ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE
FAKULTA ŽIVOTNÍHO PROSTŘEDÍ
KATEDRA PROSTOROVÝCH VĚD

Monitorování vybraných znaků vegetace pomocí hyperspektrálních dat PRISMA

DIPLOMOVÁ PRÁCE

Vedoucí práce: Ing. Tomáš Klouček, Ph.D.
Diplomant: Bc. Dominika Gulková

2024

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Dominika Gulková

Prostorové vědy v životním prostředí

Název práce

Monitorování vybraných znaků vegetace pomocí hyperspektrálních dat PRISMA

Název anglicky

Monitoring selected vegetation traits using hyperspectral PRISMA data

---

Cíle práce

Cílem diplomové práce je pomocí přístupů obrazové spektrometrie získat vybrané vlastnosti (*traits*) nebo proměnné (*variables*) popisující aktuální stav vegetačního pokryvu z hyperspektrálních snímků družice PRISMA.

K posouzení výsledků bude využito laboratorní měření hledaných vlastností a proměnných na nasbíraných vzorcích vojtěšky seté ze zájmové lokality a multispektrálních UAV snímků.

Dílčí cíle diplomové práce souvisí především s těmito výzkumnými otázkami:

(a) Je možné pomocí hyperspektrálních dat ze satelitu PRISMA získat spektrální a biochemické vlastnosti vegetace (spektrální odezva, vlhkost vegetace, obsah pigmentů)?
(b) Je relativně hrubé prostorové rozlišení dat ze satelitu PRISMA (30 m) využitelné pro precizní analýzu vegetace?
(c) Jak moc se výsledky budou lišit od analýzy nad multispektrálními daty? Jsou oba přístupy zaměnitelné, nebo je jeden výrazně výhodnější?

Metodika

Rámcovou metodickou náplní práce bude:

(a) Akvizice dat PRISMA (podání projektu s žádostí o nalétání konkrétní lokality – Školní zemědělský podnik Amálie) a multispektrálních UAV snímků

(b) Pre-processing vstupních dat

(c) Nalezení hledaných vlastností a proměnných na hyperspektrálních snímcích (spektrální odezva, vlhkost vegetace, obsah pigmentů)

(d) Sběr vzorků v terénu

(e) Extrakce a následná laboratorní analýza hledaných vlastností vegetace z nasbíraných vzorků

(f) Porovnání vypočtených a naměřených hodnot

(g) Vyhodnocení výsledků provedených analýz

Doporučený rozsah práce

cca 40 normovaných stran

Klíčová slova

Hyperspektrální dálkový průzkum Země, Spektrální odrazivost, Vlhkost vegetace, Obsah pigmentů, EnMAP--box

---

Doporučené zdroje informací

Kremezi, M., Kristollari, V., Karathanassi, V., Topouzelis, K., Kolokoussis, P., Taggio, N., Aiello, A., Ceriola, G., Barbone, E., & Corradi, P. (2021). Pansharpening PRISMA Data for Marine Plastic Litter Detection Using Plastic Indexes. IEEE Access, 9, 61955–61971. https://doi.org/10.1109/ACCESS.2021.3073903

Lu, B., Dao, P.D., Liu, J., He, Y., Shang, J. (2020): Recent Advances of Hyperspectral Imaging Technology and Applications in Agriculture. Remote Sens. 12, 2659. https://doi.org/10.3390/rs12162659

Ustin, S. L., Roberts, D. A., Gamon, J. A., Asner, G. P., & Green, R. O. (2004). Using Imaging Spectroscopy to Study Ecosystem Processes and Properties. In BioScience (Vol. 54, Issue 6). https://academic.oup.com/bioscience/article/54/6/523/294193

Verrelst, J., Malenovský, Z., Van der Tol, C., Camps-Valls, G., Gastellu-Etchegorry, J.-P., Lewis, P., North, P., & Moreno, J. (2019): Quantifying Vegetation Biophysical Variables from Imaging Spectroscopy Data: A Review on Retrieval Methods. Surveys in Geophysics, 40, 589-629. https://doi.org/10.1007/s10712-018-9478-y

Weiss, M., Jacob, F., & Duveiller, G. (2020): Remote sensing for agricultural applications: A meta-review. Remote Sensing of Environment, 236, 111402. https://doi.org/10.1016/j.rse.2019.111402

Předběžný termín obhajoby

2023/24 LS – FŽP

Vedoucí práce

Ing. Tomáš Klouček, Ph.D.

Garantující pracoviště

Katedra prostorových věd

Elektronicky schváleno dne 6. 3. 2024

prof. Ing. Petra Šímová, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 7. 3. 2024

prof. RNDr. Michael Komárek, Ph.D.

Děkan

V Praze dne 28. 03. 2024

Čestné prohlášení

Prohlašuji, že jsem diplomovou práci na téma Monitorování vybraných znaků vegetace pomocí hyperspektrálních dat PRISMA vypracovala samostatně a citovala jsem všechny informační zdroje, které jsem v práci použila a které jsem rovněž uvedla na konci práce v seznamu použitých informačních zdrojů.

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

Jsem si vědoma, 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 verzi tištěnou a že s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR.

V Praze dne 23.3.2024

Bc. Dominika Gulková

Poděkování

V práci byla použita data z družice PRISMA - © Italská kosmická agentura (ASI); data byla použita na základě licence ASI.

Tímto chci poděkovat Ing. Martině Kadlecové z FŽP ČZU za poskytnutí prostorů laboratoře pro sušení vzorků a za cenné rady při postupu analýzy vlhkosti;

Ing. Kamilu Krausovi z FAPPZ ČZU za zpřístupnění laboratoře, konstrukci Soxhletova aparátu a pomoc s extrakcí pigmentů ze vzorků;

v neposlední řadě děkuji svému školiteli Ing. Tomáši Kloučkovi, Ph.D. za jeho podporu, vedení a rady, jež byly klíčové pro úspěšné dokončení mé práce.

Abstrakt

Tato diplomová práce se zabývá využitím metod obrazové spektroskopie pro monitorování vegetace s cílem efektivnějšího využívání zemědělských a přírodních zdrojů a ochrany biodiverzity. Hlavní pozornost je věnována analýze hyperspektrálních snímků z italského satelitu PRISMA a jejich srovnání s multispektrálními snímky ze satelitu Sentinel-2 Evropské vesmírné agentury. Analýza zahrnuje předzpracování snímků, výpočet spektrálních indexů, a jejich regresní analýzu ve vztahu k výsledkům spektroradiometrického měření a kvantitativním údajům o obsahu pigmentů a vody získaným z terénních vzorků. Práce přináší nové poznatky o možnostech aplikace hyperspektrálních dat pro přesnější určování biofyzikálních vlastností vegetace a zdůrazňuje problémy spojené s kvantifikací biofyzikálních vlastností vegetace.

Klíčová slova

Hyperspektrální dálkový průzkum Země, Spektrální odrazivost, Vlhkost vegetace, Obsah pigmentů, EnMAP-box

Abstract

This thesis deals with the use of imaging spectroscopy methods for vegetation monitoring with the aim of more efficient use of agricultural and natural resources and biodiversity conservation. The main focus is on the analysis of hyperspectral images from the Italian satellite PRISMA and comparison with multispectral images from the Sentinel-2 satellite of the European Space Agency. The analysis includes image preprocessing, calculation of spectral indices and their regression analysis in relation to spectroradiometric results and quantitative measurements on pigment and water content obtained from field samples. The work provides new insights into the potential application of hyperspectral data for more accurate determination of vegetation biophysical properties and highlights the problems associated with quantifying vegetation biophysical properties.

Keywords

Hyperspectral remote sensing, Spectral reflectance, Vegetation moisture, Pigment content, EnMAP-box

Obsah

1. Úvod ... 9
2. Cíle DP ... 11
3. Literární rešerše ... 12
   3.1 (Hyper)spektrální data ... 12
   3.2 Spectral unmixing ... 14
   3.3 Pansharpening ... 15
   3.4 Soxhletova extrakce ... 17
   3.5 Spektrální indexy ... 18
      3.5.1 NDVI (Normalized Difference Vegetation Index) ... 18
      3.5.2 GNDVI (Green Normalized Difference Vegetation Index) ... 19
      3.5.3 EVI (Enhanced Vegetation Index) ... 19
      3.5.4 MCARI (Modified Chlorophyll Absorption in Reflectance Index) ... 20
      3.5.5 CIrededge (Chlorophyll Index Red Edge) ... 20
      3.5.6 NPCI (Normalized Pigment Chlorophyll Index) ... 20
      3.5.7 VARI (Visible Atmospherically Resistant Index) ... 21
      3.5.8 NDMI (Normalized Difference Moisture Index) ... 21
      3.5.9 NDWI (Normalized Difference Water Index ... 21
      3.5.10 MSI (Moisture Stress Index) ... 22
      3.5.11 NSDSI (Normalized Shortwave-Infrared Difference Bare Soil Moisture Index) ... 22
   3.6 Současný stav řešené problematiky ... 23
4. Metodika ... 24
   4.1 Charakteristika studijního území ... 24
   4.2 Data ... 26
      4.2.1 PRISMA ... 26
      4.2.2 Sentinel-2B ... 27
      4.2.3 UAV snímky – MicaSense RedEdge-MX ... 29
      4.2.4 Terénní vzorky vojtěšky seté ... 30
   4.3 Zpracování dat ... 35
      4.3.1 Preprocessing ... 35
      4.3.2 Spektrální odezva ... 39
5. Výsledky ... 42
6. Diskuse ... 49
7. Závěr a přínos práce ... 51
8. Přehled literatury a použitých zdrojů ... 52

1. Úvod

V současné době, kdy je kladen stále větší důraz na efektivní využívání zemědělských a přírodních zdrojů, se monitorování vegetace pomocí metod dálkového průzkumu Země ukazuje jako klíčový nástroj pro optimalizaci zemědělské produkce a ochranu biodiverzity.

Kvantifikace biofyzikálních vlastností vegetace, jakými jsou například typy plodin, vlhkost půdy, obsah vody a pigmentů v listech a hustota porostu, jsou nezbytné pro správné hospodaření, nicméně žádné z nich nejsou přímo měřitelné metodami dálkového průzkumu. Vztah mezi výstupem ze senzorů (reflektancí) a těmito konkrétními vlastnostmi musí být vždy modelován. Rozlišujeme empirický přístup, kdy je použito pouze statistických matematických modelů k nalezení hledaných vztahů a mechanistický (fyzikální) přístup, který zahrnuje, mimo jiné, i mechanismy, které mezi proměnnými probíhají (Weiss et al., 2020).

Využití obrazové spektrometrie (analýzy hyperspektrálních dat) nabízí ucelený přehled o odezvě materiálů napříč celým optickým spektrem a umožňuje tedy přesnější určování těchto vztahů. Ačkoliv jsou tato spektrálně bohatá data citlivá na jemné změny ve vlastnostech vegetace, objevuje se problém spektrální multikolinearity, tedy redundance pásem. Tak jako v analýze multispektrálních dat, i v obrazové spektroskopii jsou nejčastějšími a nejjednoduššími metodami kvantifikace proměnných empirické metody parametrické regrese založené na vegetačních indexech (Verrelst et al., 2019)

Tato práce se zaměřuje na předzpracování hyperspektrálních snímků ze satelitu Italské vesmírné agentury (ASI) PRISMA, jejich analýzu a srovnání výsledků s výsledky laboratorního měření vzorků vegetace nasbíraných přímo v terénu. Tyto vzorky byly analyzovány spektroradiometricky, a také prostřednictvím destruktivních metod, jakými jsou Soxhletova extrakce pro získání pigmentů či sušení pro stanovení obsahu vody.

Aby bylo možné posoudit aplikovatelnost hyperspektrálních dat v širším kontextu, byl do analýzy začleněn i multispektrální satelitní snímek Sentinel-2 z programu Copernicus Evropské vesmírné agentury (ESA). Nejprve bylo na základě snímků z obou satelitů vypočítáno čtrnáct spektrálních indexů. Hodnoty použitých spektrálních pásem byly přizpůsobeny pásmům satelitu Sentinel-2. Regresní analýzou byly posouzeny jejich hodnoty ve vztahu k výsledkům spektroradiometrického měření. Následně byly indexy vypočítány ze snímků PRISMA s využitím jejich originálních hodnot vlnové délky pásem dle odborné literatury a opět hodnoceny regresní analýzou, tentokrát ve srovnání jak se spektroradiometrickým měřením tak s kvantitativními údaji o obsahu pigmentů a vody získanými z terénních vzorků. Veškeré výsledky a hodnocení jsou uvedeny v závěru práce.

2. Cíle DP

Hlavním cílem diplomové práce je pomocí přístupů obrazové spektrometrie získat vybrané vlastnosti (traits) nebo proměnné (variables) popisující aktuální stav vegetačního pokryvu z hyperspektrálních snímků družice PRISMA. Dalším cílem práce je získané vlastnosti a proměnné porovnat s referenčními terénními vzorky a dále s jejich alternativami získanými z multispektrálních satelitních snímků Sentinel-2. Dílčí cíle diplomové práce souvisí především s těmito výzkumnými otázkami:

(a) Je možné pomocí hyperspektrálních dat ze satelitu PRISMA získat spektrální a biochemické vlastnosti vegetace (spektrální odezva, vlhkost vegetace, obsah pigmentů)?

(b) Je relativně hrubé prostorové rozlišení dat ze satelitu PRISMA (30 m) využitelné pro precizní analýzu vegetace?

(c) Jak moc se výsledky budou lišit od analýzy nad multispektrálními daty? Jsou oba přístupy zaměnitelné, nebo je jeden výrazně výhodnější?

