescence Spectroscopy Measurements Using a Small Hyperspectral UAS. *Remote Sensing 2017, Vol. 9, Page 472, 9(5)*, 472. <https://doi.org/10.3390/RS9050472>
- Ge, Y., Thomasson, J. A., & Sui, R. (2011). Remote sensing of soil properties in precision agriculture: A review. *Frontiers of Earth Science*, 5(3), 229–238. <https://doi.org/10.1007/S11707-011-0175-0/METRICS>
- Guo, L., Sun, X., Fu, P., Shi, T., Dang, L., Chen, Y., Linderman, M., Zhang, G., Zhang, Y., Jiang, Q., Zhang, H., & Zeng, C. (2021). Mapping soil organic carbon stock by hyperspectral and time-series multispectral remote sensing images in low-relief agricultural areas. *Geoderma*, 398, 115118. <https://doi.org/10.1016/J.GEODERMA.2021.115118>
- He, K. S., Rocchini, D., Neteler, M., & Nagendra, H. (2011). Benefits of hyperspectral remote sensing for tracking plant invasions. *Diversity and Distributions*, 17(3), 381–392. <https://doi.org/10.1111/J.1472-4642.2011.00761.X>
- Helm, L. T., Shi, H., Lerdau, M. T., & Yang, X. (2020). Solar-induced chlorophyll fluorescence and short-term photosynthetic response to drought. *Ecological*

- Applications : A Publication of the Ecological Society of America*, 30(5).  
<https://doi.org/10.1002/EAP.2101>
- Hille, K. (2016). *Carbon Dioxide Fertilization Greening Earth, Study Finds*.  
<http://www.nasa.gov/feature/goddard/2016/carbon-dioxide-fertilization-greening-earth>
- Hong, Z., Hu, Y., Cui, C., Yang, X., Tao, C., Luo, W., Zhang, W., Li, L., & Meng, L. (2022). An Operational Downscaling Method of Solar-Induced Chlorophyll Fluorescence (SIF) for Regional Drought Monitoring. *Agriculture (Switzerland)*, 12(4). <https://doi.org/10.3390/AGRICULTURE12040547>
- Horning, N. (2008). Remote Sensing. *Encyclopedia of Ecology, Five-Volume Set*, 2986–2994. <https://doi.org/10.1016/B978-008045405-4.00237-8>
- Hunt, E. R., & Rock, B. N. (1989). Detection of changes in leaf water content using Near- and Middle-Infrared reflectances. *Remote Sensing of Environment*, 30(1), 43–54. [https://doi.org/10.1016/0034-4257\(89\)90046-1](https://doi.org/10.1016/0034-4257(89)90046-1)
- Hutchison, K. D. (2003). Applications of MODIS satellite data and products for monitoring air quality in the state of Texas. *Atmospheric Environment*, 37(17), 2403–2412. [https://doi.org/10.1016/S1352-2310\(03\)00128-6](https://doi.org/10.1016/S1352-2310(03)00128-6)
- IDB - Index DataBase. (n.d.). Retrieved March 20, 2023, from <https://www.indexdatabase.de/>
- Ing Jiří Horák, D. (2014). *Vysoká škola báňská-Technická univerzita Ostrava Hornicko-geologická fakulta DÁLKOVÝ PRŮZKUM ZEMĚ (E-learningová podpora)*.
