

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE  
FAKULTA ŽIVOTNÍHO PROSTŘEDÍ

KATEDRA PROSTOROVÝCH VĚD



Česká  
zemědělská  
univerzita  
v Praze

DIPLOMOVÁ PRÁCE

Detekce změn na zemědělské půdě: synergie dat Sentinel-1 a  
Sentinel-2

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

Diplomant: Kateřina Bernardová

2021

# ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

## ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Kateřina Bernardová

Zemědělská specializace  
Krajinné a pozemkové úpravy

Název práce

**Detekce změn na zemědělské půdě: synergie dat Sentinel-1 a Sentinel-2**

Název anglicky

**Change detection on agriculture land: synergy of Sentinel-1 and Sentinel-2**

---

### Cíle práce

Cílem diplomové práce je pomocí synergického využití dat z družic Sentinel-1 a Sentinel-2 vyhodnotit nastalé časoprostorové změny ve využívání zemědělské půdy na příkladové lokalitě v Libereckém kraji.

Dílní cíle diplomové práce souvisí s následujícími výzkumnými otázkami:

- Jsou data pořízená družicemi Sentinel-1 a Sentinel-2 vhodná pro podrobné mapování změn na zemědělské půdě?
- Zlepší se po přidání radarových dat k datům optickým přesnost klasifikace orné půdy a trvalého travního porostu (TTP)?
- Jak se liší normalizovaný diferenční vegetační index (NDVI) na plochách orné půdy a TTP ve sledovaném období let 2015 – 2020?
- Jeví se klasifikace dat Sentinel pomocí Random Forest klasifikátoru jako vhodná metoda pro mapování změn na zemědělské půdě?
- Jaký trend ve změnách na zemědělské půdě můžeme na základě dat využitých v této práci pozorovat?

### Metodika

Metodiku diplomové práce lze rámcově rozdělit na:

- Výběr vhodného zájmového území v zemědělské lokalitě v Libereckém kraji
- Pre-processing snímků Sentinel-1 a Sentinel-2 a jejich sloučení do synergicky využitelného datového zdroje
- Klasifikace dat Sentinel-1 a Sentinel-2 pomocí klasifikátoru Random Forest
- Vyhodnocení přesnosti klasifikace
- Tvorba NDVI na plochách orné půdy a TTP a vyhodnocení jeho změn v čase
- Vyhodnocení celkového trendu ve změnách na zemědělské půdě za využití dat LPIS, klasifikovaných dat Sentinel-1, Sentinel-2 a NDVI.

### **Doporučený rozsah práce**

40 – 60 stran

### **Klíčová slova**

land use; zemědělská půda; change detection; Sentinel

---

### **Doporučené zdroje informací**

- Barrett, B., Nitze, I., Green, S., Cawkwell, F., 2014. Assessment of multi-temporal, multi-sensor radar and ancillary spatial data for grasslands monitoring in Ireland using machine learning approaches. *Remote Sens. Environ.* 152, 109–124. <https://doi.org/10.1016/j.rse.2014.05.018>
- Belgiu, M., Csillik, O., 2018. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sens. Environ.* 204, 509–523. <https://doi.org/10.1016/j.rse.2017.10.005>
- Dusseux, P., Corpetti, T., Hubert-Moy, L., Corgne, S., 2014. Combined use of multi-temporal optical and Radar satellite images for grassland monitoring. *Remote Sens.* 6, 6163–6182. <https://doi.org/10.3390/rs6076163>
- Esch, T., Metz, A., Marconcini, M., Keil, M., 2014. Combined use of multi-seasonal high and medium resolution satellite imagery for parcel-related mapping of cropland and grassland. *Int. J. Appl. Earth Obs. Geoinf.* 28, 230–237. <https://doi.org/10.1016/j.jag.2013.12.007>
- Klouček, T., Moravec, D., Komárek, J., Lagner, O., Štych, P., 2018. Selecting appropriate variables for detecting grassland to cropland changes using high resolution satellite data. *PeerJ* 6, e5487. <https://doi.org/10.7717/peerj.5487>
- Šandera, J., Štych, P., 2020. Selecting relevant biological variables derived from sentinel-2 data for mapping changes from grassland to arable land using random forest classifier. *Land* 9, 1–20. <https://doi.org/10.3390/land9110420>
- Tarantino, C., Adamo, M., Lucas, R., Blonda, P., 2016. Detection of changes in semi-natural grasslands by cross correlation analysis with WorldView-2 images and new Landsat 8 data. *Remote Sens. Environ.* 175, 65–72. <https://doi.org/10.1016/j.rse.2015.12.031>
- 

### **Předběžný termín obhajoby**

2020/21 LS – FŽP

### **Vedoucí práce**

Ing. Tomáš Klouček, Ph.D.

### **Garantující pracoviště**

Katedra prostorových věd

Elektronicky schváleno dne 20. 3. 2021

**doc. Ing. Petra Šímová, Ph.D.**

Vedoucí katedry

Elektronicky schváleno dne 21. 3. 2021

**prof. RNDr. Vladimír Bejček, CSc.**

Děkan

V Praze dne 21. 03. 2021

### **Prohlášení**

Prohlašuji, že jsem diplomovou práci na téma: Detekce změn na zemědělské půdě: synergie dat Sentinel-1 a Sentinel-2 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 verzí tištěnou a že s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR.

V Praze 28. března 2021

.....

Kateřina Bernardová

### **Poděkování**

Děkuji vedoucímu diplomové práce Ing. Tomášovi Kloučkovi, Ph.D. za cenné rady, připomínky a trpělivost při vedení práce, dále za poskytnutí cenných informací pro zpracování práce a za čas věnovaný konzultacím. Také bych chtěla poděkovat své rodině a příteli za velkou podporu.

V Praze 28. března 2021

.....