3. Literární rešerše

3.1 (Hyper)spektrální data

Senzory optického dálkového průzkumu Země využívají k získávání informací a dat světlo v optickém spektru, tedy viditelné pásmo spolu s přilehlými ultrafialovými a infračervenými vlnovými délkami.

Multispektrální senzory zaznamenávají obraz v několika diskrétních spektrálních pásmech. Typicky pokrývají základní pásma viditelného světla (červená, zelená, modrá) a mohou zahrnovat i infračervená pásma nebo jiné spektrální rozsahy mimo viditelné spektrum. Hyperspektrální snímání získává obraz ve stovkách až tisících úzkých souvislých spektrálních pásem, což umožňuje nabýt mnohem detailnější spektrální profil objektů na zemském povrchu (viz Obr. 1).

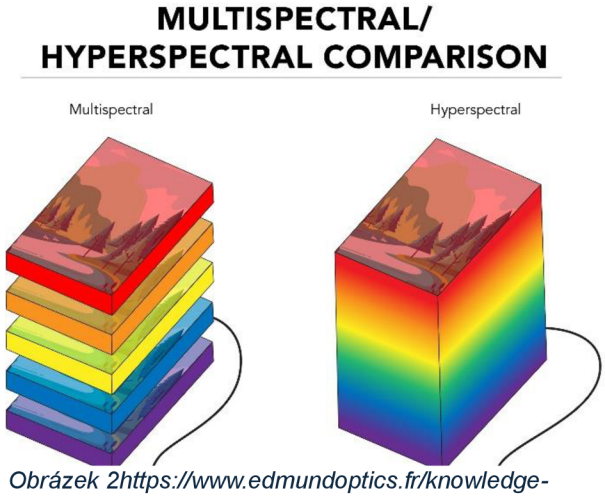

Obrázek 2https://www.edmundoptics.fr/knowledge-center/application-notes/imaging/hyperspectral-and-multispectral-imaging/

Obrázek 1 Porovnání multispektrálních a hyperspektrálních dat (Edmund Optics)

Sluneční světlo, primární zdroj energie pro většinu optických dálkových měření, prochází atmosférou, kde je část jeho energie absorbována nebo rozptýlena atmosférickými plyny a částicemi. Světlo, které dosáhne zemského povrchu a je odráženo zpět do senzoru, nese informace o charakteristikách povrchu. Kvalita a množství získaných dat jsou přímo ovlivněny množstvím dopadajícího světla a jeho spektrálními vlastnostmi, což vyžaduje hledání kompromisů mezi prostorovým a spektrálním rozlišením a poměrem signál/šum – menší a citlivější senzory pro jemné spektrální rozdíly zachytí méně objemu světla, tudíž musí pro zajištění dostatečného množství signálu zabírat větší obsah na čipu senzoru a „nezůstane“ prostor pro jemnější prostorové rozlišení.

V praxi to znamená, že systémy s vysokým prostorovým rozlišením (například panchromatické snímky), které dokáží zachytit detailní obrazy zemského povrchu, často disponují omezeným počtem spektrálních pásem a naopak, systémy s vysokým spektrálním rozlišením (hyperspektrální snímky) schopné rozlišit širokou škálu materiálových charakteristik mají obvykle nižší prostorové rozlišení (Loncan et al., 2015).

Samozřejmě existují výjimky, jednou z nich je například komerčně volně prodejný senzor CASI (Compact Airborne Spectrographic Imager) od společnosti ITRES, který disponuje 288 pásmy s 1,9nm intervaly na škále od 400 nm do 1000 nm. Jedná se o malý senzor upevňovaný na letadla, prostorové rozlišení dosahuje 1 m/px, cena senzoru se ovšem pohybuje ve vyšších desetitisících amerických dolarů (Ústav výzkumu globální změny AV ČR © 2016).

Naměřená spektrální odezva konkrétního objektu se často nazývá spektrálním podpisem, ovšem toto označení může vést k myšlence, že tato spektrální křivka je vždy konstantní a představuje jednoduchou linii, což není úplně přesné. Spektrálním podpisem se rozumí spíše jakási obálka, interval mezi dvěma křivkami, který může vykazovat variabilitu. Navíc, existují materiály s téměř totožným podpisem, či materiály, jejichž podpis vypadá jako kombinace podpisů dvou rozdílných a nekorelujících materiálů (Price, 1994). Proto je v práci místo „spektrální podpis“ použito slovní spojení „spektrální odezva“.

3.2 Spectral unmixing

Vzhledem k prostorovému rozlišení obou snímků hyperspektrálních i multispektrálních snímků může naměřená spektrální odezva v každém pixelu ve skutečnosti představovat kombinaci dvou a více materiálů. Technika spectral unmixing se zaměřuje na dekompozici odezvy každého pixelu na jednotlivé odezvy sledovaných materiálů, známých jako endmembers (koncové členy – „prvočinitele“).

Tento proces může být proveden lineárně, kdy se předpokládá, že spektrum pixelu je lineární kombinací spektrálních odezev materiálů (zpravidla při makroskopickém mísení – pouhým okem rozlišitelné materiály) nebo nelineárně, kdy se berou v úvahu složitější vzájemné interakce mezi materiály (mísení vícevrstvé – průchod signálu korunou stromů a kombinované odrazy signálu před dopadem na snímač nebo mísení mikroskopické – např. rozpuštěné železo ve vodě nebo malé kameny v písku)(Wei & Wang, 2020).

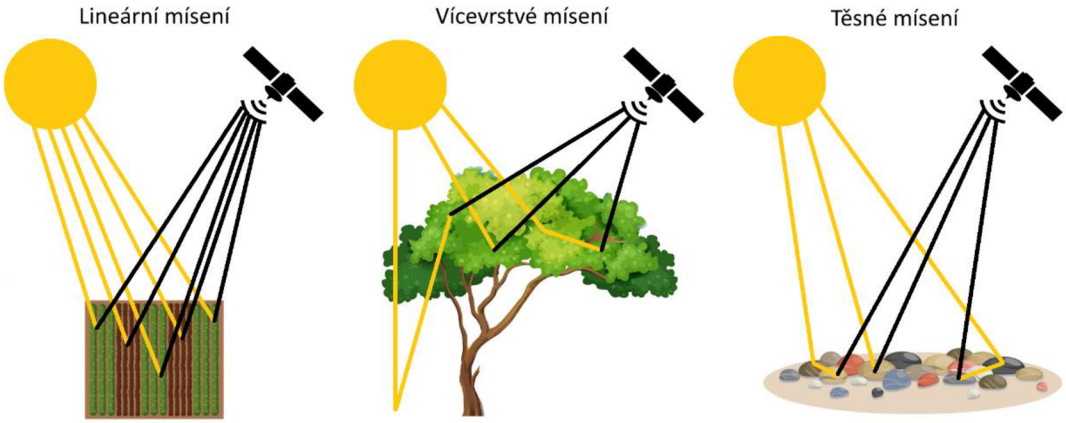

Obrázek 2 Typy mísení materiálu (autorka)

V případě této práce bylo uvažováno lineární mísení vojtěšky seté a holé půdy. Na satelitních snímcích se velmi často vyskytují stíny, které musí být také uvažovány v modelu, ale vzhledem k nízké výšce porostu a optimálním klimatickým podmínkám v čase akvizice snímku nebyly stíny téměř přítomny a mohly být zanedbány.

Obrázek 3 Fotografie z lokality v době sběru vzorků s patrným makroskopickým směšováním materiálů vyžadujícím spektrální unmixing získaného satelitního snímku (autorka)

Standardní rovnice pro lineární spektrální unmixing, kde y je spektrální odezva celého pixelu, f_1 frakce prvního člena a x_1 jeho odezva, f_2 frakce druhého člena, x_2 jeho spektrální odezva, vypadá takto:

$$y = f_1 * x_1 + f_2 * x_2 \, .$$

3.3 Pansharpening

Pansharpening je technika zostření multispektrálních či hyperspektrálních snímků při zachování původní spektrální kvality dat. Ke zostření snímku se využívá panchromatického snímku s vysokým prostorovým rozlišením. Mezi metody pansharpeningu patří metody CS (Component Substitution – substituce komponent), metody MRA (Multiresolution Analysis – multirozkladová analýza), hybridní metody, bayesiánské metody a Matrix Factorization (maticová faktorizace).

Mezi metody CS se řadí metoda PCA (Principal Component Analysis – analýza hlavních komponent) a GS (metoda Gram-Schmidt) (Loncan et al., 2015). Metoda PCA je založena na technice analýzy hlavních komponent, která transformuje původní korelovaná data na nové vzájemně nekorelované proměnné nazývané hlavní komponenty. Každá komponenta má vlastní míru variability – rozptylu dat, který vysvětluje. Podle tohoto rozptylu jsou komponenty seřazeny od největšího k nejmenšímu. První komponenta vysvětluje největší variabilitu původních dat, druhá komponenta vysvětluje největší variabilitu dat bez první komponenty, atd. Komponenty se stávají osami nového n-rozměrného souřadnicového systému a jsou tedy vzájemně ortogonálními vektory.

Při PCA pansharpeningu je využita hypotéza, která tvrdí, že první komponenta hyperspektrálních dat vyjadřuje prostorovou informaci snímku (nejvyšší vysvětlená variabilita dat v různých spektrech), další komponenty nesou spektrální informaci. Tato první komponenta je tedy nahrazena panchromatickým snímkem a poté je provedena reverzní analýza hlavních komponent – zpětná transformace dat do původního souřadnicového systému, jejímž výsledkem je snímek zachovávající spektrální rozlišení původních dat s prostorovým rozlišením panchromatického snímku (Loncan et al., 2015).

Metoda GS je zobecněním metody PCA. Gram-Schmidtova transformace (ortogonalizace) bere vektory, které nejsou vzájemně ortogonální a lineární transformací je převádí do systému, ve kterém ortogonální jsou. Při GS pansharpeningu každé pásmo snímku představuje jeden n-dimenzionální vektor (počet dimenzí je roven počtu pixelů ve snímku). Váženým průměrem spektrálních kanálů je vytvořen simulovaný panchromatický snímek s prostorovým rozlišením hyperspektrálních dat. Tento snímek je použit při Gram-Schmidtově transformaci jako první hlavní vektor, který není transformován (pokud by v tomto kroku byla jako první vektor vybrána první hlavní komponenta dat, dostaneme právě PCA pansharpening). Histogram opravdového panchromatického snímku je následně roztažen na hodnoty simulovaného panchromatického snímku a je za něj nahrazen. Poté je provedena zpětná transformace dat na původní hodnoty (Jenerowicz & Woroszkiewicz, 2016).

3.4 Soxhletova extrakce

Pro získaní vybraných vlastností (traits) nebo proměnných (variables) je možné využít jak přímého laboratorního měření tak nepřímých odhadů pomocínapř. vegetačních indexů získaných z dat DPZ. Pro laboratorní získání chlorofylu z terénních vzorků bylo použito Soxhletovy extrakce. Soxhletova extrakce byla vynalezena německým chemikem Franzem von Soxhletem v roce 1879. Tato metoda byla původně navržena pro extrakci lipidů z pevných materiálů, ale její využití se rozšířilo na širokou škálu aplikací v analytické chemii, včetně extrakce chlorofylu z rostlinného materiálu. Tento proces zahrnuje použití Soxhletova extraktoru, který umožňuje opakované vymývání pevného

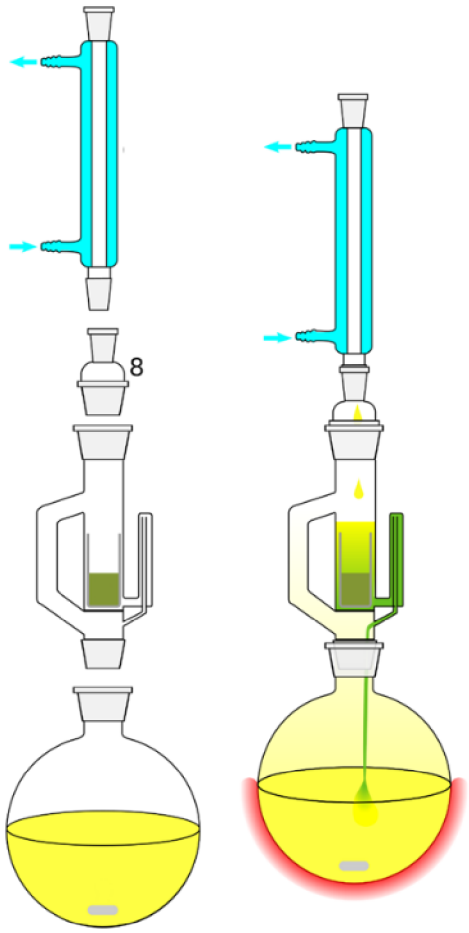

Obrázek 4 Diagram Soxhletova aparátu (uživatel Quantockgoblin na Wikimedia Commons)

materiálu rozpouštědlem bez nutnosti jeho větší spotřeby. Při extrakci chlorofylu se obvykle používají rozpouštědla jako je ethanol nebo aceton, která efektivně rozpouštějí chlorofyl bez degradace jeho molekulární struktury. V extraktoru se postupně vaří a odpařuje rozpouštědlo, které je nahoře chlazeno, kondenzuje a kape přes rostlinný materiál. Po dosažení ekvilibria vyteče rozpouštědlo nazpět do varné baňky a celý proces se opakuje. Tato metoda je ceněna pro svou efektivitu, schopnost extrahovat cílové sloučeniny s vysokou čistotou a minimální ztrátou rozpouštědla (Ramluckan et al., 2014). Diagram Soxhletova aparátu zobrazuje Obr. 4.