- Kaufmann, H., Sang, B., Storch, T., Segl, K., Foerster, S., Guanter, L., Erhard, M., Heider, B., Hofer, S., Honold, H. P., Penné, B., Bachmann, M., Habermeyer, M., Müller, A., Müller, R., Rast, M., Staenz, K., Straif, C., & Chlebek, C. (2015). Environmental mapping and analysis program - A German hyperspectral mission. *Optical Payloads for Space Missions*, 161–181. <https://doi.org/10.1002/9781118945179.CH7>
- Kochová, T., Hejtná, L., Céza, A. v, Čermáková, E., Koblížková, E., Mertl, J., Pokorný, J., Přeč, J., Rollerová, M., & Vlčková, V. (2018). *Zpracovala CENIA, česká informační agentura životního prostředí*. <http://www.mzp.cz>
- Kováč, D., Novotný, J., Šigut, L., Grace, J., & Urban, O. (2022). Dynamic of Fluorescence Emissions at O2A and O2B Telluric Absorption Bands in

- Forested Areas with Seasonal APAR and GPP Variations. *Remote Sensing* 2023, Vol. 15, Page 67, 15(1), 67. <https://doi.org/10.3390/RS15010067>
- Kraft, S., del Bello, U., Drusch, M., Gabriele, A., Harnisch, B., & Moreno, J. (2013). On the demands on imaging spectrometry for the monitoring of global vegetation fluorescence from space. *Imaging Spectrometry XVIII*, 8870, 88700N. <https://doi.org/10.1117/12.2024245>
- Krajská správa ČSÚ. (2021). *Sklizeň zemědělských plodin ve Středočeském kraji v roce 2021 | ČSÚ pro Středočeský kraj*. <https://www.czso.cz/csu/xs/sklizen-zemedelskych-plodin-ve-stredoceskem-kraji-v-roce-2021>
- Krämer, J., Siegmann, B., Kraska, T., Muller, O., & Rascher, U. (2021). The potential of spatial aggregation to extract remotely sensed sun-induced fluorescence (SIF) of small-sized experimental plots for applications in crop phenotyping. *International Journal of Applied Earth Observation and Geoinformation*, 104, 102565. <https://doi.org/10.1016/J.JAG.2021.102565>
- Kumar, L., Schmidt, K., Dury, S., & Skidmore, A. (2002). *Imaging Spectrometry and Vegetation Science*. 111–155. [https://doi.org/10.1007/978-0-306-47578-8\\_5](https://doi.org/10.1007/978-0-306-47578-8_5)
- Landsat Normalized Difference Vegetation Index | U.S. Geological Survey*. (n.d.). Retrieved March 6, 2023, from <https://www.usgs.gov/landsat-missions/landsat-normalized-difference-vegetation-index>
- Lasaponara, R., Masini, N., Biscione, M., & Earsel, E. (2020). *Towards Horizon*.
- Lausch A., Zacharias S., Dierke C., Pause M., Kühn I., Doktor D., Dietrich P., & Werban U. (2012). *Analysis of Vegetation and Soil Patterns using Hyperspectral Remote Sensing, EMI, and Gamma-Ray Measurements*. <https://doi.org/10.2136/vzj2012.0217>
- Li, F., Miao, Y., Hennig, S. D., Gnyp, M. L., Chen, X., Jia, L., & Bareth, G. (2010). Evaluating hyperspectral vegetation indices for estimating nitrogen concentration of winter wheat at different growth stages. *Precision Agriculture*, 11(4), 335–357. <https://doi.org/10.1007/S11119-010-9165-6>
- Li, S., Gao, M., Li, Z.-L., Wang, M., Yu, H., Chen, J., & Zhu, Y. (2021). Retrieving Sun-Induced Chlorophyll Fluorescence from Hyperspectral Data with TanSat Satellite. *Sensors* 2021, Vol. 21, Page 4886, 21(14), 4886. <https://doi.org/10.3390/S21144886>
- Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2015). *REMOTE SENSING AND IMAGE INTERPRETATION Fifth Edition*.



- Liu, N., Budkewitsch, P., & Treitz, P. (2017). Examining spectral reflectance features related to Arctic percent vegetation cover: Implications for hyperspectral remote sensing of Arctic tundra. *Remote Sensing of Environment*, *192*, 58–72. <https://doi.org/10.1016/J.RSE.2017.02.002>
- Longmire, A. R., Poblete, T., Hunt, J. R., Chen, D., & Zarco-Tejada, P. J. (2022). Assessment of crop traits retrieved from airborne hyperspectral and thermal remote sensing imagery to predict wheat grain protein content. *ISPRS Journal of Photogrammetry and Remote Sensing*, *193*, 284–298. <https://doi.org/10.1016/J.ISPRSJPRS.2022.09.015>
- Lussem, U., Bolten, A., Gnyp, M. L., Jasper, J., & Bareth, G. (2018). Evaluation of RGB-based vegetation indices from UAV imagery to estimate forage yield in Grassland. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, *42(3)*, 1215–1219. <https://doi.org/10.5194/ISPRS-ARCHIVES-XLII-3-1215-2018>
- Málková Hana. (2010). *KLASIFIKACE LAND COVER Z HYPERSPEKTRÁLNÍCH DAT V REKULTIVOVANÝCH OBLASTECH SOKOLOVSKÉ HNĚDOUHELNÉ PÁNVE*. Karlova univerzita.