## ABSTRAKT

Tato diplomová práce je zaměřena na posouzení přínosnosti synergického využití dat z družic Sentinel-1 a Sentinel-2 k detekci změn na zemědělské půdě, konkrétně změn nastalých na orné půdě a trvalém travním porostu. Literární rešerše stručně popisuje základní principy dálkového průzkumu Země, charakterizuje spektrální vlastnosti vybraných povrchů a představuje družice Sentinel-1 a Sentinel-2 a jejich data, která jsou v této práci využita. Analýza byla provedena na zájmovém území v zemědělské oblasti Libereckého kraje za období let 2015 až 2020. Součástí metodiky byl pre-processing optických i radarových dat, jejich klasifikace pomocí klasifikátoru Random Forest, vyhodnocení přesnosti klasifikace, srovnání s referenčními daty LPIS (*Land Parcel Identification System*) a tvorba normalizovaného diferenčního vegetačního indexu NDVI (*Normalized Difference Vegetation Index*) na plochách orné půdy a trvalého travního porostu. Výzkum vyhodnotil klasifikátor Random Forest jako velmi vhodný pro mapování změn na zemědělské půdě, přesnost určení orné půdy dosahovala až 90 % za použití synergie dat. Trendy ve změnách na zemědělské půdě zjištěné v této práci odpovídají trendům detekovaným statistickými údaji a ostatními studii zabývajícími se touto problematikou. Výsledky analýzy slouží k objasnění trendu ve změnách na zemědělské půdě v České republice a k porovnání vhodnosti synergického využití radarových dat Sentinel-1 a optických dat Sentinel-2 pro detekci těchto změn.

**Klíčová slova:** land use, zemědělská půda, change detection, Sentinel

## ABSTRACT

This diploma thesis is focused on the description of possible utilization of Sentinel-1 and Sentinel-2 remote sensed data for agriculture change detection in the Czech Republic, specifically changes in cropland and grassland. The literature review briefly defines the concept of remote sensing, describes the spectral characteristics of selected types of land cover and presents Sentinel-1 and Sentinel-2 satellites and their data. Analysis was conducted on an agricultural area of interest in the Liberecký region covering the years 2015–2020. Methodology consists of optical and radar data pre-processing, classification of data using the Random Forest classification method, classification accuracy assessment, comparison with LPIS (*Land Parcel Identification System*) reference data and time analysis of cropland and grassland NDVI (*Normalized Difference Vegetation Index*) values. This research had evaluated the Random Forest classifier as very suitable for mapping changes on agricultural land, the accuracy of cropland determination reached up to 90 % using the synergetic data approach. The trends in changes on agricultural land were found to be corresponding to those detected by statistical data and other similar studies. Results of the analysis are used to clarify the land use change trend on agricultural land in the Czech Republic and to assess the possible utilization of synergic use of Sentinel data for detection of these changes.

**Keywords: land use, agriculture land, change detection, Sentinel**

# Obsah

1.	Úvod.....	10
2.	Cíle práce .....	11
3.	Literární rešerše.....	12
3.1	Dálkový průzkum Země.....	12
3.2	Druhy DPZ .....	14
3.2.1	Aktivní metody .....	14
3.2.2	Pasivní metody .....	15
3.3	Spektrální chování objektů.....	16
3.3.1	Půda .....	17
3.3.2	Voda.....	17
3.3.3	Vegetace .....	18
3.4	Multispektrální DPZ.....	18
3.4.1	Sentinel-2.....	18
3.5	Radarový DPZ .....	19
3.5.1	Sentinel-1 .....	20
3.6	Předzpracování dat DPZ.....	21
3.6.1	Geometrické korekce .....	21
3.6.2	Radiometrické korekce .....	21
3.6.3	Atmosférické korekce.....	21
3.7	Metody klasifikace dat .....	23
3.7.1	Neřízená klasifikace .....	23
3.7.2	Řízená klasifikace.....	24
3.7.3	Objektová klasifikace .....	25
3.8	Změny ve využívání zemědělské půdy .....	26
3.8.1	Historie změn ve využívání zemědělské půdy ČR.....	26
3.8.2	Výzkum synergického využití radarových a optických dat.....	27



4.	Metodika .....	28
4.1	Zájmové území .....	28
4.2	Data .....	29
4.3	Předzpracování dat .....	31
4.4	Klasifikace .....	32
4.5	Změny na zemědělské půdě.....	33
4.6	NDVI .....	34
5.	Výsledky .....	35
5.1	Vyhodnocení přesnosti klasifikace.....	35
5.2	Analýza změn NDVI .....	41
5.3	Analýza trendu změn na zemědělské půdě.....	44
6.	Diskuze.....	46
7.	Závěr .....	48
8.	Přehled literatury a použitých zdrojů .....	50
	Seznam tabulek .....	57
	Seznam příloh.....	58
	Seznam obrázků .....	58
	Přílohy .....	59

## 1. Úvod

Zájem mezinárodní výzkumné komunity o sledování změn využití půdy vzrostl za posledních pár desítek let v návaznosti na zjištění, že procesy na povrchu země mohou mít také výrazný vliv na klima. Dopadů změn ve využívání půdy je mnoho, jedná se zejména o dopady na biologickou rozmanitost, degradaci půdy a schopnost biologických systémů uspokojit lidskou potřebu (Lambin a Geist, 2006). Ze všech typů krajinného pokryvu v Evropské unii tvoří orná půda a trvalý travní porost (TTP) nejzastoupenější složku se 44 % celkové plochy (Klouček et al., 2018).

Trvalý travní porost hraje nezastupitelnou roli jako přirozené prostředí mnoha organismů, napomáhá s akumulací skleníkových plynů, zabraňuje erozi, zadržuje vodu v krajině a snižuje znečištění (Klouček et al., 2018). Tyto výhody však mohou být snadno narušeny orbou travních porostů, čímž se tyto plochy mění na ornou půdu (Pazúr et al., 2014). Přeměna TTP na ornou půdu vede ke zvýšení vyluhování dusičnanů a ke snížení zásob uhlíku v půdě. Vzhledem k nárůstu orné půdy na úkor TTP, který je v mnoha oblastech světa v posledním půlstoletí pozorován, je identifikace TTP klíčovým prvkem udržitelného zemědělství (Dusseux et al., 2014). Výskyt orné půdy na úkor TTP je zvláště patrný v postkomunistických státech, které nedávno vstoupily do EU a začaly dostávat zemědělské dotace (Pazúr et al., 2014).