3.5 Spektrální indexy

Spektrální indexy jsou definovány tak, aby zvýraznily spektrální vlastnosti materiálů citlivé na hledané proměnné (Glenn et al., 2008). Hlavní výhodou indexů je jejich jednoduchost. Metody založené na spektrálních indexech byly definovány už v době prvních aplikacích satelitů s širokopásmovými senzory. Na počátku optického dálkového průzkumu byl k dispozici jen malý soubor spektrálních pásem a disponibilní výpočetní výkon byl značně omezený. To vedlo k dlouhé tradici vývoje jednoduchých dvoupásmových, nebo nejvýše tří až čtyřpásmových indexů, která pokračuje dodnes (Verrelst et al., 2019). Níže je popsáno sedm vegetačních indexů a sedm indexů citlivých na vlhkost.

3.5.1 NDVI (Normalized Difference Vegetation Index)

NDVI je asi nejznámější spektrální index používaný k hodnocení vegetace na základě její schopnosti odrážet blízké infračervené a viditelné světlo. Hodnoty NDVI se pohybují mezi -1 a 1, kde vyšší hodnoty indikují bohatší vegetaci (Tucker et al., 1979).

Rovnice pro výpočet je

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

3.5.2 GNDVI (Green Normalized Difference Vegetation Index)

GNDVI, rozšíření NDVI, zahrnuje zelenou barvu v oblasti viditelného spektra spolu s blízkým infračerveným světlem. Tento index byl navržen k lepšímu odhadu obsahu chlorofylu a dusíku v listech (Buschmann & Nagel, 1993).

Rovnice pro výpočet je

$$GNDVI = \frac{NIR - Green}{NIR + Green}$$

3.5.3 EVI (Enhanced Vegetation Index)

EVI je alternativou k NDVI, která zlepšuje měření při vysoké hladině vegetačního pokryvu, kde je NDVI již saturováno, zároveň redukuje vliv šumu a atmosférických podmínek (Huete et al., 1997).

Rovnice pro výpočet je:

$$EVI = 2.5 * \frac{NIR - Red}{1 + NIR + 6 * Red - 7.5 * Blue}$$

3.5.4 MCARI (Modified Chlorophyll Absorption in Reflectance Index)

MCARI je index speciálně zaměřený na odhad chlorofylového obsahu v listech rostlin, využívá zeleného pásma a dvou rozdílných červených pásem (Daughtry et al., 2000).

Rovnice pro výpočet je:

$$MCARI = [(Red_{700} - Red_{670})] - 0{,}2 * (Red_{700} - Green) * \frac{Red_{700}}{Red_{670}}$$

3.5.5 CIrededge (Chlorophyll Index Red Edge)

Index chlorofylu RedEdge je specializovaný vegetační index, který využívá spektrální oblast tzv. RedEdge, tedy přechodu mezi červeným (kolem 680 nm) a blízkým infračerveným (kolem 730 nm) spektrem. Tato oblast spektra je zvláště citlivá na změny v koncentraci chlorofylu v listech rostlin (Gitelson et al., 2003).

Rovnice pro výpočet je:

$$CIrededge = \frac{NIR}{rededge} - 1$$

3.5.6 NPCI (Normalized Pigment Chlorophyll Index)

NPCI je index citlivý na chlorofyl využívá odrazivost v červeném a modrém spektru (Peñuelas et al., 1993).

Rovnice pro výpočet je:

$$NPCI = \frac{Red - Blue}{Red + Blue}$$

3.5.7 VARI (Visible Atmospherically Resistant Index)

VARI je navržen pro použití v oblastech, kde není dostupné infračervené světlo, a vychází z odrazivosti ve viditelném spektru (Gitelson et al., 2002).

Rovnice pro výpočet je:

$$VARI = \frac{Green - Red}{Green + Red - Blue}$$

3.5.8 NDMI (Normalized Difference Moisture Index)

NDMI, index používaný k hodnocení obsahu vlhkosti ve vegetaci a půdě, se opírá o rozdíl v odrazivosti mezi blízkým infračerveným a krátkovlnným infračerveným spektrem (Gao, 1996).

Rovnice pro výpočet je:

$$NDMI = \frac{NIR - SWIR}{NIR + SWIR}$$

3.5.9 NDWI (Normalized Difference Water Index

NDWI, který původně vyvinul McFeeters (1996) pro detekci vodních ploch, je v modifikované verzi určen k detekci a monitorování obsahu vody v rostlinách a půdě, využívá rozdílu v odrazivosti v blízkém a krátkovlnném infračerveném spektru (Jackson et al., 2004).

Rovnice pro výpočet je:

$$NDWI = \frac{NIR - SWIR}{NIR + SWIR}$$

3.5.10 MSI (Moisture Stress Index)

MSI, zaměřený na odhalení stresu rostlin způsobeného nedostatkem vody, se opírá o odrazivost v krátkovlnném infračerveném spektru (Rock et al., 1986).

Rovnice pro výpočet je:

$$MSI = \frac{SWIR}{NIR}$$

3.5.11 NSDSI (Normalized Shortwave-Infrared Difference Bare Soil Moisture Index)

Tyto tři indexy byly navrženy pro monitorování vlhkosti holé půdy pomocí rozdílu v odrazivosti v krátkovlnném infračerveném spektru. Indexy NSDSI umožňují odhalit variace ve vlhkosti půdy (Yue et al., 2019).

Rovnice pro výpočet jsou:

$$NSDSI1 = \frac{SWIR_1 - SWIR_2}{SWIR_1}$$

$$NSDSI2 = \frac{SWIR_1 - SWIR_2}{SWIR_2}$$

$$NSDSI3 = \frac{SWIR_1 - SWIR_2}{SWIR_1 + SWIR_2}$$

3.6 Současný stav řešené problematiky

V současnosti existují dva hlavní přístupy modelování vztahů mezi naměřenou reflektancí a biofyzikálními vlastnostmi vegetace. Empirický, jenž využívá statistických matematických modelů a mechanistický, který využívá převážně modelů radiačního přenosu. V práci byly využity právě empirické modely založené čistě na matematických vztazích.

Mezi empirické metody patří nejčastější metoda založená na spektrálních indexech, které se i s postupem času jeví jako nejpřesnější metoda. Mnoho studií se pokoušelo o analýzy celého spektra, jako například analýzu hlavních komponent (Yao & Tian, 2003), faktorovou analýzu (N. Coops et al., 2002), analýzu pomocí neuronových sítí (Tumbo et al., 2002) a postupnou vícenásobnou regresi (O'neill et al., 2002). V literatuře lze ovšem nalézt příklady, kdy normalizovaný diferenční index využívající pouze dvě úzká vlnová pásma byl vhodnější než vícenásobný regresní model využívající pět vlnových pásem (Goel et al., 2003) nebo částečný regresní model založený na celém spektru metodou nejmenších čtverců (Hansen & Schjoerring, 2003).

Existuje řada fyzikálně založených modelů, které zohledňují interakce dopadajícího záření s listy a korunami stromů a jsou schopny simulovat reflektanční spektra. Modely jsou často používány v takzvaném „přímém směru" kdy vytvářejí simulovaná reflektanční spektra s použitím mnoha kombinací vstupních proměnných, které popisují biochemické a biofyzikální vlastnosti. Databáze těchto spekter jsou potom použity v „inverzním směru", kdy dokáží tyto proměnné zpětně kvantifikovat. Mezi nejznámější se řadí modely PROSPECT (Le Maire et al., 2004) a LIBERTY (N. C. Coops & Stone, 2005).

Existuje i hybridní přístup, který využívá spektrální indexy, které jsou korelovány s koncentrací listových pigmentů, jako funkci pro minimalizaci chyby při inverzním směru modelů (Zarco-Tejada et al., 2001). Techniky inverze model radiačního přenosu nabízejí potenciál obecnějšího přístupu ke kvantifikaci pigmentů z hyperspektrálních dat než spektrální pigmentové indexy a další přístupy, které jsou založeny na empirických kalibracích modelů, vyžadují ovšem znalost

parametrů a měření mnohem více proměnných na referenčních vzorcích (Demarez & Gastellu-Etchegorry, 2000).

4. Metodika

4.1 Charakteristika studijního území

Lokalita Amálie u obce Ruda na Rakovnicku je součástí školního zemědělského podniku ČZU. V roce 2019 zde byl zahájen projekt zaměřený na tvorbu modelové „chytré krajiny“. Tento projekt si klade za cíl implementaci funkčního systému opatření, která mají za úkol optimalizaci managementu vodních zdrojů, zvýšení biodiverzity, redukci eroze půdy, modifikaci mikroklimatu, a mnoho dalších. Konečným cílem je vytvoření soběstačného ekosystému, který bude schopen odolávat negativním dopadům sucha a povodní, a to i v kontextu sníženého výskytu srážek v dané lokalitě; a využití těchto poznatků i v jiných se suchem bojujících oblastech (ČZU © 2022).

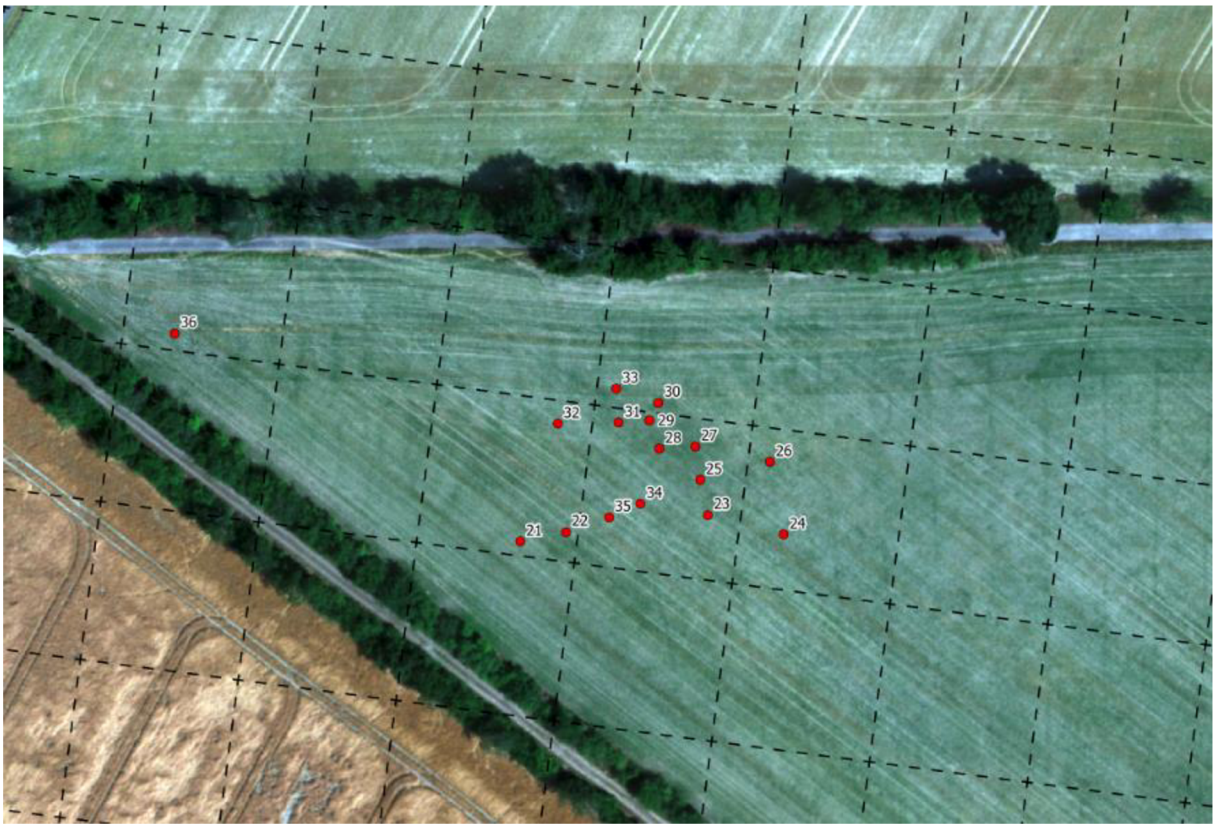

Obrázek 5 Výřez multispektrálního UAV snímku se znázorněnými body měření

4.2 Data

4.2.1 PRISMA

PRISMA (PRecursore IperSpettrale della Missione Applicativa – hyperspektrální předchůdce aplikační mise) je družice vlastněná a provozovaná Italskou vesmírnou agenturou (ASI). PRISMA je vybavena dvěma senzory: modul HYC (hyperspektrální kamera) a modul PAN (panchromatická kamera). HYC vybavený hranolovým (prizmatickým) disperzním spektrometrem pokrývá dvě pásma: VNIR/NIR (viditelné a blízké infračervené světlo) a NIR/SWIR (blízké infračervené a krátkovlnné infračervené světlo) s celkem 239 kanály. Druhým senzorem je modul PAN – optický snímač vysokého prostorového rozlišení s jedním panchromatickým kanálem, synchronizovaný s daty HYC pro testování technik fúze obrazů.

HYC má prostorové rozlišení 30 m a pracuje ve dvou pásmech: 66 kanálů VNIR/NIR s rozsahem 400-1010 nm a 173 kanálů NIR/SWIR s rozsahem 920-2505 nm. Hranolový tvar spektrometru má za následek nelineární spektrální rozptyl a šířka pásem se tedy mění v závislosti na jejich poloze v EM spektru. Pro pásmo VNIR/NIR je udávána šířka 9,4 nm a pro pásmo NIR/SWIR 9,3 nm. Modul používá techniku řádkového skenování (pushbroom) s šířkou pruhu 30 km a zorným polem 1000 km na každou stranu. Stejnou techniku skenování využívá i modul PAN, ale s prostorovým rozlišením 5 m.(Stefano et al., 2013)

Družice obíhá na heliosynchronní dráze ve výšce 614 km s inklinací 98.19° a LTDN (místním časem na sestupném uzlu) v 10:30 hod.