- Marshall, M., Belgiu, M., Boschetti, M., Pepe, M., Stein, A., & Nelson, A. (2022a). Field-level crop yield estimation with PRISMA and Sentinel-2. *ISPRS Journal of Photogrammetry and Remote Sensing*, *187*. <https://doi.org/10.1016/j.isprsjprs.2022.03.008>
- Marshall, M., Belgiu, M., Boschetti, M., Pepe, M., Stein, A., & Nelson, A. (2022b). Field-level crop yield estimation with PRISMA and Sentinel-2. *ISPRS Journal of Photogrammetry and Remote Sensing*, *187*, 191–210. <https://doi.org/10.1016/J.ISPRSJPRS.2022.03.008>
- Marshall, M., & Thenkabail, P. (2015). Advantage of hyperspectral EO-1 Hyperion over multispectral IKONOS, GeoEye-1, WorldView-2, Landsat ETM+, and MODIS vegetation indices in crop biomass estimation. *ISPRS Journal of Photogrammetry and Remote Sensing*, *108*, 205–218. <https://doi.org/10.1016/J.ISPRSJPRS.2015.08.001>
- Marshall, M., Thenkabail, P., Biggs, T., & Post, K. (2016). Hyperspectral narrowband and multispectral broadband indices for remote sensing of crop evapotranspiration and its components (transpiration and soil evaporation).

- Agricultural and Forest Meteorology*, 218–219, 122–134.  
<https://doi.org/10.1016/J.AGRFORMET.2015.12.025>
- Masek, J. G., Wulder, M. A., Markham, B., McCorkel, J., Crawford, C. J., Storey, J., & Jenstrom, D. T. (2020). Landsat 9: Empowering open science and applications through continuity. *Remote Sensing of Environment*, 248, 111968.  
<https://doi.org/10.1016/J.RSE.2020.111968>
- Meroni, M., Rossini, M., Guanter, L., Alonso, L., Rascher, U., Colombo, R., & Moreno, J. (2009). Remote sensing of solar-induced chlorophyll fluorescence: Review of methods and applications. *Remote Sensing of Environment*, 113(10), 2037–2051. <https://doi.org/10.1016/J.RSE.2009.05.003>
- Meyer. (2015). *GOME-2: Factsheet*. <http://www.eumetsat.int>
- Middleton, E. M., Mandl, D. J., Frye, S. W., Ong, L., Ungar, S. G., Campbell, P. E., Huemmrich, K. F., & Landis, D. R. (2014). *EO-1/Hyperion: Nearing Fourteen Years of Successful Mission Science Operation and End of Mission Plans*.
- Mohammed, G. H., Colombo, R., Middleton, E. M., Rascher, U., van der Tol, C., Nedbal, L., Goulas, Y., Pérez-Priego, O., Damm, A., Meroni, M., Joiner, J., Cogliati, S., Verhoef, W., Malenovský, Z., Gastellu-Etchegorry, J. P., Miller, J. R., Guanter, L., Moreno, J., Moya, I., ... Zarco-Tejada, P. J. (2019). Remote sensing of solar-induced chlorophyll fluorescence (SIF) in vegetation: 50 years of progress. *Remote Sensing of Environment*, 231.  