Celkem nedávny pokrok v oblasti dálkového průzkumu Země a digitálního zpracování obrazu nabízí nové příležitosti k přesnější a časově méně náročné detekci změn krajinného pokryvu za stále většího pokrytí ploch (Chen et al., 2011). Vhodným zdrojem obrazových dat jsou produkty Sentinel. Primárním cílem mise Sentinel programu Copernicus je poskytovat data využitelná při vytváření a provádění evropských politik v oblasti bezpečnosti a životního prostředí např. pro ověření správnosti dotací pro zatravňování půdy. Snímky radarové družice Sentinel-1 a multispektrální družice Sentinel-2 jsou volně dostupné veřejnosti a jejich synergické využití pro různé analýzy, mezi které patří i klasifikace změn na zemědělské půdě, je pro jejich slibné výsledky dnes mnoha vědci aktivně doporučováno.

## 2. Cíle práce

Náplní této práce je za pomoci synergického využití dat z družic Sentinel-1 a Sentinel-2 vyhodnotit nastalé časoprostorové změny ve využívání zemědělské půdy na příkladové lokalitě v Libereckém kraji, posoudit vhodnost dat Sentinel-1 a Sentinel-2 pro mapování změn na zemědělské půdě a zhodnotit využitelnost klasifikační metody Random Forest, viz výzkumné otázky a), d) a e).

Ve své první části je práce zaměřena především na popis základního principu dálkového průzkumu Země a elektromagnetického záření, charakteristiku spektrálních vlastností vybraných povrchů a na představení dvou družic Sentinel a jejich dat. Stručně je také zmíněna obecná problematika změn na zemědělské půdě a podrobněji je rozepsána historie a výzkum těchto změn na území České republiky.

Praktická část práce je věnována předzpracování a klasifikaci družicových dat za období let 2015-2020, vyhodnocení nastalých změn na orné půdě a trvalém travním porostu a jejich porovnání s referenčními daty LPIS. Posouzen je také vliv přidání radarového pásma k optickým datům na účinnost této klasifikace, viz výzkumná otázka b). Dále je provedena analýza hodnot NDVI v průběhu sledovaného období a výsledky jsou stručně shrnuty do samostatné kapitoly, viz výzkumná otázka c).

Zemědělská půda je elementárním prvkem naší společnosti a je proto nutno trendy v jejích změnách pečlivě sledovat a analyzovat. Výsledky této práce by mohly být vhodným podkladem pro budoucí rozhodování při volbě vhodných metod pro monitoring změn na zemědělské půdě.

### 3. Literární rešerše


#### 3.1 Dálkový průzkum Země

Dálkový průzkum Země (DPZ) je metoda získávání informací o cílových objektech bezkontaktním způsobem. Tato metoda využívá celé elektromagnetické spektrum od krátkých vlnových délek (např. UV) až po dlouhé (mikrovlnné) (Baghdadi a Zribi, 2016). Jedná se o tzv. geoinformační technologii, jež sbírá data o zemském povrchu, která jsou poté zpracována a využívána v celé řadě vědních odvětví, jakými jsou zemědělství, astronomie, geodézie, hydrologie nebo archeologie (Halounová a Pavelka, 2005).

Za posledních 30 let se dálkové snímání posunulo od pouhé fotointerpretace několika obrazů ke kombinování této fotointerpretace s počítačovou analýzou velkého množství obrazů a dat. DPZ tak přešel z využití výhradně leteckých snímků a pozemních senzorů k využití satelitních dat, dronů a celého spektra vlnových délek od viditelných po mikrovlnné (Baghdadi a Zribi, 2016).

Systematické dálkové snímání začalo v období mezi první a druhou světovou válkou leteckým snímáním používaným pro vojenský průzkum a fotogrammetrii. Důraz na shromažďování zpravodajských informací k monitorování americko-sovětských vojsk za období studené války stimuloval rychlý technologický pokrok satelitního dálkového průzkumu Země pro vojenské účely.

Ve stejném období byl pak učiněn pokrok i ve vývoji DPZ pro civilní potřeby. První meteorologický satelit TIROS 1 byl vypuštěn v roce 1960 a v roce 1972 byl vypuštěn satelit Landsat, který poskytoval kontinuální zdroj satelitních snímků, jež bylo možné využít pro různé civilní aplikace, jako např. průzkum ložisek nerostů a ropy, monitorování plodin a správu přírodních zdrojů (National Research Council, 2001).



Obr. 1 Princip DPZ (<http://maps.unomaha.edu> (upraveno))


## Elektromagnetické záření

Elektromagnetické záření (EMZ) vzniká při zrychleném nebo zpomaleném pohybu nabitých částic, přičemž tok záření je přímo úměrný druhé mocnině zrychlení. Toto záření představuje spojité spektrum s rozsahem zhruba dvaceti řádů, rozdělené do několika druhů EMZ podle frekvence nebo vlnové délky viz Obr. 2. V DPZ jsou pak využívány zejména vlnové délky viditelného, UV, mikrovlnného a infračerveného záření (Kolář, 1990).

Sluneční záření dopadající na zemský povrch je buďto odraženo, přenášeno do povrchu nebo pohlceno a emitováno zpět viz Obr. 1. EMZ při interakci prochází řadou změn ve své síle, směru, vlnové délce, polarizaci a fázi. Tyto změny jsou pak detekovány senzory a umožňují pozorovateli získat užitečné informace o objektu zájmu. Takto dálkově nasnímaná data obsahují jak prostorovou informaci (velikost, tvar, orientaci) tak i spektrální informaci (odstín, barvu, spektrální signatury) (Aggarwal, 2004).

Veškerá hmota s určitou teplotou vyzařuje elektromagnetické záření různých vlnových délek. Celkový rozsah vlnových délek se běžně označuje jako elektromagnetické spektrum. To sahá od paprsků gama až k rádiovým vlnám. Dálkové

snímání operuje v několika oblastech elektromagnetického spektra. Optická část elektromagnetického spektra označuje tu část spektra, ve které lze aplikovat optické zákony. To se týká jevů jako je např. odrazivost nebo lom světla. Rozsah optického spektra sahá od rentgenového záření (0,02  $\mu\text{m}$ ), přes viditelnou část spektra až po daleké infračervené záření (1000  $\mu\text{m}$ ). Ultrafialové (UV) záření má nejkratší rozsah vlnových délek využitelných pro účely DPZ. Mikrovlnné záření obsahuje vlnové délky od 1 mm do 1 m (Janssen a Bakker, 2001).