Co se hardwaru týče, vychází PRISMA z designu MITA (Minisatellite for Advanced Technology) vyvinutého společností CGS (Carlo Gavazzi Space S.p.A) s rozměry 1,751 x 1,545 x 3,400 m. Při radiofrekvenční komunikaci se využívá S-pásmo pro sledování, telemetrii a řízení, zatímco X-pásmo slouží pro datový downlink nákladu se subsystémem PDHT (Payload Data Handling and Transmission) určeným pro zpracování a přenos dat. Právě tento subsystém vyhodnocuje poměr signálu a šumu pro každé jednotlivé pásmo a rozhoduje o započtení pásma do snímku, výsledný počet pásem se tedy může mezi jednotlivými snímky/nálety lišit (eoPortal, 2012).

Obrázek 6 Satelit PRISMA (ASI)

Satelit PRISMA umožňuje natáčení senzoru pro akvizici konkrétní lokality. Pro získání dat byla zapotřebí registrace na stránkách ASI, podání oficiální žádosti o akvizici s popisem projektu, schválení této žádosti, vhodné klimatické podmínky a volný strojový čas družice. Hlavně poslední bod se ukázal být poměrně problematický, nakonec byla data nasnímána až po třech měsících po urgování a cíleném navýšení důležitosti žádosti ze strany ASI. Snímek byl pořízen 15.7.2023.

4.2.2 Sentinel-2B

Sentinel-2B je součástí programu Copernicus, hlavní iniciativy Evropské unie pro pozorování Země, spravované Evropskou kosmickou agenturou (ESA) ve spolupráci s Evropskou komisí. Sentinel-2B je vybaven nástrojem MSI (Multispectral Instrument), který poskytuje obrazová data ve 13 spektrálních kanálech v pásmech viditelného, blízkého infračerveného a krátkovlnného

infračerveného světla. Tento nástroj je navržen k poskytování podrobných obrazů zemského povrchu s vysokou frekvencí opakování a s vysokým rozlišením, což umožňuje sledování změn v čase na globální úrovni.

Prostorové rozlišení se liší v závislosti na konkrétním kanálu, s hodnotami od 10 m pro viditelná a blízká infračervená pásma do 20 m a 60 m pro specifická pásma krátkovlnného infračerveného světla a pro aplikace, jako je sledování atmosféry a oblačnosti.

Sentinel-2B obíhá na heliosynchronní dráze ve výšce přibližně 786 km s inklinací 98,57° a LTDN 10:30 hod.

Stejně jako u satelitu PRISMA je komunikace s pozemními stanicemi zajištěna pomocí X-pásma pro přenos vědeckých dat a S-pásma pro telemetrii, sledování a řízení.

Data byla stažena pomocí distribuční platformy Copernicus Data Space Ecosystem (Obr. 7). Browser je interaktivní webová stránka s přístupem k platformě umožňující výběr snímků ke stažení, případně i jednodušší analýzy (zpravidla spektrální indexy) přímo ve webovém prohlížeči (https://dataspace.copernicus.eu/news/2023-9-28-accessing-sentinel-mission-data-new-copernicus-data-space-ecosystem-apis).

Lokalita byla vybrána interaktivně s co nejbližším datem akvizice ke snímku ze satelitu PRISMA (17.07.2023). Snímek se nazývá S2B_MSIL2A_20230717T100559_N0509_R022_T33UVR_20230717T131029 (Obr. 7).

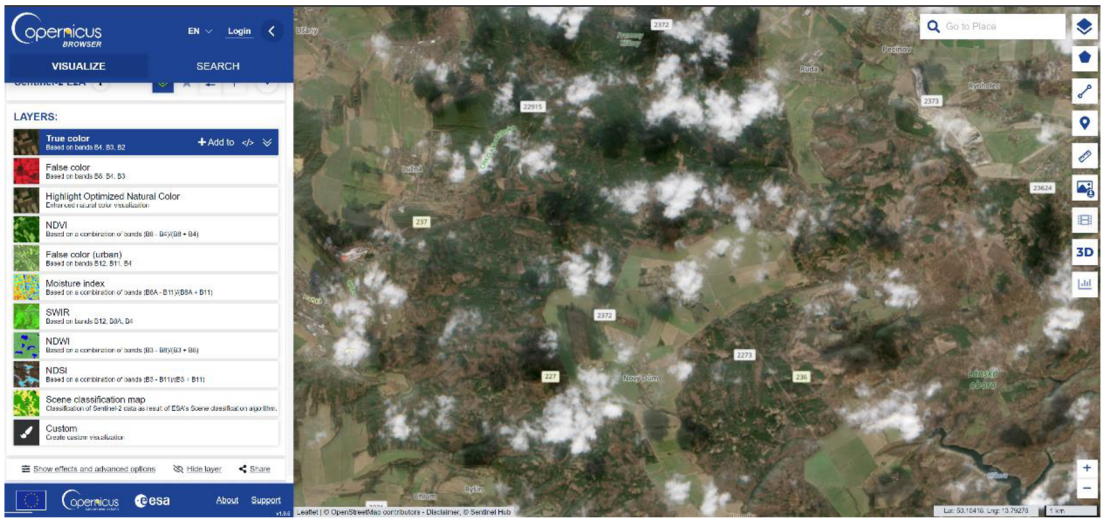

Obrázek 7 Výřez obrazovky z Copernicus Browser – výběr lokality pro stažení snímků

4.2.3 UAV snímky – MicaSense RedEdge-MX

Kamera MicaSense RedEdge-MX je vysoce výkonná multispektrální kamera určená primárně pro precizní zemědělství a výzkum životního prostředí. Kamera obsahuje pět pásem – modré, zelené, červené, pásmo Red-Edge a blízké infračervené. Šířka pásem se pohybuje od 12 nm do 57 nm a kamera váží pouhých 232 gramů. Při výšce letu 120 metrů nad zemí je prostorové rozlišení stanoveno na 8 cm/px.

Kamera byla připevněna na bezpilotní letoun typu křídlo eBee X od společnosti senseFly (Obr. 8). Dron má hmotnost pouhých 1,6 kilogramu a je navržen tak, aby byl kompatibilní s různými kamerami (mimo výše zmíněné kamery od MicaSense lze také na dron namontovat termální kamery, lidarové senzory, atp.). Křídlo také disponuje technologiemi RTK (Real-Time Kinematic) a PPK (Post-Processing Kinematic), které pomocí komunikace s referenčními stanicemi zpřesňují měření polohy dronu.

Obrázek 8 Křídlo eBee X (https://ageagle.com/drones/ebee-x/)

Snímky byly pořízeny v rámci pravidelného snímání lokality Amálie výzkumníky z Katedry prostorových věd na FŽP ČZU, kteří ze snímků vytvořili ortofotomozaiku, která byla poskytnuta bezúplatně. Dosažené prostorové rozlišení výsledné ortofotomozaiky bylo cca 24 cm/px.

4.2.4 Terénní vzorky vojtěšky seté

Pro referenční laboratorní měření byla potřeba nasbírat vzorky vegetace (vojtěšky seté) v terénu. Sběr vzorků byl uskutečněn 21.07.2023 metodou kvadrátů (quadrat sampling). Pro každý vzorek byl vybrán náhodný čtverec o rozměru 25 cm * 25 cm a v tomto čtverci byla sesbírána veškerá vegetace nad zemí a uložena do přenosné ledničky, která po dobu sběru zpomalila vadnutí vegetace. Po ukončení sběru byly vzorky převezeny do laboratoře, kde byl každý vzorek zvážen, rozdělen na třetiny (pro měření spektrální odezvy, vlhkosti a chlorofylu) a následně uložen v mrazícím zařízení při stabilní teplotě -26 °C, a to až do okamžiku provedení laboratorních analýz.

4.2.4.1 ASD FieldSpec4

ASD FieldSpec 4 je primárně terénní spektroradiometr, ke kterému lze připevnit kontaktní sondu a vlastní zdroj světla a přetvořit ho tak na laboratorní, čehož bylo v rámci diplomové práce využito (Obr. 9). Pomocí ASD FieldSpec 4 byla získána spektrální odezva nasbírané vegetace. Měření bylo prováděno v laboratoři Katedry prostorových věd na FŽP ČZU. Spektroradiometr poskytl Ing. David Moravec, Ph.D. z téže katedry.

4.2.4.2 Vlhkost

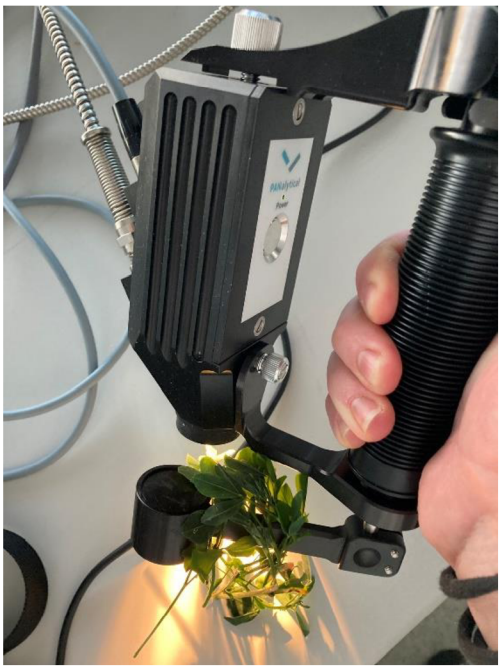

Obrázek 9 Ukázka z měření – otevřená kontaktní sonda spektrometru ASD FieldSpec 4 se vzorkem vojtěšky a viditelným zdrojem světla

Měření vlhkosti probíhalo v laboratoři Katedry prostorových věd FŽP ČZU zpřístupněné Ing. Martinou Kadlecovou. Pro každý vzorek byla nejprve zaznamenána jeho živá hmotnost analytickou vahou KERN ABS-N/ABJ-NM,

Obrázek 10 Pohled do sušící trouby Memmert s již vysušenými vzorky vojtěšky

následně byly vzorky vysušeny v sušicí troubě Memmert (Obr. 10) po dobu 24 hodin při teplotě 60 °C. Po dokončení sušení byly vzorky opět zváženy a z rozdílu

hmotností byl vypočítán obsah vody ve vzorcích. Na základě dříve zvážených čtverců o rozměrech 25 cm * 25 cm byl následně určen obsah vody ve vegetaci vztažený na jednotku plochy.

Takto vypadá upravená rovnice pro výpočet vegetační vlhkosti:

$$VWC = \frac{m_{25} * 0{,}0625 * (m_{ziva} - m_{sucha})}{1000 * m_{ziva}},$$

kde VWC je Vegetation Water Content – obsah vody v jednotkách $\frac{kg}{m^2}$,
m_{25} je živá hmotnost vzorku 25 cm * 25 cm v gramech,
m_{ziva} je živá hmotnost sušeného vzorku z konkrétního čtverce v gramech
a m_{sucha} je suchá hmotnost sušeného vzorku z konkrétního čtverce v gramech.

4.2.4.3 Chlorofyl

Měření chlorofylu probíhalo v laboratoři Katedry fyziologie rostlin na FAPPZ ČZU za pomocí Ing. Kamila Krause z téže katedry. Vzorky z poslední třetiny byly nejdříve zváženy, poté umístěny do buničinových kapslí a ty byly následně použity v Soxhletově extraktoru (Obr. 11). Extrahovaný roztok v acetonu byl homogenizován do objemu 100 ml. S využitím spektrofotometru THERMO Evolution™ 201 UV-Visible byla analyzována spektrální odezva tohoto roztoku ve čtyřech vybraných spektrálních pásmech. Pomocí příslušného vzorce byl určen obsah chlorofylu typu A a B, stejně jako karotenoidů ve vzorcích, vyjádřený v gramech na metr čtvereční (g/m^2).

Obrázek 11 Sestava 8 Soxhletových aparátů pro potřeby DP (autorka)

Pigmenty byly dopočítány podle následujících vzorců speciálně kalibrovaných na Soxhletovu extrakci:

$$Cl_a = 20 * [9{,}784 * (A_{663{,}8} - A_{710})] - [0{,}97 * (A_{646{,}8} - A_{710})],$$

$$Cl_b = 20 * [21{,}426 * (A_{646{,}8} - A_{710})] - [4{,}65 * (A_{663{,}8} - A_{710})],$$

$$Car. = \frac{20 * (1000\ A_{480} - 1{,}12\ Cl_a - 34{,}07\ Cl_b}{245},$$

kde Cl_a je obsah chlorofylu a,
Cl_b obsah chlorofylu b,
$Car.$ je obsah karotenoidů,
A_{480} je spektrální odezva vzorku na vlnové délce 480 nm,
$A_{646,8}$ spektrální odezva vzorku na vlnové délce 646,8 nm,
$A_{663,8}$ spektrální odezva vzorku na vlnové délce 663,8 nm
a A_{710} spektrální odezva vzorku na vlnové délce 710 nm (Kamil Kraus, II. 2024, in verb.).

4.3 Zpracování dat

4.3.1 Preprocessing

Hyperspektrální snímky PRISMA byly dotazovány a získány v podobě L2D produktu vyjadřujícího standardní reflektanci. To znamená, že již byly provedeny veškeré geometrické, radiometrické i atmosférické korekce, data odpovídají hodnotám reflektance při povrchu Země a jsou ortorektifikována. Data Sentinel-2B byla stažena v odpovídajícím formátu (pro Sentinel 2 se produkt nazývá L2A – Level 2A).

Ke zostření snímku PRISMA bylo využito metody Gram-Schmidt pansharpening v programu ENVI, čímž bylo prostorové rozlišení zlepšeno na 5 m/px. Data Sentinel byla převzorkována na 20 m/px.