<https://doi.org/10.1016/j.rse.2019.04.030>
- Moravec, D., Komárek, J., Medina, S. L. C., & Molina, I. (2021). Effect of atmospheric corrections on NDVI: Intercomparability of Landsat 8, Sentinel-2, and UAV sensors. *Remote Sensing*, 13(18). <https://doi.org/10.3390/RS13183550>
- Moreno Jose. (2017). *Remote Sensing | Special Issue : Remote Sensing of Vegetation Fluorescence and Photosynthetic Efficiency*.  
[https://www.mdpi.com/journal/remotesensing/special\\_issues/Vegetation\\_Fluorescence](https://www.mdpi.com/journal/remotesensing/special_issues/Vegetation_Fluorescence)
- Mozgeris, G., Juodkiene, V., Jonikavičius, D., Straigyte, L., Gadal, S., & Ouerghemmi, W. (2018). Ultra-Light Aircraft-Based Hyperspectral and Colour-Infrared Imaging to Identify Deciduous Tree Species in an Urban Environment. *Remote Sensing 2018, Vol. 10, Page 1668, 10(10)*, 1668.  
<https://doi.org/10.3390/RS10101668>

- Nagler, P. L., Daughtry, C. S. T., & Goward, S. N. (2000). Plant Litter and Soil Reflectance. *Remote Sensing of Environment*, 71(2), 207–215.  
[https://doi.org/10.1016/S0034-4257\(99\)00082-6](https://doi.org/10.1016/S0034-4257(99)00082-6)
- Novotná, K. (2013). *Využití hyperspektrálních dat k detekci a klasifikaci vybraných antropogenních materiálů*. <https://dspace.cuni.cz/handle/20.500.11956/54164>
- Omia, E., Bae, H., Park, E., Kim, M. S., Baek, I., Kabenge, I., & Cho, B. K. (2023). Remote Sensing in Field Crop Monitoring: A Comprehensive Review of Sensor Systems, Data Analyses and Recent Advances. *Remote Sensing 2023, Vol. 15, Page 354, 15(2)*, 354. <https://doi.org/10.3390/RS15020354>
- Oppelt, N., & Mauser, W. (2004). Hyperspectral monitoring of physiological parameters of wheat during a vegetation period using AVIS data. *International Journal of Remote Sensing*, 25(1), 145–159.  
<https://doi.org/10.1080/0143116031000115300>
- Pancorbo, J. L., Camino, C., Alonso-Ayuso, M., Raya-Sereno, M. D., Gonzalez-Fernandez, I., Gabriel, J. L., Zarco-Tejada, P. J., & Quemada, M. (2021). Simultaneous assessment of nitrogen and water status in winter wheat using hyperspectral and thermal sensors. *European Journal of Agronomy*, 127, 126287. <https://doi.org/10.1016/J.EJA.2021.126287>
- Pearlman, J., Segal, C., Clancy, P., Nelson, N., Jarecke, P., Ono, M., Beiso, D., Liao, L., Yokoyama, K., Carman, S., Browne, B., Ong, L., & Ungar, S. (2001). *The EO-1 Hyperion Imaging Spectrometer IEEE Aerospace Conference*.
- Pinkerton, D. K., Pierce, K. M., & Synovec, R. E. (2016). Chemometric Resolution of Complex Higher Order Chromatographic Data with Spectral Detection. *Data Handling in Science and Technology*, 30, 333–352.  