Obr. 2 Spektrum elektromagnetického záření (<https://labguide.cz>)

## 3.2 Druhy DPZ

Podle zdroje elektromagnetického záření rozlišujeme dvě metody měření energie – aktivní a pasivní (Halounová a Pavelka, 2005).

### 3.2.1 Aktivní metody

Aktivní metody poskytují svůj vlastní zdroj energie k zjištění informací o objektech. Tyto senzory využívají elektromagnetického spektra v rozsahu vlnových délek viditelného světla, blízkého infračerveného záření a radarového záření (Zhu et al., 2018).

- **Radary** (*Radio Detection and Ranging*) jsou aktivní mikrovlnné senzory, vybavené vlastním zdrojem mikrovlnného záření. Jejich principem je určování objektů a jejich umístění pomocí radiových vln (Lillesand, Kiefer a Chipman, 2015).

Předností radarů je nezávislost na vnějších okolnostech, např. povětrnostních, z tohoto důvodu nachází uplatnění zejména v podmínkách s hustou vrstvou vegetace nebo vysokou oblačností (Thiel et al., 2006).

- **Lidary** (*Light Detection and Ranging*) měří vzdálenost mezi senzorem a cílovým povrchem, zjišťováním času uplynulého mezi vysláním krátkodobého laserového pulzu a příjmem zpětného signálu na senzoru. Tyto typy senzorů jsou vhodné např. pro mapování krajinného pokryvu a nadzemní biomasy (Lefsky et al., 2002).

### 3.2.2 Pasivní metody

Pasivní systémy využívají záření, které je emitováno zemským povrchem nebo které je emitováno Sluncem a od zemského povrchu se následně odráží (Campbell a Wynne, 2011).

- **Radiometry** využívají k detekci elektromagnetického záření dlouhé vlnové délky, které jsou emitovány povrchem půdy. Tato data pak mohou být využita pro odhad půdní vlhkosti nebo mapování půdy (Janssen a Bakker, 2001).
- **Multispektrální skenery** jsou citlivé na konkrétní oblasti elektromagnetického spektra a měří spektrální odrazivost v úzkém rozsahu vlnových délek. Typická pásma jsou např. modrá (0,45 – 0,50  $\mu\text{m}$ ), zelená (0,50 – 0,60  $\mu\text{m}$ ), červená (0,60 – 0,70  $\mu\text{m}$ ), panchromatická (0,50 – 0,75  $\mu\text{m}$ ) a termální infračervená (10,00 – 12,50  $\mu\text{m}$ ) (Jain a Singh, 2003).
- **Termální skenery** snímají energii emitovanou z povrchu objektu v rozmezí vlnových délek 7–14  $\mu\text{m}$ . Vyzařovaná energie je určena teplotou a emisivitou materiálu (Ninomiya a Fu, 2019). Teplý objekt vyzařuje více tepelné energie než chladnější objekt, a proto je takovýto objekt na snímcích lépe viditelný. Nezávislost těchto snímků na denní době a světelnosti je zejména užitečná při sledování živých tvorů, detekci sopek nebo lesních požárů (Zhu et al., 2018).

### 3.3 Spektrální chování objektů

Pro jakýkoli daný materiál se množství slunečního záření, které se odráží (absorbuje, prochází), bude měnit s vlnovou délkou. Tato důležitá vlastnost hmoty nám umožňuje rozlišit různé povrchy na základě hodnot jejich odezvy pro danou vlnovou délku (Zeeshan, Deshmukh a Shafiuddin, 2017).

#### Spektrální odrazivost

Spektrální odrazivost je poměr intenzity dopadajícího záření a intenzity odraženého záření měřeného z objektu nebo plochy na specifických vlnových délkách. Spektrální charakteristika je vlastností každého objektu na zemi a je nezávislá na čase, poloze, intenzitě osvětlení i atmosférických podmínkách (Peddle et al., 2001).

Je dána vztahem:

$$\rho(\lambda) = [ER(\lambda)/EI(\lambda)] * 100$$

Kde,

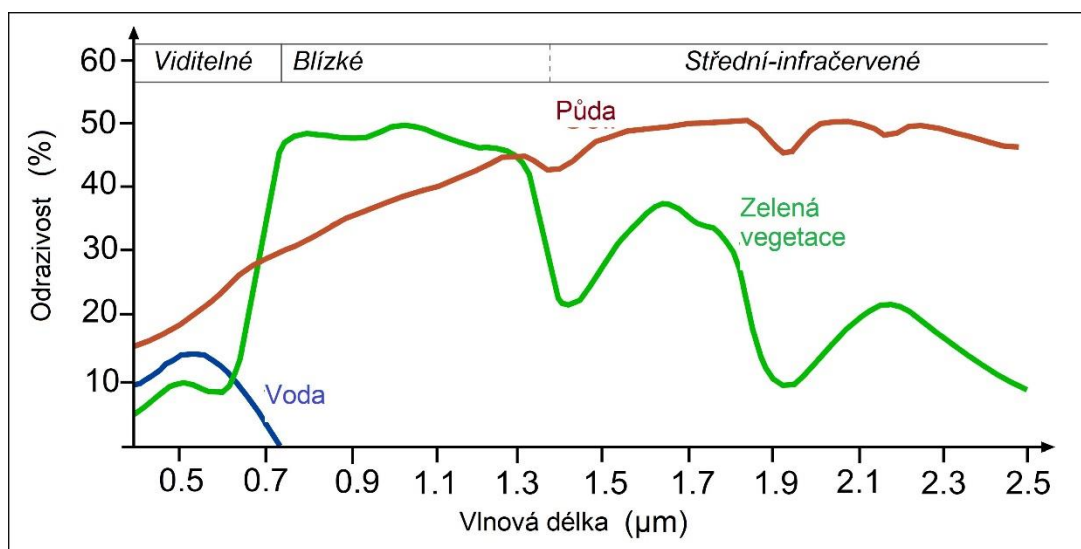
$\rho(\lambda)$  = spektrální odrazivost při konkrétní vlnové délce.

$ER(\lambda)$  = energie vlnové délky odražené od povrchu objektu.

$EI(\lambda)$  = energie vlnové délky dopadající na povrch objektu.