Pro další postup bylo potřeba provést spectral unmixing snímků PRISMA a Sentinel-2B. Původní rovnice pro lineární spectral unmixing

$$y = f_{veg} * x_{veg} + f_{soil} * x_{soil} ,$$

kde y je spektrální odezva celého pixelu, f_{veg} frakce vojtěšky a x_{veg} její odezva, f_{soil} frakce holé půdy, x_{soil} její spektrální odezva byla upravena do tvaru pro zjištění spektrální odezvy vegetace:

$$x_{veg} = \frac{y - f_{soil} * x_{soil}}{f_{veg}},$$

zde namísto vstupních znalostí odezev jednotlivých materiálů a dopočítání jejich poměrů v pixelu známe odezvu pouze jednoho z nich a jejich poměry (vizualizace těchto poměrů se nazývá mapou abundancí). Mapa abundancí byla získána pomocí prahování hodnoty indexu NDVI v softwaru ArcGIS Pro.

Rovnice pro index NDVI je

$$\frac{NIR - Red}{NIR + Red} ;$$

pro pásma kamery RedEdge-MX tedy

$$\frac{B_5 - B_3}{B_5 + B_3},$$

kde B_5 představuje pátý kanál (NIR) a B_3 třetí kanál senzoru (červené pásmo)

Standardní prahová hodnota NDVI pro rozlišení vegetace a zbylých materiálů (v tomto případě holé půdy či suché vegetace) se udává 0,1999 (Hashim et al., 2019). Tato prahová hodnota byla manuálně posunuta na NDVI = 0,321 podle vizuální kontroly snímku (Obr. 12 a 13).

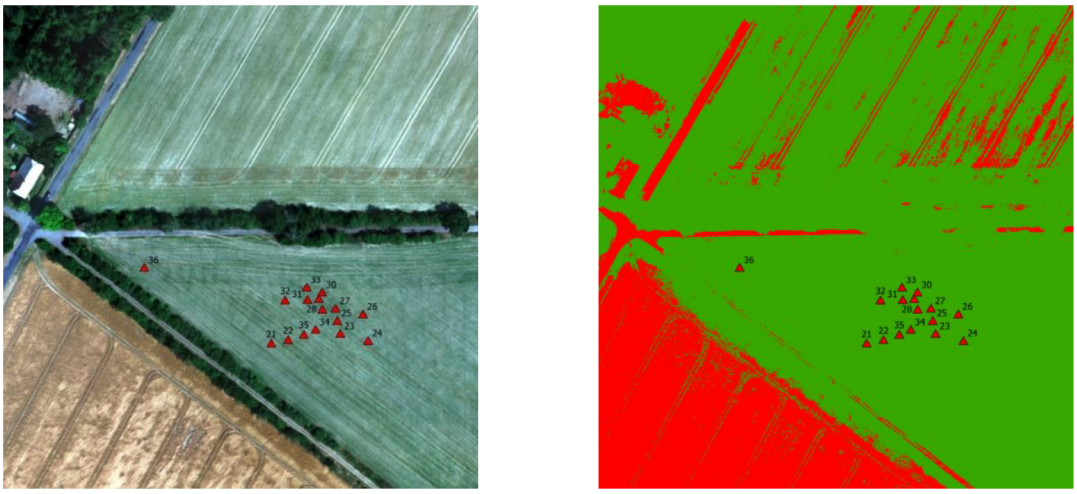

Obrázek 12 a 13 Pravé barvy MS UAV snímku, jsou zde patrné vyježdění cesty na horním poli, podle kterých byla posouvána prahová hodnota NDVI na 0,321 a 2 b) vizualizace hodnot NDVI na snímku (červená barva představuje NDVI < 0,321, zelená NDVI ≥ 0,321), červené trojúhelníky představují lokality nasbíraných vzorků.

Rovnice pro výpočet frakcí vypadá následovně:

$$fCover = 1 - \frac{NDVI_{max} - NDVI}{NDVI_{max} - NDVI_{min}},$$

kde $fCover$ vyjadřuje procentuální zastoupené vojtěšky v pixelu,
$NDVI_{max}$ vyjadřuje nejvyšší hodnotu NDVI ve snímku
(pro lokalitu odpovídá NDVI = 0,99995),
$NDVI_{min}$ vyjadřuje nejnižší hodnotu NDVI vegetace

(tedy v předchozím kroku získanou prahovou hodnotu 0,321)
a $NDVI$ vyjadřuje hodnotu indexu NDVI v konkrétním pixelu.

Pomocí této rovnice a rastrového kalkulátoru v softwaru ArcGIS Pro byla vytvořena mapa abundancí, která vyjadřuje procentuální zastoupení vojtěšky seté v pixelech vzhledem k holé půdě (Obr.14).

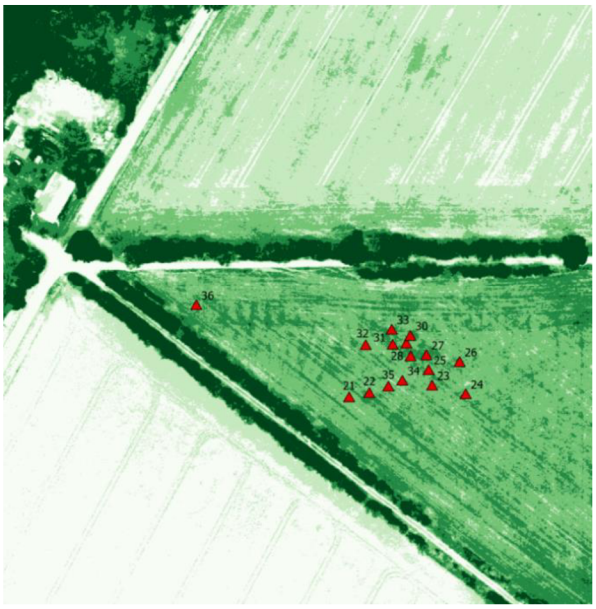

Obrázek 14 Mapa abundancí vojtěšky seté a holé půdy, čím tmavší zelená tím větší procentuální zastoupení vojtěšky vůči půdě

Tato mapa abundancí poté vstupovala do zonální statistiky v softwaru ArcGIS Pro, která rastr agregovala pomocí průměrné hodnoty tak, aby odpovídal pixelům satelitu PRISMA a Sentinel 2. Pro každý senzor tedy vznikla vlastní mapa abundancí s odpovídající prostorovým rozlišením (Obr. 15).

Obrázek 15 Ukázka agregované mapy abundancí pro senzor PRISMA

Spektrální odezva holé hlíny byla získána manuálně z obou původních snímků v softwaru QGIS. Na každém z nich bylo potřeba získat spektrální profil pixelu, který je celý pokryt hlínou, což bylo vzhledem k tomu, že nálet probíhal v zemědělské krajině v období žní, poměrně snadné.

Samotné dopočítání spektrální odezvy vojtěšky bylo realizováno pomocí vlastního R skriptu (v příloze), který iteruje rovnici pro výpočet spektrální odezvy vojtěšky skrze všechny pixely, kde se nacházelo terénní měření a všechny vlnové délky družic PRISMA a Sentinel-2B.

4.3.2 Spektrální odezva

Každý vzorek z terénního měření byl změřen spektrometrem ASD FieldSpec 4 a byla zjištěna jeho spektrální odezva (dvě měření zprůměrovaná do jedné hodnoty). Tyto odezvy byly použity jako referenční data pro posouzení kvality získaných odezev vegetace z hyperspektrálních a multispektrálních dat.

Data získaná měřením spektrometru a odvozená ze satelitů PRISMA a Sentinel 2 nejsou přímo srovnatelná kvůli rozdílům v měřítkách a senzitivitě senzorů. Pro

korektní porovnání byl upřednostněn postup výpočtu spektrálních indexů, jejichž bezrozměrné hodnoty tyto rozdíly v měřítkách eliminují.

V první fázi bylo vybráno a analyzováno celkem 14 vegetačních a vlhkostních indexů uvedených v Tab. 1, přičemž jejich výpočet v RStudio byl adaptován pro spektrální pásma satelitu Sentinel-2. Vzniklé hodnoty byly porovnávány s referenčním měřením vegetace spektrometrem.

Tabulka 1 Indexy s upravenými hodnotami pásem pro Sentinel-2

Spektrální index	Vzorec pro výpočet	Zdroj
Normalized Difference Vegetation Index (NDVI)	$NDVI = \frac{R_{864,7} - R_{704,1}}{R_{864,7} + R_{704,1}}$	Tucker et al., 1979
Chlorophyll Index Red Edge (Clrededge)	$Clrededge = \frac{R_{832,8}}{R_{740,5}} - 1$	Gitelson et al., 2003
Green Normalized Difference Vegetation Index (GNDVI)	$GNDVI = \frac{R_{864,7} - R_{664,6}}{R_{864,7} + R_{664,6}}$	Buschmann & Nagel, 1993
Normalized Pigment Chlorophyll Index (NPCI)	$NPCI = \frac{R_{704,1} - R_{559,8}}{R_{704,1} + R_{559,8}}$	Peñuelas et al., 1993
Enhanced Vegetation Index (EVI)	$EVI = 2.5 * \frac{R_{864,7} - R_{704,1}}{1 + R_{864,7} + 6 * R_{782,8} - 7.5 * R_{559,8}}$	Huete et al., 1997
Visual Atmospherically Resistant Index (VARI)	$VARI = \frac{R_{664,6} - R_{704,1}}{R_{664,6} + R_{704,1} - R_{559,8}}$	Gitelson et al., 2002
Modified Chlorophyll Absorption in Reflectance Index (MCARI)	$MCARI = [(R_{740,5} - R_{704,1})] - 0,2 * (R_{740,5} - R_{664,6}) * \frac{R_{740,5}}{R_{704,1}}$	Daughtry et al., 2000
Normalized Difference Moisture Index (NDMI)	$NDMI = \frac{R_{864,7} - R_{1613,7}}{R_{864,7} + R_{1613,7}}$	Gao, 1996
Normalized Difference Water Index 1 (NDWI1)	$NDWI1 = \frac{R_{664,6} - R_{1613,7}}{R_{664,6} + R_{1613,7}}$	Jackson et al., 2004
Normalized Difference Water Index 2 (NDWI2)	$NDWI2 = \frac{R_{664,6} - R_{2202.4}}{R_{664,6} + R_{2202.4}}$	
Moisture Stress Index (MSI)	$MSI = \frac{R_{1613,7}}{R_{864,7}}$	Rock et al., 1986
Normalized Difference Soil Moisture Index 1 (NSDSI1)	$NSDSI1 = \frac{R_{1613,7} - R_{2202.4}}{R_{1613,7}}$	
Normalized Difference Soil Moisture Index 2 (NSDSI2)	$NSDSI2 = \frac{R_{1613,7} - R_{2202.4}}{R_{2202.4}}$	Yue et al., 2019
Normalized Difference Soil Moisture Index 3 (NSDSI3)	$NSDSI3 = \frac{R_{1613,7} - R_{2202.4}}{R_{1613,7} + R_{2202.4}}$	

V dalším kroku bylo využito původních, neupravených rovnic indexů s konkrétními vlnovými délkami pásem dle literatury uvedených v Tab. 2 pro analýzu dat získaných výhradně ze satelitu PRISMA. Výsledky těchto výpočtů byly porovnány jak s měřeními ze spektrometru tak s empirickými laboratorními měřeními, která zahrnovala Soxhletovu extrakci pro zjištění obsahu chlorofylu a výpočet volumetrického obsahu vody (VWC) z rozdílu mezi původní a suchou hmotností vzorků.

Tabulka 2 Indexy s originálními hodnotami pásem dle literatury

Spektrální index	Vzorec pro výpočet	Zdroj
Normalized Difference Vegetation Index (NDVI)	$NDVI = \frac{R_{800} - R_{670}}{R_{800} + R_{670}}$	Tucker et al., 1979
Chlorophyll Index Red Edge (CIrededge)	$CIrededge = \frac{R_{750}}{R_{705}} - 1$	Gitelson et al., 2003
Green Normalized Difference Vegetation Index (GNDVI)	$GNDVI = \frac{R_{801} - R_{550}}{R_{801} + R_{550}}$	Buschmann & Nagel, 1993
Normalized Pigment Chlorophyll Index (NPCI)	$NPCI = \frac{R_{680} - R_{430}}{R_{680} + R_{430}}$	Peñuelas et al., 1993
Enhanced Vegetation Index (EVI)	$EVI = 2.5 * \frac{R_{1088} - R_{700}}{1 + R_{1088} + 6 * R_{700} - 7.5 * R_{449}}$	Huete et al., 1997
Visual Atmospherically Resistant Index (VARI)	$VARI = \frac{R_{560} - R_{660}}{R_{560} + R_{640} - R_{485}}$	Gitelson et al., 2002
Modified Chlorophyll Absorption in Reflectance Index (MCARI)	$MCARI = [(R_{700} - R_{670})] - 0{,}2 * (R_{700} - R_{550}) * \frac{R_{700}}{R_{670}}$	Daughtry et al., 2000
Normalized Difference Moisture Index (NDMI)	$NDMI = \frac{R_{820} - R_{1600}}{R_{820} + R_{1600}}$	Gao, 1996
Normalized Difference Water Index 1 (NDWI1)	$NDWI1 = \frac{R_{860} - R_{1240}}{R_{860} + R_{1240}}$	Jackson et al., 2004
Normalized Difference Water Index 2 (NDWI2)	$NDWI2 = \frac{R_{860} - R_{2200}}{R_{860} + R_{2200}}$	
Moisture Stress Index (MSI)	$MSI = \frac{R_{1600}}{R_{820}}$	Rock et al., 1986
Normalized Difference Soil Moisture Index 1 (NSDSI1)	$NSDSI1 = \frac{R_{1600} - R_{2200}}{R_{1600}}$	
Normalized Difference Soil Moisture Index 2 (NSDSI2)	$NSDSI2 = \frac{R_{1600} - R_{2200}}{R_{2200}}$	Yue et al., 2019
Normalized Difference Soil Moisture Index 3 (NSDSI3)	$NSDSI3 = \frac{R_{1600} - R_{2200}}{R_{2200}}$	

Pro křivku spektrálních odezvy vojtěšky ze spektrometru ASD FieldSpec4 a spočtenou křivku spektrální odezvy vegetace ze satelitu PRISMA bylo provedeno odstranění kontinua pomocí nástroje Continuum Removal v programu ENVI. Křivky po odstranění kontinua byly vytaženy do grafů a porovnány.