<https://doi.org/10.1016/B978-0-444-63638-6.00010-3>
- Pokorný, R. (2015). *Stanovení indexu listové plochy v nesmíšených porostech lesních dřevin Certifikovaná metodika ©2015*. <http://www.czechglobe.cz>
- Porcar-Castell, A., Garcia-Plazaola, J. I., Nichol, C. J., Kolari, P., Olascoaga, B., Kuusinen, N., Fernández-Marín, B., Pulkkinen, M., Juurola, E., & Nikinmaa, E. (2012). Physiology of the seasonal relationship between the photochemical reflectance index and photosynthetic light use efficiency. *Oecologia*, 170(2), 313–323. <https://doi.org/10.1007/S00442-012-2317-9/FIGURES/5>

- PRISMA (Hyperspectral)*. (2012, July 29). <https://www.eoportal.org/satellite-missions/prisma-hyperspectral#prisma-hyperspectral-precursor-and-application-mission>
- PRISMA ("PRecursore IperSpettrale della Missione)*. (2019). [https://space.leonardo.com/documents/16277711/19568565/Prisma+2019\\_03.pdf?t=1553163493858](https://space.leonardo.com/documents/16277711/19568565/Prisma+2019_03.pdf?t=1553163493858)
- Pu, R., Gong, P., & Yu, Q. (2008). Comparative Analysis of EO-1 ALI and Hyperion, and Landsat ETM+ Data for Mapping Forest Crown Closure and Leaf Area Index. *Sensors (Basel, Switzerland)*, 8(6), 3744. <https://doi.org/10.3390/S8063744>
- Qiao, L., Zhao, R., Tang, W., An, L., Sun, H., Li, M., Wang, N., Liu, Y., & Liu, G. (2022). Estimating maize LAI by exploring deep features of vegetation index map from UAV multispectral images. *Field Crops Research*, 289, 108739. <https://doi.org/10.1016/J.FCR.2022.108739>
- Rees G.W. (2012). *Physical Principles of Remote Sensing Third Edition* (Third).
- Rodríguez-López, L., Duran-Llacer, I., González-Rodríguez, L., Abarca-del-Rio, R., Cárdenas, R., Parra, O., Martínez-Retureta, R., & Urrutia, R. (2020). Spectral analysis using LANDSAT images to monitor the chlorophyll-a concentration in Lake Laja in Chile. *Ecological Informatics*, 60, 101183. <https://doi.org/10.1016/J.ECOINF.2020.101183>
- Sahoo, R. N., Ray, S. S., & Manjunath, K. R. (n.d.). *Hyperspectral remote sensing of agriculture*.
- Sahoo, R. N., Ray, S. S., & Manjunath, K. R. (2015). Hyperspectral remote sensing of agriculture. *Current Science*.
- Schuettmeyer, D. (n.d.). *The FLEX satellite mission, scientific objectives, and technical implementation, including the importance of airborne fluorescence, cal/val Scheme*.
- Siqueira, R., Longchamps, L., Dahal, S., & Khosla, R. (2020). Use of Fluorescence Sensing to Detect Nitrogen and Potassium Variability in Maize. *Remote Sensing 2020, Vol. 12, Page 1752, 12(11)*, 1752. <https://doi.org/10.3390/RS12111752>
- Springer, K. R., Wang, R., & Gamon, J. A. (2017). Parallel Seasonal Patterns of Photosynthesis, Fluorescence, and Reflectance Indices in Boreal Trees. *Remote Sensing 2017, Vol. 9, Page 691, 9(7)*, 691. <https://doi.org/10.3390/RS9070691>

- Statky ČZU*. (n.d.). Retrieved March 6, 2023, from <https://statky.czu.cz/cs/r-11153-onas>
- Stručný přehled SZP*. (n.d.). Retrieved March 10, 2023, from [https://agriculture.ec.europa.eu/common-agricultural-policy/cap-overview/cap-glance\\_cs](https://agriculture.ec.europa.eu/common-agricultural-policy/cap-overview/cap-glance_cs)
- Svendsen, D. H., Hernández-Lobato, D., Martino, L., Laparra, V., Moreno-Martínez, Á., & Camps-Valls, G. (2021). Inference over radiative transfer models using variational and expectation maximization methods. *Machine Learning*, *112*(3), 921–937. <https://doi.org/10.1007/S10994-021-05999-4/FIGURES/5>