Graf mezi  $\rho(\lambda)$  a  $\lambda$  se nazývá křivka spektrální odrazivosti viz Obr. 3. Ta se mění v závislosti na změnách v chemickém složení a fyzikálních podmínkách sledovaného prvku. Spektrální příznak je pak termín používaný pro unikátní vzor spektrální odezvy, který je pro daný prvek v terénu charakteristický (Aggarwal, 2004).





Obr. 3 Spektrální křivky vody, půdy a zelené vegetace (<https://seos-project.eu>)

### 3.3.1 Půda

Půda je směsí anorganických a organických látek, jenž se liší svými fyzikálními, biologickými nebo chemickými vlastnostmi. Souhrou těchto vlastností vytváří svůj spektrální projev. S rostoucí vlnovou délkou se odrazivost půdy zvyšuje (Kolář, 1990).

Většina záření dopadajícího na povrch půdy se buďto odráží, nebo absorbuje, přičemž malá část se přenáší. Vlastnosti půdy, které určují její odrazivost jsou její vlhkost, obsah organické hmoty, struktura a obsah oxidu železa. Přítomnost vlhkosti v půdě snižuje její odrazivost (Aggarwal, 2004).

### 3.3.2 Voda

Většina záření dopadajícího na vodní plochy se neodráží, ale je buďto absorbována nebo přenášena. Voda tak vypadá modře nebo modrozeleně, díky silnější odrazivosti při kratších vlnových délkách, nebo tmavě při červených nebo blízkých infračervených vlnových délkách. Faktorem, který ovlivňuje variabilitu v odrazivosti vodních útvarů je například jejich hloubka (Aggarwal, 2004).

### 3.3.3 Vegetace

Spektrální charakteristiky vegetace se mění s vlnovou délkou. Chlorofyl v listech silně absorbuje záření v červených a modrých vlnových délkách, v zelených vlnových délkách však záření odráží. Vnitřní struktura zdravých listů působí jako difúzní odražeč blízkých infračervených vlnových délek. Měření a monitorování odrazivosti v blízké infračervené oblasti je jedním z možných způsobů, jak učit míru zdraví konkrétní vegetace (Aggarwal, 2004). Absorpce světla listovými pigmenty dominuje ve viditelné oblasti spektra odrazivosti (400–700 nm). Chlorofylové pigmenty a absorbují vlnové délky v modrém spektru (400–500 nm), pigmenty b zase absorbují vlnové délky ve spektru červeném (600–700 nm). Na vlnových délkách v zeleném spektru (500–600 nm) dochází k menší absorpci, a proto se zdravá vegetace jeví zeleně (Huete, 2004).

## 3.4 Multispektrální DPZ

Multispektrální dálkový průzkum Země je definován jako shromažďování odražené, emitované nebo zpětně rozptýlené energie z objektu nebo oblasti zájmu ve více pásmech elektromagnetického spektra na rozdíl od panchromatických dat, které se nachází v jednom pásmu. Multispektrální systémy dálkového průzkumu Země používají paralelní pole senzorů, které detekují záření v malém počtu širokých pásem vlnových délek. (Zeeshan, Deshmukh a Shafiuddin, 2017).

### 3.4.1 Sentinel-2

Vývoj programu Copernicus Evropskou kosmickou agenturou (ESA) a Evropskou unií (EU) významně přispěl k efektivnímu monitorování zemského povrchu zejména svými multispektrálními produkty Sentinel-2.

Konstelace Sentinel-2 je již druhým počinem mise Sentinel. Je tvořena dvěma identickými družicemi Sentinel-2A a Sentinel-2B. První snímky této mise byly obdrženy několik dní po vypuštění družice Sentinel-2A dne 23. června 2015. Družice Sentinel-2B pak byla vypuštěna 7. března 2017. Obě družice na své palubě nesou multispektrální senzory MSI (*Multispectral Imaging Instruments*), které jsou schopny

zaznamenávat 13 spektrálních pásem. Primárním cílem mise Sentinel-2 je poskytovat satelitní data vysokého rozlišení pro monitorování změn krajinného pokryvu, změn klimatu, monitorování katastrof, ale také doplňování dalších satelitních misí jako je např. Landsat a SPOT (*Satellite Pour l'Observation de la Terre*) zajištěním kontinuity monitorování dynamiky na povrchu Země (Phiri et al., 2020).

Data Sentinel-2 jsou běžnému uživateli dostupná na třech úrovních, 1B, 1C a 2A. V případě produktů Level-1B a Level-1C se jedná o radiometricky korigovaná ToA (*top of the atmosphere*) data. Produkt Level-2A je možno vytvořit na straně uživatele za pomoci produktu Level-1C s využitím příslušného toolboxu. Takový produkt je pak atmosféricky korigovaný a obsahuje hodnoty povrchové odrazivosti BoA (*bottom of the atmosphere*) (TAS, 2021).

### **3.5 Radarový DPZ**

Radar má speciální vlastnosti, které z něj činí vhodnou alternativu nebo doplnění k tradičním optickým metodám DPZ. Mikrovlnná energie je schopna proniknout atmosférickými podmínkami, kvůli kterým je využití tradičních optických a multispektrálních systémů nevhodné nebo dokonce nepoužitelné. Radary jsou tak schopné snímat povrchy i skrz déšť, mlhu, krupobití, kouř a vysokou oblačnost (Herold a Haack, 2006).

Využití mikrovlnné technologie pro mapování krajiny nebylo v minulosti tak rozšířené jako mapování pomocí optického DPZ, avšak v posledních dvou desetiletích se tento trend začal měnit. Zejména data z řady minulých i současných SAR (*Synthetic Aperture Radar*) systémů, jako např. ERS (*European Remote-Sensing Satellite*), ASAR (*Advanced Synthetic Aperture Radar*), JERS-1 (*Japanese Earth Resources Satellite*), RADARSAT nebo ALOS-1 (*Advanced Land Observation Satellite*), jsou již běžně využívána v regionálním měřítku (Joshi et al., 2016).