Byla provedena lineární regresní analýza. Regresní analýza je statistická metoda používaná k modelování vztahu mezi závislou proměnnou (obvykle označovanou Y) a jednou nebo více nezávislými proměnnými (označovanými X). Cílem je předpovědět hodnotu závislé proměnné na základě hodnot nezávislých proměnných.

Kvalita modelů byla hodnocena pomocí koeficientu determinace (R2), jenž vysvětluje celkové množství variability dat popsaných pomocí modelu, a RMSE (Root Mean Square Error), což je míra průměrné chyby předpovědí modelu.

5. Výsledky

Na obrázku 16 jsou viditelné spektrální odezvy smíšeného pixelu, holé půdy a samotné vegetace v pixelu 30 ze satelitu PRISMA. Můžeme pozorovat rozdílné chování křivky holé (vlhké) půdy a vojtěšky v pásmu cca 650 nm – 750 nm – oblasti Red-Edge. Na rozdíl od křivky vojtěšky, která v této oblasti nejprve lehce klesá a poté velmi intenzivně naroste, je průběh nárůstu křivky půdy téměř konstantní. To nasvědčuje korektní selekci pixelu s holou půdou. Na křivkách jsou patrná absorpční pásma vody v cca 1400 nm a 1900 nm.

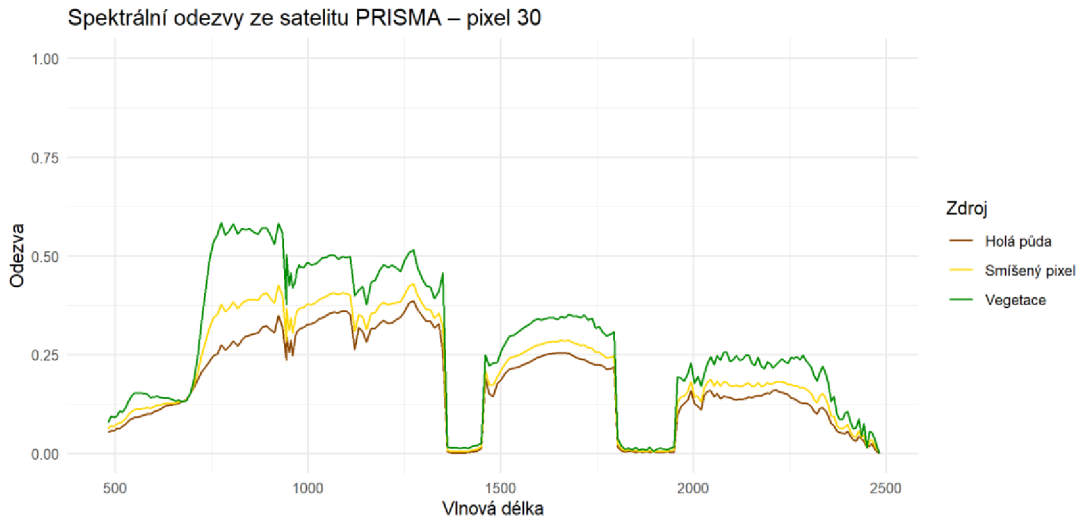

Obrázek 16 Spektrální odezvy smíšeného pixelu, holé půdy a samotné vegetace v pixelu 30 ze satelitu PRISMA

Na dalším grafu (Obr. 17) jsou křivky ze satelitu Sentinel-2B pro tutéž oblast. Vzhledem k tomu, že Sentinel-2 disponuje pouze 13 pásmy, tak je průběh křivky spektrální odezvy viditelně generalizovaný oproti PRISMA. Na tomto grafu je ovšem znatelná vyšší odezva signálu u holé půdy oproti vegetaci v oblasti Red-Edge, což koresponduje s modelovými spektrálními křivkami vegetace a půdy uvedenými v literatuře.

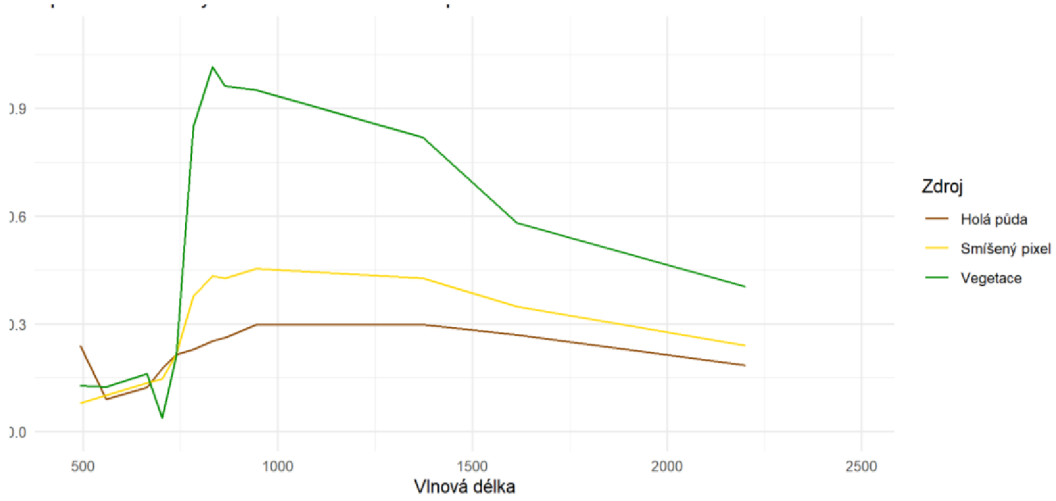

Obrázek 17 Spektrální odezvy smíšeného pixelu, holé půdy a samotné vegetace v pixelu 30 ze satelitu Sentinel-2

Na obrázku 18 je ukázka spektrálních křivek samotné vojtěšky ze satelitů PRISMA a Sentinel-2B s odstraněným kontinuem.

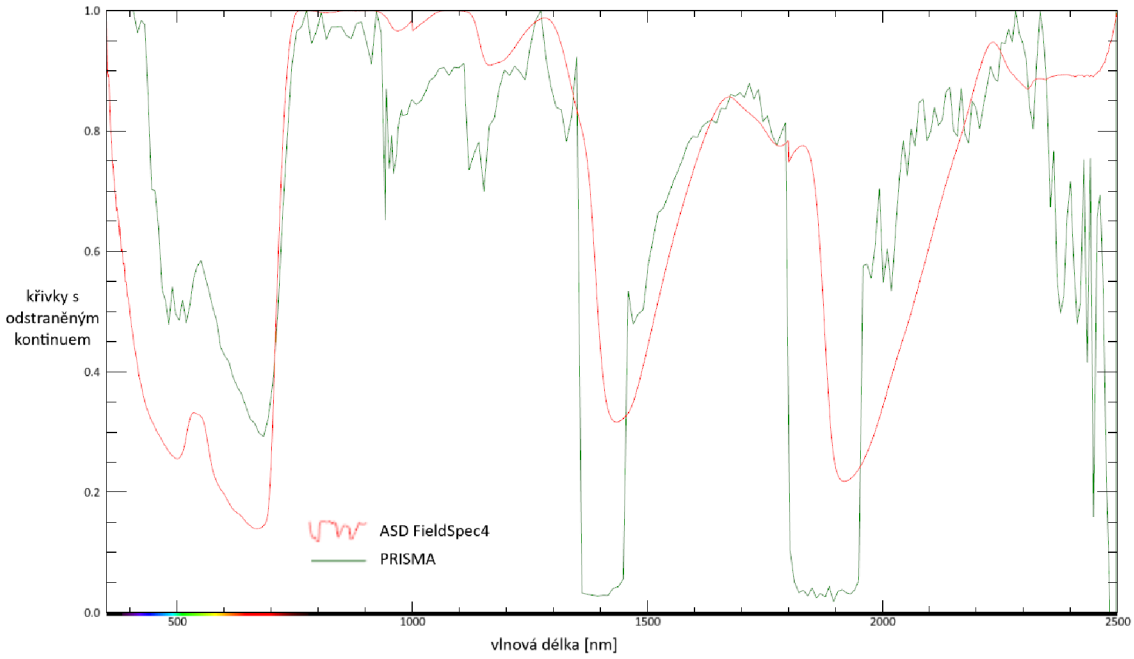

Obrázek 18 Spektrální křivky samotné vegetace ze satelitů PRISMA a Sentinel-2 s odstraněným kontinuem

Je patrné, že spektrální odezva ze spektrometru je oproti PRISMA nejvýrazněji odlišná v absorpčních pásmech vody (1400 nm a 1900 nm). I přesto je však z obr. 18 patrné, že mají obě křivky velmi podobný trend, což potvrzuje korektní preprocessing dat ze satelitu PRISMA a získání správné spektrální odezvy vegetace.

Byla provedena regresní analýza, jejímž výsledkem byly rovnice pro kvantifikaci hodnot ze spektrometru s použitím spektrálních indexů ze satelitů. V tabulce 3 (která je rozdělená na půl sloupce s jednotlivými indexy, kdy levá část tabulky reprezentuje rovnici modelu, R2 – koeficient determinace, a RMSE pro Sentinel-2B, a pravá ty samé hodnoty pro PRISMA) vidíme výsledky provedené regresní analýzy a její výsledné modely spektrálních indexů obou satelitů i s mírami jejich shodnosti s referenčními daty.

Tabulka 3 Výsledky kalibrace matematických modelů spektrálních indexů v porovnání se spektroradiometrickým měřením

$y = -0{,}186881x + 0{,}827225$	0,86	0,04	GNDVI	0,95	0,04	$y = -0{,}312488x + 0{,}827225$
$y = -0{,}45599x + 0{,}17975$	0,75	0,13	NPCI	0,79	0,20	$y = -0{,}078398x + 0{,}179748$
$y = 0{,}110219x + 0{,}251590$	0,90	0,02	EVI	0,09	0,02	$y = -0{,}011039x + 0{,}251590$
$y = 1{,}84441x - 0{,}93234$	0,86	0,36	VARI	0,97	0,06	$y = 0{,}72319x - 0{,}93234$
$y = -0{,}24151x + 0{,}69173$	0,09	0,32	MCARI	0,26	0,13	$y = -0{,}16756x + 0{,}69173$
$y = -0{,}163731x + 0{,}374481$	0,56	0,06	NDMI	0,50	0,07	$y = -0{,}17551x + 0{,}37467$
$y = 0{,}16611x - 0{,}66489$	0,78	0,04	NDWI1	0,88	0,66	$y = 0{,}32015x - 0{,}67034$
$y = 0{,}07231x - 0{,}41006$	0,23	0,08	NDWI2	0,66	0,09	$y = 0{,}25463x - 0{,}41777$
$y = 0{,}1966x + 0{,}455770$	0,52	0,08	MSI	0,48	0,08	$y = 0{,}212601x + 0{,}455620$
$y = -0{,}195367x + 0{,}519311$	0,78	0,05	NSDSI1	0,75	0,05	$y = -0{,}188333x + 0{,}519519$
$y = -0{,}60693x + 1{,}08794$	0,75	0,15	NSDSI2	0,73	0,16	$y = -0{,}59230x + 1{,}08941$
$y = -0{,}157737x + 0{,}351246$	0,77	0,04	NSDSI3	0,75	0,04	$y = -0{,}152774x + 0{,}351475$

Pro satelit PRISMA jsou hodnoty koeficientu determinace zpravidla vyšší a

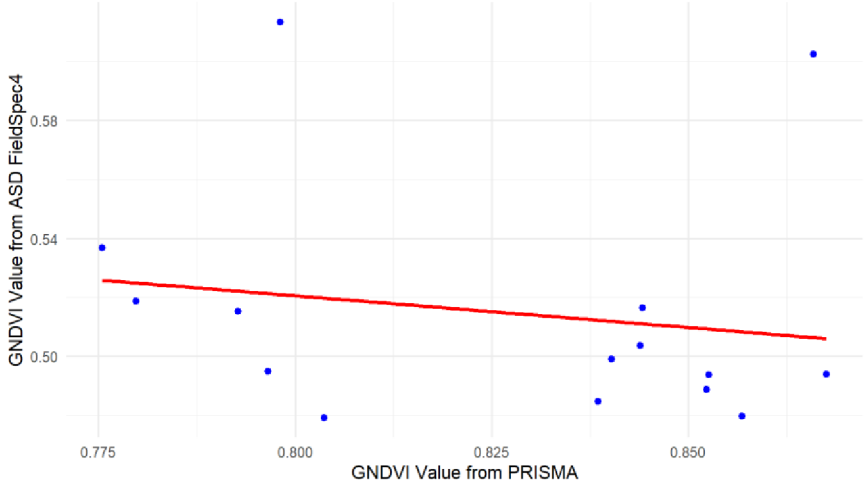

Obrázek 19 Závislost hodnot indexu GNDVI ze spektroradiometru na hodnotách ze satelitu PRISMA

hodnoty RMSE zpravidla nižší než u satelitu Sentinel-2B. Nejvyššího koeficientu u PRISMA dosáhl spektrální index VARI (0,97), naopak nejnižšího EVI (0,09). Nejnižší RMSE měl index EVI (0,02) a nejvyšší NDWI1 (0,66). V případě Sentinel-2B dopadl na základě koeficientu determinace index EVI (0,90) a nejhůře MCARI (0,09). Nejnižší RMSE měl index EVI (0,02) a naopak nejvyšší byla u indexu CIrededge (0,59). Na obrázku 19 vidíme grafické znázornění příkladu

závislosti hodnoty indexu GNDVI vypočtené z dat ASD FieldSpec4 na hodnotě vypočítané ze satelitu PRISMA.