- Tagliabue, G., Boschetti, M., Bramati, G., Candiani, G., Colombo, R., Nutini, F., Pompilio, L., Rivera-Caicedo, J. P., Rossi, M., Rossini, M., Verrelst, J., & Panigada, C. (2022). Hybrid retrieval of crop traits from multi-temporal PRISMA hyperspectral imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, *187*, 362–377. <https://doi.org/10.1016/J.ISPRSJPRS.2022.03.014>
- TanSat - Earth Online*. (n.d.). Retrieved March 6, 2023, from <https://earth.esa.int/eogateway/missions/tansat>
- Tayade, R., Yoon, J., Lay, L., Khan, A. L., Yoon, Y., & Kim, Y. (2022). Utilization of Spectral Indices for High-Throughput Phenotyping. *Plants*, *11*(13). <https://doi.org/10.3390/PLANTS11131712>
- Tayebi, A., Kasmaeeyazdi, S., Tinti, F., & Bruno, R. (2023). Contributions from experimental geostatistical analyses for solving the cloud-cover problem in remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*, *118*, 103236. <https://doi.org/10.1016/J.JAG.2023.103236>
- Tedesco, D., de Oliveira, M. F., dos Santos, A. F., Costa Silva, E. H., de Souza Rolim, G., & da Silva, R. P. (2021). Use of remote sensing to characterize the phenological development and to predict sweet potato yield in two growing seasons. *European Journal of Agronomy*, *129*, 126337. <https://doi.org/10.1016/J.EJA.2021.126337>
- Tenreiro, T. R., García-Vila, M., Gómez, J. A., Jiménez-Berni, J. A., & Fereres, E. (2021). Using NDVI for the assessment of canopy cover in agricultural crops within modelling research. *Computers and Electronics in Agriculture*, *182*, 106038. <https://doi.org/10.1016/J.COMPAG.2021.106038>

- Thenkabail, P. S., Smith, R. B., & De Pauw, Eddy. (1999). *Hyperspectral vegetation indices for determining agricultural crop characteristics*. 47.  
[https://www.researchgate.net/publication/236019248\\_Hyperspectral\\_vegetation\\_indices\\_for\\_determining\\_agricultural\\_crop\\_characteristics](https://www.researchgate.net/publication/236019248_Hyperspectral_vegetation_indices_for_determining_agricultural_crop_characteristics)
- Thorp, K. R., Tian, L., Yao, H., & Tang, L. (n.d.). NARROW-BAND AND DERIVATIVE-BASED VEGETATION INDICES FOR HYPERSPECTRAL DATA. *Transactions of the ASAE*, 47(1), 291–299.
- Tong, A., & He, Y. (2017). Estimating and mapping chlorophyll content for a heterogeneous grassland: Comparing prediction power of a suite of vegetation indices across scales between years. *ISPRS Journal of Photogrammetry and Remote Sensing*, 126, 146–167.  
<https://doi.org/10.1016/J.ISPRSJPRS.2017.02.010>
- van der Tol, C., Berry, J. A., Campbell, P. K. E., & Rascher, U. (2014). Models of fluorescence and photosynthesis for interpreting measurements of solar-induced chlorophyll fluorescence. *Journal of Geophysical Research: Biogeosciences*, 119(12), 2312–2327. <https://doi.org/10.1002/2014JG002713>
- Vegetation Indices*. (n.d.). Retrieved March 7, 2023, from <https://www.l3harrisgeospatial.com/docs/vegetationindices.html>
- Vegetation indices: a key tool in precision agriculture | Pix4D*. (n.d.). Retrieved March 25, 2023, from <https://www.pix4d.com/blog/pix4dfields-vegetation-indices-for-precision-agriculture/>
- Vincini, M., & Frazzi, E. (2011). Comparing narrow and broad-band vegetation indices to estimate leaf chlorophyll content in planophile crop canopies. *Precision Agriculture*, 12(3), 334–344. <https://doi.org/10.1007/S11119-010-9204-3/FIGURES/3>
- Wang, F., Yi, Q., Hu, J., Xie, L., Yao, X., Xu, T., & Zheng, J. (2021). Combining spectral and textural information in UAV hyperspectral images to estimate rice grain yield. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102397. <https://doi.org/10.1016/J.JAG.2021.102397>