### 3.5.1 Sentinel-1

V rámci programu Copernicus, dříve také známém jako GMES (*Global Monitoring for Environment and Security*), byla realizována mise Sentinel-1 prostřednictvím konstelace dvou satelitů Sentinel-1A a Sentinel-1B, z nichž každý nese jednofrekvenční radarový senzor C-SAR snímající povrch v pásmu C (5404 MHz). Mise Sentinel-1, jejíž součástí jsou satelity Sentinel-1A a Sentinel-1B, je speciálně navržena za účelem sběru systematických a kontinuálních dat a informací pro monitorování povrchu Země, oceánů a přírodních katastrof (Torres et al., 2012).

Radar se syntetickou aperturou SAR (*Synthetic Aperture Radar*) na palubě družice Sentinel-1 získává data ve čtyřech exkluzivních módech snímání:

- **Stripmap (SM)** – V tomto režimu poskytuje přístroj pokrytí s vysokým geometrickým rozlišením ( $5 \text{ m} \times 5 \text{ m}$ ) při šířce záběru 80 km. Úhel dopadu se pohybuje v rozmezí  $18,3^\circ$  až  $46,8^\circ$ . Režim Stripmap je využíván jen zřídka jako podpora při nouzových situacích.
- **Extra-Wide Swath (EW)** – EW režim využívá techniky TOPSTAR a pokrývá velmi široký záběr 400 km při středním rozlišení ( $20 \text{ m} \times 40 \text{ m}$ ). Polarizace je buď jednoduchá (VV či HH) nebo duální (VV + VH nebo HH + HV). Tento mód se využívá zejména pro snímání polárních oblastí a mořského ledu.
- **Interferometric Wide Swath (IW)** – Tento mód funguje na principu skládání tzv. subzáběrů pomocí techniky TOPSAR, při které je paprsek naklápěn v azimutálním směru, což zajišťuje stejnou kvalitu obrazu na celé scéně. Jedná se o výchozí mód.
- **Wave (WV)** – Datový produkt Wave má prostorové rozlišení  $5 \text{ m} \times 5 \text{ m}$  a rozměry  $20 \text{ km} \times 20 \text{ km}$ . Slouží k určování směru a výšky vln na otevřeném oceánu (Torres et al., 2012).

## **3.6 Předzpracování dat DPZ**

Surová data získaná senzorem dálkového snímání obsahují vnitřní, vnější, systematické a nesystematické chyby, které jsou spjaté s procesem získávání dat, vlivem atmosféry a zemských procesů. Taková data jsou pro většinu aplikací nevhodná, a proto je zapotřebí různých postupů pro vylepšení nebo opravu těchto dat do vhodné formy. Toho je dosaženo za pomoci geometrických, radiometrických a atmosférických korekcí (Wulder a Franklin, 2003).

### **3.6.1 Geometrické korekce**

Satelitní snímky obsahují řadu geometrických zkreslení, která jsou nevyhnutelnými aspekty postupu záznamu dat a tvaru a rotace Země. Neupravené snímky tak budou obsahovat jinou geometrii než mapy a nebudou s nimi kompatibilní. Geometrická korekce je proces opravy těchto zkreslení a přiřazení obrazu požadovaného souřadného systému či kartografického zobrazení (Green, Clark a Edwards, 2000).

### **3.6.2 Radiometrické korekce**

Radiometrické korekce upravují DN (*Digital Numbers*) hodnoty obrazu tak, aby odpovídaly skutečným odrazovým či zářivým vlastnostem objektů. Sezónní odlišnosti v hodnotách jsou zpravidla způsobeny rozdílnými podmínkami pro rozptyl a pohlcení elektromagnetického záření a výškou Slunce. Radiometrické korekce také mohou upravovat šum, chybějící řádky nebo nežádoucí pruhy (Janzen, Fredeen a Wheate, 2014).

### **3.6.3 Atmosférické korekce**

Sluneční záření odražené od zemského povrchu k družicovým sensorům je modifikováno jeho interakcí s atmosférou. Cílem atmosférických korekcí je určit skutečné hodnoty odrazivosti povrchu a získat fyzické parametry zemského povrchu odstraněním vlivů atmosféry ze satelitních snímků. Atmosférická korekce je pravděpodobně nejdůležitější částí předzpracování dat dálkového snímání (Hadjimitsis et al., 2010).

Vybráni byly čtyři běžní reprezentanti atmosférických korekcí:

- Nástroj **FLAASH** (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*) je prvním nástrojem atmosférických korekcí opravující vlnové délky ve viditelné části spektra pomocí blízkého a středního infračerveného záření. Pro převod záření využívá kód MODTRAN4. Tento model je vysoce variabilní a umožňuje definovat všechny parametry ovlivňující rozptyl a absorpci v atmosféře jako jsou např. stav atmosféry, poloha slunce a množství aerosolů.
- **QUAC** (*QUick Atmospheric Correction*) je metoda atmosférické korekce pro multispektrální a hyperspektrální snímky, která určuje parametry korekce přímo z informací obsažených v jednotlivých pixelech. Přesné hodnoty odrazu je díky ní možné získat i ze senzorů bez radiometrických kalibrací nebo při neznámé intenzitě slunečního záření. Výpočetní rychlost této metody je mnohem kratší než u FLAASH, a proto je velice vhodná pro aplikace v reálném čase (ENVI, 2009).
- Metoda **DOS** (*Dark Object Subtract*) je korekční metoda využívaná zejména pro detekci změn ve využívání půdy. Prvky jako voda, lesy a stíny jsou považovány za tmavé objekty, pokud se jejich hodnoty odrazivosti blíží nule. Je-li na obraze nalezen tmavý objekt, je tomuto objektu přiřazena minimální hodnota odrazivosti v histogramu. Z tohoto minima je pak možné korigovat celou scénu pomocí účinků atmosférické disperze (Prieto-Amparan et al., 2018).
- **Sen2Cor** je Level-2A je plugin určený pro korekci vlivů atmosféry produktů úrovně 1C na produkt úrovně 2A s hodnotami odrazivosti na úrovni povrchu. Mezi další výstupy patří např. mapa vodního výparu nebo klasifikace scény s indikátory pro pravděpodobnost výskytu oblačnosti či sněhové pokrývky. Výstupy programu jsou k dispozici pro prostorová rozlišení 60 m, 20 m a 10 m. Dnes mohou uživatelé produkty úrovně 2A generovat pomocí tohoto pluginu např. prostřednictvím Sentinel-2 Toolboxu v prostředí programu SNAP (*Sentinel Application Platform*) (Main-Knorn et al., 2017).