Porovnání indexů s originálními hodnotami pásem proběhlo pouze pro satelit PRISMA a jeho porovnání s původními hodnotami indexu vidíme v tabulce 4, která je rozdělená do půl sloupců, kde obě poloviny reprezentují hodnoty z PRISMA – nalevo se nachází výsledky modelů spektrálních indexů upravených pro pásma Sentinel-2B a napravo indexů s originálními hodnotami dle literatury.:

Nejvyšší hodnotu koeficientu determinace s upravenými pásmy pro Sentinel-2B měl index VARI (0,97), který měl nejlepší hodnoty i ve své originální podobě (také 0,97). Nejhůře si pak pro upravená pásma vedl index EVI s hodnotou 0,02 a pro originální pásma index NDWI1 se zápornou hodnotu R2=-0,04. Pro RMSE dopadl u upravených pásem nejlépe index EVI (0,02) a nejhůře NDWI1 (0,66). V originálních pásmech měl nejmenší RMSE index NDWI1 (0,01) a nejvyšší index MCARI (0,76). Je vidět zdánlivé zlepšení hodnot koeficientu determinace, což může znamenat větší korelaci mezi naměřenými hodnotami ze satelitu a spektroradiometru a tudíž lepší model, nicméně pořád platí značný rozptyl hodnot ve scatterplotu, na obrázku 19 pro hNDVI (hyperspektrální NDVI)

Tabulka 4 Výsledky kalibrace matematických modelů spektrálních indexů v porovnání se

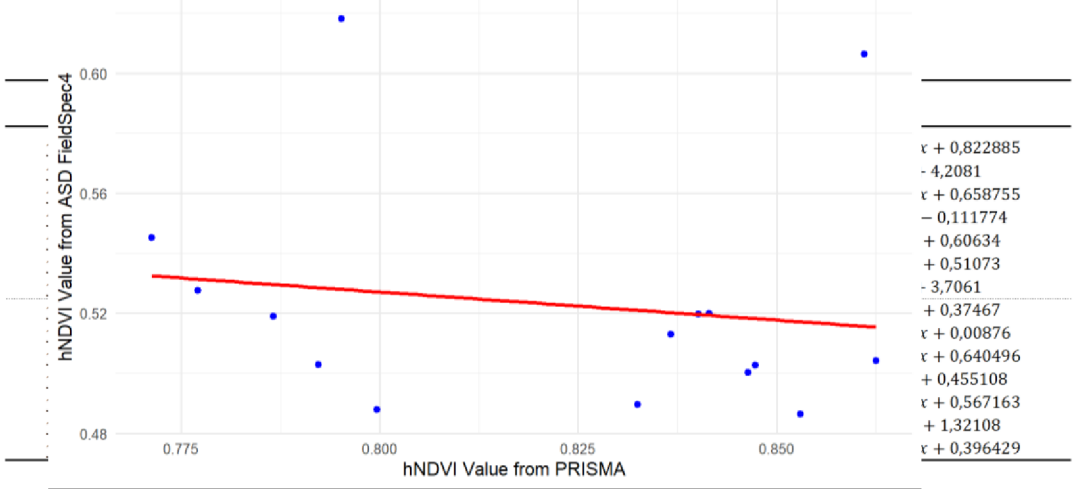

Obrázek 19 Závislost hodnot indexu hNDVI ze spektroradiometru na hodnotách ze satelitu PRISMA

Dalším výsledkem práce jsou modely reprezentující závislost přímo měřených hodnot chlorofylu a vlhkosti v závislosti na naměřených indexech ze satelitu PRISMA (tabulka 5), ve které se na levé straně nachází porovnání modelů indexů se spektroradiometrickým měřením a napravo s laboratorními metodami extrakce ze vzorků

Tabulka 5 Výsledky kalibrace matematických modelů spektrálních indexů z PRISMA v porovnání se spektroradiometrickým (vlevo) a laboratorním (vpravo) měřením

Model	porovnání se spektrometrem		Indexy	porovnání s empirickým měřením		Model
	R2	RMSE		R2	RMSE	
$y = 0{,}16936x + 0{,}59602$	0,79	0,04	hNDVI	-0,02	37,03	$y = 222{,}2x - 14{,}3$
$y = -0{,}060651x + 0{,}192347$	0,47	0,03	Clrededge	-0,07	37,08	$y = -218x + 130{,}6$
$y = -0{,}312488x + 0{,}827225$	0,95	0,04	GNDVI	0,10	34,81	$y = 1926{,}8x - 361{,}6$
$y = -0{,}078398x + 0{,}179748$	0,79	0,20	NPCI	0,17	33,34	$y = -888{,}2x + 191{,}9$
$y = -0{,}011039x + 0{,}251590$	0,09	0,02	EVI	-0,03	37,12	$y = 204{,}03x - 3{,}17$
$y = 0{,}72319x - 0{,}93234$	0,97	0,06	VARI	-0,05	37,54	$y = -155{,}36x + 69{,}36$
$y = -0{,}16756x + 0{,}69173$	0,26	0,13	MCARI	0,05	35,77	$y = 179{,}511x + 7{,}755$
$y = -0{,}17551x + 0{,}37467$	0,50	0,07	NDMI	-0,05	0,01	$y = 0{,}03333x + 0{,}10047$
$y = 0{,}32015x - 0{,}67034$	0,88	0,66	NDWI1	-0,03	0,01	$y = 0{,}042703x + 0{,}103213$
$y = 0{,}25463x - 0{,}41777$	0,66	0,09	NDWI2	-0,05	0,01	$y = -0{,}04298x + 0{,}12430$
$y = 0{,}212601x + 0{,}455620$	0,48	0,08	MSI	-0,03	0,01	$y = -0{,}03070x + 0{,}12765$
$y = -0{,}188333x + 0{,}519519$	0,75	0,05	NSDSI1	0,23	0,01	$y = -0{,}16804x + 0{,}16275$
$y = -0{,}59230x + 1{,}08941$	0,73	0,16	NSDSI2	0,27	0,01	$y = -0{,}08187x + 0{,}14785$
$y = -0{,}152774x + 0{,}351475$	0,75	0,04	NSDSI3	0,24	0,01	$y = -0{,}24294x + 0{,}15539$

Posledním výsledkem je porovnání indexů spočtených z ASD FieldSpec4 a PRISMA s laboratorními měřeními (Tab. 6). V tomto případě dopadly výsledky regresní

Tabulka 6 Výsledky kalibrace matematických modelů spektrálních indexů z PRISMA (vlevo) a z ASD FieldSpec4 (vpravo) v porovnání s laboratorním měřením chlorofylu a vlhkosti

Model	PRISMA		Indexy	spektroradiometr		Model
	R2	RMSE		R2	RMSE	
$y = 222{,}2x - 14{,}3$	-0,02	37,03	hNDVI	0,05	35,67	$y = -422{,}9x + 449{,}9$
$y = -218x + 130{,}6$	-0,07	37,08	Clrededge	0,05	35,67	$y = -14{,}5x + 162{,}87$
$y = 1926{,}8x - 361{,}6$	0,10	34,81	GNDVI	-0,07	37,82	$y = 41{,}27x + 76{,}83$
$y = -888{,}2x + 191{,}9$	0,17	33,34	NPCI	0,20	32,70	$y = -426{,}7x + 383$
$y = 204{,}03x - 3{,}17$	-0,03	37,12	EVI	-0,08	37,99	$y = -0{,}3479x + 103{,}1391$
$y = -155{,}36x + 69{,}36$	-0,05	37,54	VARI	0,09	34,91	$y = 428{,}25x + 149{,}72$
$y = 179{,}511x + 7{,}755$	0,05	35,77	MCARI	-0,07	37,82	$y = -70{,}61x + 137{,}91$
$y = 0{,}03333x + 0{,}10047$	-0,05	0,01	NDMI	0,10	0,01	$y = 0{,}14566x + 0{,}04065$
$y = 0{,}042703x + 0{,}103213$	-0,03	0,01	NDWI1	0,09	0,01	$y = -0{,}13859x + 0{,}15886$
$y = -0{,}04298x + 0{,}12430$	-0,05	0,01	NDWI2	-0,09	0,01	$y = 0{,}03339x + 0{,}10401$
$y = -0{,}03070x + 0{,}12765$	-0,03	0,01	MSI	0,02	0,01	$y = -0{,}08906x + 0{,}16398$
$y = -0{,}16804x + 0{,}16275$	0,23	0,01	NSDSI1	0,25	0,01	$y = -0{,}06490x + 0{,}14375$
$y = -0{,}08187x + 0{,}14785$	0,27	0,01	NSDSI2	0,27	0,01	$y = -0{,}01469x + 0{,}12634$
$y = -0{,}24294x + 0{,}15539$	0,24	0,01	NSDSI3	0,31	0,01	$y = -0{,}07131x + 0{,}13521$

analýzy hůře, než tomu bylo u porovnání se spektrální odezvou. Nejlépe si pro PRISMA data vedl index NSDSI2 s R2=0,27, nejhůře potom index CIrededge s R2=-0,07. U spektroradiometru měl největší koeficient determinace index také index NSDSI2 (0,27) a nejmenší potom index NDWI2 (-0,09).

6. Diskuse

Preprocessing vstupních dat proběhl zdánlivě korektně, porovnání se spektroradiometrickým měřením naznačuje závislost dat měřených spektroradiometrem a počítaných ze satelitních snímků. Při porovnání s laboratorním měřením chlorofylu a vlhkosti už vztahy nevychází tak dobře. To může být způsobeno příliš malou lokalitou, na které byly vzorky sbírány. Při originálním rozlišení satelitu PRISMA 30 m/px by totiž vzorky odpovídaly pouhým čtyřem pixelům. Metoda pansharpeningu, ač průlomová, rozhodně není stoprocentní a spektrální odezva z těchto dat nemusí odpovídat reálné.

Vzorky byly po nasbírání zmraženy, aby se vadnutím nesnižovala jejich spektrální odrazivost. Pro extrakci chlorofylu by ovšem byly ideální vzorky čerstvé. Technika extrakce chlorofylu nemusela z tohoto důvodu být úplně stoprocentně korektní.

Lokalita byla nalétnuta satelitem 15.7.2023, sběr vzorků proběhl až 21.7.2023, protože informace o pořízení snímku je sdělována až ex post, když jsou data již nasnímaná, což velmi komplikuje plánování pozemního měření. Tato prodleva šesti dní mohla také způsobit nepoměr mezi hodnotami modelů ze satelitu a ze vzorků.

V neposlední řadě byla problematickým faktorem hustota vegetačního pokryvu, kdy byly jednotlivé pixely snímku PRISMA tvořeny kombinací vojtěšky a holé půdy. Tento problém byl v práci vyřešen použitím metody spectral unmixing, nicméně i ta mohla přispět k možné snížené věrohodnosti provedených vyhodnocení.

Na základě získaných výsledků diplomové práce se nepodařilo stoprocentně prokázat využitelnost dat z hyperspektrálního satelitu, nicméně mnoho studií na toto téma tvrdí, že hyperspektrální data přinášejí nové důležité informace, které se z multispektrálních dat získat nedají, hlavně co se týče vlhkosti vegetace (Kremezi et al., 2021). V práci bylo zjištěno, že spektrální indexy NSDSI, ač originálně vytvořeny pro obsah vlhkosti v půdě, byly značně citlivé na obsah vody ve vegetaci. Toto zjištění může být hodnotné pro další analýzu.

V některých případech regresní analýzy spektrálních indexů byl koeficient determiance dokonce záporný. Záporná hodnota koeficientu determinace znamená, že model vysvětluje variabilitu hůře než model, který by pouze používal průměr závislé proměnné. To může být způsobeno nesprávnou metodou empirických měření na vzorcích, ale také obecně nepřesností satelitu, potažmo nesprávné statistické metody.

Co se týče závislosti hodnot indexů vypočtených spektroradiometru na hodnotách ze satelitu PRISMA, vykazuje většina hodnot určitou míru korelace, na tak malém vzorku ale nemůžeme s jistotou hovořit o přímém vztahu, navíc jsou u všech indexů patrné hodnoty, které značně nezapadají do trendu ostatních hodnot. Obdobně vypadají data u ostatních indexů jak pro satelit PRISMA tak pro Sentinel-2B. Vysoká míra koeficientu determinace ale křivka lineárního modelu neprocházející daty naznačuje možnou nelinearitu vztahu. Výsledky porovnání hodnot spektroradiometru s laboratorním měřením dopadly velmi podobně jako u satelitu PRISMA, tudíž se jeví, že problém nastal spíše při sběru vzorků a jejich měření.

7. Závěr a přínos práce

Z výsledků diplomové práce je patrné, že spektrální indexy opravdu korelují s biofyzikálními a biochemickými proměnnými ve vegetaci. Výše této korelace závisí od kvality nasbíraných vzorků a použité metodě získání těchto proměnných (spektroradiometrem nebo standardními destrukčními laboratorními měřeními). Práce přináší porovnání hyperspektrálních dat se spektrální odezvou a hodnotami chlorofylu a vlhkosti změřenými pomocí laboratorního měření a může sloužit jako cenná pilotní studie pro další výzkum.

Diplomová práce splňuje v zadání stanovené cíle a její výsledky v rámci možností odpovídají na stanovené výzkumné otázky.