- Wang, Y., Suarez, L., Poblete, T., Gonzalez-Dugo, V., Ryu, D., & Zarco-Tejada, P. J. (2022). Evaluating the role of solar-induced fluorescence (SIF) and plant physiological traits for leaf nitrogen assessment in almond using airborne hyperspectral imagery. *Remote Sensing of Environment*, 279, 113141. <https://doi.org/10.1016/J.RSE.2022.113141>

- Weiss, M., Jacob, F., & Duveiller, G. (2020a). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236, 111402. <https://doi.org/10.1016/J.RSE.2019.111402>
- Weiss, M., Jacob, F., & Duveiller, G. (2020b). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236, 111402. <https://doi.org/10.1016/J.RSE.2019.111402>
- Wong, C. Y. S., D'Odorico, P., Arain, M. A., & Ensminger, I. (2020). Tracking the phenology of photosynthesis using carotenoid-sensitive and near-infrared reflectance vegetation indices in a temperate evergreen and mixed deciduous forest. *New Phytologist*, 226(6), 1682–1695. <https://doi.org/10.1111/NPH.16479>
- Xavier, A. C., Theodor Rudorff, B. F., Moreira, M. A., Alvarenga, B. S., De Freitas, J. G., & Salomon, M. V. (2006). Hyperspectral field reflectance measurements to estimate wheat grain yield and plant height. *Scientia Agricola*, 63(2), 130–138. <https://doi.org/10.1590/S0103-90162006000200004>
- Yang, W., Nigon, T., Hao, Z., Dias Paiao, G., Fernández, F. G., Mulla, D., & Yang, C. (2021). Estimation of corn yield based on hyperspectral imagery and convolutional neural network. *Computers and Electronics in Agriculture*, 184, 106092. <https://doi.org/10.1016/J.COMPAG.2021.106092>
- Yang, Y., Chen, R., Yin, G., Wang, C., Liu, G., Verger, A., Descals, A., Filella, I., & Penuelas, J. (2022). Divergent Performances of Vegetation Indices in Extracting Photosynthetic Phenology for Northern Deciduous Broadleaf Forests. *IEEE Geoscience and Remote Sensing Letters*, 19. <https://doi.org/10.1109/LGRS.2022.3182405>
- Yao, L., Yang, D., Liu, Y., Wang, J., Liu, L., Du, S., Cai, Z., Lu, N., Lyu, D., Wang, M., Yin, Z., & Zheng, Y. (2021). A New Global Solar-induced Chlorophyll Fluorescence (SIF) Data Product from TanSat Measurements. *Advances in Atmospheric Sciences*, 38(3), 341–345. <https://doi.org/10.1007/S00376-020-0204-6>
- Zarco-Tejada, P. J., Berjón, A., & Miller, J. R. (n.d.). *Stress Detection in Crops with Hyperspectral Remote Sensing and Physical Simulation Models*.
- Zarco-Tejada, P. J., Pushnik, J. C., Dobrowski, S., & Ustin, S. L. (2003). Steady-state chlorophyll a fluorescence detection from canopy derivative reflectance and double-peak red-edge effects. *Remote Sensing of Environment*, 84(2), 283–294. [https://doi.org/10.1016/S0034-4257\(02\)00113-X](https://doi.org/10.1016/S0034-4257(02)00113-X)

- Zhang, F., & Zhou, G. (2019). Estimation of vegetation water content using hyperspectral vegetation indices: A comparison of crop water indicators in response to water stress treatments for summer maize. *BMC Ecology*, *19*(1), 1–12. <https://doi.org/10.1186/S12898-019-0233-0/FIGURES/4>
- Zhong, Y., Wang, X., Wang, S., & Zhang, L. (2021). Advances in spaceborne hyperspectral remote sensing in China. *Geo-Spatial Information Science*, *24*(1), 95–120. <https://doi.org/10.1080/10095020.2020.1860653>
- Zhou, B., Elazab, A., Bort, J., Vergara, O., Serret, M. D., & Araus, J. L. (2015). Low-cost assessment of wheat resistance to yellow rust through conventional RGB images. *Computers and Electronics in Agriculture*, *116*, 20–29. <https://doi.org/10.1016/J.COMPAG.2015.05.017>