### 3.7 Metody klasifikace dat

Jedním z nejdůležitějších způsobů využití dat dálkového průzkumu Země je tvorba map využití půdy (*land use*) a půdního krytu (*land cover*), kterých lze dosáhnout pomocí procesu zvaného klasifikace obrazu (Al-Doski, Mansor a Shafri, 2013).

Proces klasifikace pracuje na základě myšlenky, že různé typy zemského povrchu mají různé vlastnosti spektrální odrazivosti. Obecně se dá klasifikace definovat jako proces kategorizace všech pixelů v obraze nebo satelitních datech, za účelem získání požadovaných tříd krajinného pokryvu.

Obecný postup klasifikace dat je následovný:

- tvorba klasifikačního schématu: sběr informací a dat o zájmovém území, volba požadovaných tříd land cover/land use,
- předzpracování snímků, včetně radiometrických, atmosférických, geometrických a topografických korekcí, zvýraznění obrazu,
- výběr reprezentativních vzorků tříd (tzv. tréninková data),
- provedení samotného klasifikačního algoritmu,
- post-processing (filtrace obrazu)
- vyhodnocení přesnosti (porovnání klasifikovaných dat s referenčními daty).

Existuje hned několik klasifikačních přístupů, které jsou široce využívány k vytváření map krajinného pokryvu. Mezi ně patří např. řízené a neřízené metody, které lze provést pomocí rozličných parametrických a neparametrických klasifikátorů (Al-Doski, Mansor a Shafri, 2013).

#### 3.7.1 Neřízená klasifikace

Neřízená klasifikace je metoda, při které software k tomu určený rozděljuje velké množství neznámých pixelů do různých tříd nebo shluků na základě jejich hodnot odrazivosti bez zákroku uživatele. Nejčastěji používanými metodami jsou K-

means a ISODATA (*Iterative Self-Organizing Data Analysis Technique*) (Al-Doski, Mansor a Shafri, 2013).

Algoritmus K-means je jedním z nejjednodušších a nejnámějších shlukových algoritmů. Jeho principem je určování shlukových středů, přičemž objekty se zařazují do takového shluku, jehož středů jsou nejbližší. Algoritmus začíná náhodným umístěním shluků ve spektrálním prostoru, každý pixel ze vstupního obrazu je poté přiřazen k nejbližšímu středů shluku. Shluková centra jsou následně přepočítána a přemístěna do těžiště hodnot shluků. Takto se iterace opakuje, dokud se poloha středů neustálí (Piloyan a Konečný, 2017).

Algoritmus ISODATA nemá stálý počet shluků, takže jejich požadovaný počet musí být zadán jejich minimálním a maximálním počtem. V tomto intervalu pak počet shluků kolísá v jednotlivých iteracích. Shluky mohou být spojovány, jestliže vzdálenost jejich středů je menší než předem zadaná hodnota, nebo mohou být rozdělovány, pakliže se stanou příliš heterogenními. Po každé iteraci je provedeno přepočtení statistik a opakování celého procesu. Klasifikace je ukončena, jakmile je dosaženo maximálního zadaného počtu iterací (Abbas et al., 2016).

### 3.7.2 Řízená klasifikace

Při řízené klasifikaci se nejprve určí požadované kategorie a poté je zkoumána jejich spektrální odlišitelnost. Vychází se z reprezentativních vzorků, tzv. tréninkových dat, které lze v obrazovém záznamu identifikovat a slouží k popisu jednotlivých tříd. Odlišnost tréninkových ploch umožňuje rozlišení tříd na základě jejich spektrálních charakteristik (Lillesand, Kiefer a Chipman, 2015).

Existuje celá řada parametrických a neparimetrických algoritmů, pro představu jsou níže uvedeni dva zástupci těchto kategorií:

- **Minimum Distance** je jednou z nejjednodušších a výpočetně nejlevnějších parametrických metod s relativně velmi efektivním algoritmem pro řízenou klasifikaci multispektrálních obrazů. Je založena na měření euklidovské vzdálenosti mezi určovaným pixelem a mezi středy shluků ve vícerozměrném prostoru. Určovaný pixel je pak



zařazen do toho shluku, k jehož centroidu má nejbliže (Zeki a Zaid, 2015).

- **Random Forest** je neparametrická metoda řízeného učení využívaná ke klasifikaci a regresi dat. V posledních pár desetiletích si klasifikátor Random Forest (RF) vysloužil zvýšenou pozornost zejména díky vynikajícím klasifikačním výsledkům a rychlosti zpracování dat. RF klasifikátor poskytuje spolehlivé klasifikace za pomoci předpovědí odvozených ze souboru rozhodovacích stromů (Breiman, 2001). Podstatou je tzv. bagging (*Bootstrap Aggregating*), což je metoda strojového učení, která pracuje na principu vytváření velkého množství učících se podmnožin z tréninkových dat (Liaw a Wiener, 2002). Vstupní vektor je klasifikován každým stromem ze skupiny, poté je na základě „hlasování“ stromů zařazen do příslušné třídy s největším počtem hlasů (Kulkarni a Lowe, 2016).

### 3.7.3 Objektová klasifikace

Na rozdíl od pixelově založených metod, které klasifikují jednotlivé pixely přímo, objektová klasifikace nejprve agreguje pixely do spektrálně homogenních objektů pomocí segmentačního algoritmu a následně jednotlivé objekty klasifikuje.

Objektová klasifikace má však i několik svých nevýhod. Těmi jsou například obrazová nadsegmentace a podsegmentace. Výsledkem nedostatečné segmentace jsou např. objekty, které pokrývají více než jednu třídu a tím způsobují klasifikační chyby, jelikož všechny pixely musí být v každém smíšeném objektu přiřazeny ke stejné třídě.

Výhodou objektové klasifikace je, že snižuje spektrální variace v rámci tříd a odstraňuje tzv. salt-and-pepper efekty, které jsou typické pro klasifikaci založenou na pixelech (Hossain a Chen, 2019).