8. Přehled literatury a použitých zdrojů

Buschmann, C., & Nagel, E. (1993). In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. International Journal of Remote Sensing, 14(4), 711–722. https://doi.org/10.1080/01431169308904370

Coops, N. C., & Stone, C. (2005). A comparison of field-based and modelled reflectance spectra from damaged Pinus radiata foliage. Australian Journal of Botany, 53(5), 417–429. https://doi.org/10.1071/BT04129

Coops, N., Dury, S., Smith, M. L., Martin, M., & Ollinger, S. (2002). Comparison of green leaf eucalypt spectra using spectral decomposition. Australian Journal of Botany, 50(5), 567–576. https://doi.org/10.1071/BT01082

Daughtry, C. S. T., Walthall, C. L., Kim, M. S., De Colstoun, E. B., & McMurtrey, J. E. (2000). Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. Remote Sensing of Environment, 74(2), 229–239. https://doi.org/10.1016/S0034-4257(00)00113-9

Demarez, V., & Gastellu-Etchegorry, J. P. (2000). A modeling approach for studying forest chlorophyll content. Remote Sensing of Environment, 71(2), 226–238. https://doi.org/10.1016/S0034-4257(99)00089-9

Gao, B.-C. (1996). NDWI – A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water From Space. In REMOTE SENS. ENVIRON (Vol. 7212). ©Elsevier Science Inc.

Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. In J. Plant Physiol (Vol. 160). http://www.urbanfischer.de/journals/jpp

Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. www.elsevier.com/locate/rse

Glenn, E. P., Huete, A. R., Nagler, P. L., & Nelson, S. G. (2008). Relationship Between Remotely-sensed Vegetation Indices, Canopy Attributes and Plant Physiological Processes: What Vegetation Indices Can and Cannot Tell Us About the Landscape. Sensors, 8, 2136–2160. www.mdpi.org/sensors

Goel, P. K., Prasher, S. O., Landry, J.-A., Patel, R. M., Viau, A. A., & Miller, J. R. (2003). ESTIMATION OF CROP BIOPHYSICAL PARAMETERS THROUGH AIRBORNE AND FIELD HYPERSPECTRAL REMOTE SENSING. Transactions of the ASAE, 46(4), 1235–1246.

Hansen, P. M., & Schjoerring, J. K. (2003). Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. Remote Sensing of Environment, 86(4), 542–553. https://doi.org/10.1016/S0034-4257(03)00131-7

Hashim, H., Abd Latif, Z., & Adnan, N. A. (2019). URBAN VEGETATION CLASSIFICATION with NDVI THRESHOLD VALUE METHOD with VERY HIGH RESOLUTION (VHR) PLEIADES IMAGERY. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 42(4/W16), 237–240. https://doi.org/10.5194/isprs-archives-XLII-4-W16-237-2019

Huete, A. R., Liu, H. Q., Batchily, ° K, & Van Leeuwen, W. (1997). A Comparison of Vegetation Indices over a Global Set of TM Images for EOS-MODIS. REMOTE SENS. ENVIRON, 5, 440–451.

Jackson, T. J., Chen, D., Cosh, M., Li, F., Anderson, M., Walthall, C., Doriaswamy, P., & Hunt, E. R. (2004). Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. Remote Sensing of Environment, 92(4), 475–482. https://doi.org/10.1016/j.rse.2003.10.021

Jenerowicz, A., & Woroszkiewicz, M. (2016). The pan-sharpening of satellite and UAV imagery for agricultural applications. Remote Sensing for Agriculture, Ecosystems, and Hydrology XVIII, 9998, 99981S. https://doi.org/10.1117/12.2241645

Kremezi, M., Kristollari, V., Karathanassi, V., Topouzelis, K., Kolokoussis, P., Taggio, N., Aiello, A., Ceriola, G., Barbone, E., & Corradi, P. (2021). Pansharpening PRISMA Data for Marine Plastic Litter Detection Using Plastic Indexes. IEEE Access, 9, 61955–61971. https://doi.org/10.1109/ACCESS.2021.3073903

Le Maire, G., François, C., & Dufrêne, E. (2004). Towards universal broad leaf chlorophyll indices using PROSPECT simulated database and hyperspectral reflectance measurements. Remote Sensing of Environment, 89(1), 1–28. https://doi.org/10.1016/j.rse.2003.09.004

Loncan, L., De Almeida, L. B., Bioucas-Dias, J. M., Briottet, X., Chanussot, J., Dobigeon, N., Fabre, S., Liao, W., Licciardi, G. A., Simoes, M., Tourneret, J. Y., Veganzones, M. A., Vivone, G., Wei, Q., & Yokoya, N. (2015). Hyperspectral Pansharpening: A Review. IEEE Geoscience and Remote Sensing Magazine, 3(3), 27–46. https://doi.org/10.1109/MGRS.2015.2440094

Lu, B., Dao, P. D., Liu, J., He, Y., & Shang, J. (2020). Recent advances of hyperspectral imaging technology and applications in agriculture. In Remote Sensing (Vol. 12, Issue 16). MDPI AG. https://doi.org/10.3390/RS12162659

McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. International Journal of Remote Sensing, 17(7), 1425–1432. https://doi.org/10.1080/01431169608948714

O'neill, A. L., Kupiec, J. A., & Curran, P. J. (2002). Biochemical and reflectance variation throughout a Sitka spruce canopy. www.elsevier.com/locate/rse

Peñuelas, J., Gamon, J. A., Griffin, K. L., & Field II, C. B. (1993). Assessing Community Type, Plant Biomass, Pigment Composition, and Photosynthetic Efficiency of Aquatic Vegetation from Spectral Reflectance* (Vol. 46).

Price, J. C. (1994). How Unique Are Spectral Signatures? (Vol. 49).

Ramluckan, K., Moodley, K. G., & Bux, F. (2014). An evaluation of the efficacy of using selected solvents for the extraction of lipids from algal biomass by the soxhlet extraction method. Fuel, 116, 103–108. https://doi.org/10.1016/j.fuel.2013.07.118

Rock, B. N., Vogelmann, J. E., Williams, D. L., Vogelmann, A. F., & Hoshizaki, T. (1986). Remote Detection of Forest Damage (Vol. 36, Issue 7).

Stefano, P., Angelo, P., Simone, P., Filomena, R., Federico, S., Tiziana, S., Umberto, A., Vincenzo, C., Acito, N., Marco, D., Stefania, M., Giovanni, C., Raffaele, C., Roberto, D. B., Giovanni, L., & Cristina, A. (2013). The PRISMA hyperspectral mission: Science activities and opportunities for agriculture and land monitoring. International Geoscience and Remote Sensing Symposium (IGARSS), 4558–4561. https://doi.org/10.1109/IGARSS.2013.6723850

Tucker, C. J., Elgin, J. H., Mcmurtrey, J. E., & Fan, C. J. (n.d.). Monitoring Corn and Soybean Crop Development with Hand-Held Radiometer Spectral Data.

Tumbo, S. D., Wagner, D. G., Heinemann, P. H., & Wagner, D. G. (2002). HYPERSPECTRAL-BASED NEURAL NETWORK FOR PREDICTING CHLOROPHYLL STATUS IN CORN. Transactions of the ASAE, 45(3), 825–832.

Ustin, S. L., Roberts, D. A., Gamon, J. A., Asner, G. P., & Green, R. O. (2004). Using Imaging Spectroscopy to Study Ecosystem Processes and Properties. In BioScience (Vol. 54, Issue 6). https://academic.oup.com/bioscience/article/54/6/523/294193

Verrelst, J., Malenovský, Z., Van der Tol, C., Camps-Valls, G., Gastellu-Etchegorry, J. P., Lewis, P., North, P., & Moreno, J. (2019). Quantifying Vegetation Biophysical Variables from Imaging Spectroscopy Data: A Review on Retrieval Methods. In Surveys in Geophysics (Vol. 40, Issue 3, pp. 589–629). Springer Science and Business Media B.V. https://doi.org/10.1007/s10712-018-9478-y

Wei, J., & Wang, X. (2020). An Overview on Linear Unmixing of Hyperspectral Data. In Mathematical Problems in Engineering (Vol. 2020). Hindawi Limited. https://doi.org/10.1155/2020/3735403

Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. Remote Sensing of Environment, 236. https://doi.org/10.1016/j.rse.2019.111402

Yao, H., & Tian, L. (2003). A genetic-algorithm-based selective principal component analysis (GA-SPCA) method for high-dimensional data feature extraction. IEEE Transactions on Geoscience and Remote Sensing, 41(6 PART I), 1469–1478. https://doi.org/10.1109/TGRS.2003.811691

Yue, J., Tian, J., Tian, Q., Xu, K., & Xu, N. (2019). Development of soil moisture indices from differences in water absorption between shortwave-infrared bands. ISPRS Journal of Photogrammetry and Remote Sensing, 154, 216–230. https://doi.org/10.1016/j.isprsjprs.2019.06.012

Zarco-Tejada, P. J., Miller, J. R., Noland, T. L., Mohammed, G. H., & Sampson, P. H. (2001). Scaling-Up and Model Inversion Methods with Narrowband Optical Indices for Chlorophyll Content Estimation in Closed Forest Canopies with Hyperspectral Data. In IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING (Vol. 39, Issue 7).

8.1 Internetové zdroje

ČZU © 2022 (online) [cit.2024.03.23], dostupné z < https://zivauni.cz/chytra-krajina-amalie-u-lan-je-cim-dal-chytrejsi-a-puvodem-i-urozena/>. https://zivauni.cz/chytra-krajina-amalie-u-lan-je-cim-dal-chytrejsi-a-puvodem-i-urozena/)

Kupní smlouva Ústavu výzkumu globální změny AV ČR © 2016 (online) [cit.2024.03.23], dostupné z <https://smlouvy.gov.cz/smlouva/soubor/690353/CJ_0870_itres_hyperspectral_system_administration.pdf >.

eoPortal © 2012 (online) [cit.2024.03.23], dostupné z <https://www.eoportal.org/satellite-missions/prisma-hyperspectral#mission-capabilities>.

ESA © 2023 (online) [cit.2024.03.23], dostupné z < https://dataspace.copernicus.eu/news/2023-9-28-accessing-sentinel-mission-data-new-copernicus-data-space-ecosystem-apis>.

8.2 Seznam obrázků a tabulek

Obrázek 1 Porovnání multispektrálních a hyperspektrálních dat

Edmund Optics © 2018 (online) [cit.2024.03.23], dostupné z <https://www.edmundoptics.com/knowledge-center/application-notes/imaging/hyperspectral-and-multispectral-imaging/>.

Obrázek 2 Typy mísení materiálu (autorka)

Obrázek 3 Fotografie z lokality v době sběru vzorků s patrným makroskopickým směšováním materiálů vyžadujícím spektrální unmixing získaného satelitního snímku (autorka)

Obrázek 4 Diagram Soxhletova aparátu

uživatel Quantockgoblin na Wikimedia Commons, public domain 2008 (online) [cit.2024.03.23], dostupné z <https://en.wikipedia.org/wiki/Soxhlet_extractor#/media/File:Soxhlet_extractor.svg>

Obrázek 5 Výřez multispektrálního UAV snímku se znázorněnými body měření

Obrázek 6 Satelit PRISMA

ASI © 2023 (online) [cit.2024.03.23], dostupné z <https://www.asi.it/en/earth-science/prisma/>.

Obrázek 7 Výřez obrazovky z Copernicus Browser – výběr lokality pro stažení snímků

Obrázek 8 Křídlo eBee X AgEagle © rok neznámý (online) [cit.2024.03.23], dostupné z <https://ageagle.com/drones/ebee-x/>

Obrázek 9 Ukázka z měření – otevřená kontaktní sonda spektrometru ASD FieldSpec 4 se vzorkem vojtěšky a viditelným zdrojem světla

Obrázek 10 Pohled do sušící trouby Memmert s již vysušenými vzorky vojtěšky

Obrázek 11 Sestava 8 Soxhletových aparátů pro potřeby DP (autorka)

Obrázek 12 a 13 Pravé barvy MS UAV snímku, jsou zde patrné vyježděné cesty na horním poli, podle kterých byla posouvána prahová hodnota NDVI na 0,321 a 2 b) vizualizace hodnot NDVI na snímku (červená barva představuje NDVI < 0,321, zelená NDVI ≥ 0,321), červené trojúhelníky představují lokality nasbíraných vzorků.

Obrázek 14 Mapa abundancí vojtěšky seté a holé půdy, čím tmavší zelená tím větší procentuální zastoupení vojtěšky vůči půdě

Obrázek 15 Ukázka agregované mapy abundancí pro senzor PRISMA

Obrázek 16 Spektrální odezvy smíšeného pixelu, holé půdy a samotné vegetace v pixelu 30 ze satelitu PRISMA

Obrázek 17 Spektrální odezvy smíšeného pixelu, holé půdy a samotné vegetace v pixelu 30 ze satelitu Sentinel-2

Obrázek 18 Spektrální křivky samotné vegetace ze satelitů PRISMA a Sentinel-2 s odstraněným kontinuem

Obrázek 19 Závislost hodnot indexu GNDVI ze spektroradiometru na hodnotách ze satelitu PRISMA

Obrázek 20 Závislost hodnot indexu hNDVI ze spektroradiometru na hodnotách ze satelitu PRISMA

Tabulka 7 Indexy s upravenými hodnotami pásem pro Sentinel-2

Tabulka 8 Indexy s originálními hodnotami pásem dle literatury

Tabulka 9 Výsledky kalibrace matematických modelů spektrálních indexů v porovnání se spektroradiometrickým měřením

Tabulka 10 Výsledky kalibrace matematických modelů spektrálních indexů v porovnání se spektroradiometrickým měřením

Tabulka 11 Výsledky kalibrace matematických modelů spektrálních indexů v porovnání se spektroradiometrickým a empirickým měřením

Tabulka 12 Výsledky kalibrace matematických modelů spektrálních indexů v porovnání s empirickým měřením