### **3.8 Změny ve využívání zemědělské půdy**

Změna klimatu a využívání půdy jsou v současnosti považovány za hlavní globální problémy životního prostředí. Zemědělské systémy, zejména orná půda a pastviny pokrývají zhruba 40 % veškerého půdního povrchu. Změny ve využívání půdy dlouhodobě výrazně přispívají ke zvýšení globální koncentrace oxidu uhličitého a k negativním dopadům na zemědělskou produkci (Lorencová et al., 2013).

#### **3.8.1 Historie změn ve využívání zemědělské půdy ČR**

Plocha zemědělské půdy na území České republiky prošla v minulosti nesčetnými změnami. Obecně plocha zemědělské půdy expandovala až do 80. let 19. století, kdy dosáhla svého vrcholu. V tomto období převažoval výskyt zemědělských ploch zejména v nížinných oblastech středních Čech a jižní Moravy, velké plochy se však také vyskytovaly v kopcovitých oblastech i na horách, někdy i ve výškách přes 1000 m. n. m.

Vývoj průmyslové společnosti však způsobil zvyšující se fyzický a ekonomický tlak na zemědělskou půdu, která se stále častěji přetvářela k jiným způsobům využití. Až do 2. světové války plocha zemědělské půdy klesala, zejména vlivem ekonomických důvodů: změna na jiný způsob využití probíhala nejprve v urbanizovaných oblastech a jejich blízkém okolí a v méně úrodných oblastech. Intenzivní pokles zemědělské půdy byl pozorován ve všech regionech České republiky. České pohraničí bylo s odsunem Němců vylidněno a zanedbáno. Na spoustě míst nebyl nikdo, kdo by se o půdu staral, načež místo ní nastoupily lesy. Intenzivní rozvoj centrálně plánované ekonomiky, zejména vliv těžby a konstrukčních aktivit způsobil zhoršování půdní kvality. V průběhu 90. let 20. století nastala velká změna v rozvoji ploch TTP a lesů, jež měla pozitivní vliv na zlepšení celkového stavu životního prostředí, celková rozloha orné půdy však klesala (Bičík et al., 2001).

Dle výzkumu, který provedla Lorencová (2013) byl zjištěn úbytek orné půdy o 6 % od roku 1948 do roku 2010, avšak výměra trvalých kultur i TTP vzrostla o 3 %. I přes redukcii ploch orné půdy způsobilo znárodnování a socialistická industrializace enormní nárůst využívání přírodních zdrojů. Intenzifikace zemědělské produkce vyvolaly degradaci krajiny a zjednodušení její struktury. Plocha orné půdy se nejvíce

snížila v příhraničních oblastech (o více než 50 %). Tyto oblasti vyšších nadmořských výšek a chladného podnebí nejsou přirozeně vhodné pro zemědělskou výrobu, a proto byly zatravňovány nebo zalesňovány. Plocha TTP rostla především na severní hranici a částečně i na východní hranici země.

### **3.8.2 Výzkum synergického využití radarových a optických dat**

Esch et al. (2014) ve svém výzkumu kombinovaného využití snímků s vysokým a středním rozlišením pro mapování orné půdy a TTP zjistili, že v časovém intervalu období sklizně, který by se mohl zdát pro rozlišování mezi obilovinami a travním porostem nejvhodnější, vykazují hodnoty NDVI i přesto podobnost mezi TTP a kukuřicí nebo okopaninami. Z tohoto důvodu vyžaduje rozlišení mezi plodinami na orné půdě a TTP další data získaná v průběhu jarní sezóny. Při analýze sezónního chování vyšlo najevo, že NDVI trvalých travních porostů vykazoval zřetelný nárůst v období jara (březen, duben), vrcholný stav na začátku léta a mírný pokles během období sucha následovaný konstantním poklesem od konce léta do zimy (Esch et al., 2014).

Soria-Ruiz, Fernandez-Ordoñez a Woodhouse (2010) ve své práci kombinují data Radarsat-1 s pásmy Landsat ETM+ (*Enhanced Thematic Mapper Plus*) za účelem land cover klasifikace ve středním Mexiku. Dospěli k závěru, že synergické využití optických a radarových dat přináší úspěšnější informace o krajinném pokryvu a zvyšuje přesnost klasifikace, oproti využití samostatného multispektrálního obrazu.

Spracklen a Spracklen (2021) posuzovali využití synergických dat Sentinel-1 a Sentinel-2 pro mapování přírodních lesů a akátových plantáží. Při použití pouze dat Sentinel-2 dosáhli přesnosti klasifikace 90 %. Z jejich výsledků je však zřejmé, že přidání radarového pásma přesnost klasifikace těchto kategorií krajinného pokryvu nezvýšilo.

Niculescu et al. (2018) ve výsledcích své studie využívající klasifikátor Random Forest k monitoringu vegetace s pomocí série dat Sentinel-1 a Sentinel-2 mluví o synergii těchto dat jako o velké příležitosti pro monitorování globální vegetace, zejména díky vylepšeným spektrálním a časovým charakteristikám oproti datům SPOT (*Satellite Pour l'Observation de la Terre*).

## 4. Metodika

V této části práce jsou podrobněji popsána použitá data, postup práce v programech SNAP a ArcGIS a metodiky vyhodnocení změn na zemědělské půdě zaměřená na ornou půdu a TTP, a to jak pomocí klasifikátoru Random Forest, tak normovaného vegetačního indexu NDVI.

### 4.1 Zájmové území

Zájmovým územím pro tuto práci je zemědělská oblast o ploše zhruba 35 712 ha v Libereckém kraji, viz Obr. 4. Většími městy nacházejícími se v této oblasti jsou např. Česká Lípa, Nový Bor, Mimoň, Jablonné v Podještědí nebo Stráž pod Ralskem. Částečně sem zasahují CHKO České středohoří, CHKO Lužické hory a CHKO Kokořínsko-Máchův kraj. Celé území se nachází v mírně teplé klimatické oblasti a převažují zde půdní typy luvizem, pseudoglej a podzol. Většina zájmového území spadá z hlediska krajinné typologie do lesozemědělské oblasti (CENIA, 2021).



Obr. 4 Zájmové území sledování změn na zemědělské půdě – Liberecký kraj

Zemědělství jako ekonomické odvětví nemá v Libereckém kraji stěžejní postavení, je zde pouze doplňkovým odvětvím hospodářství. Nejvyšší podíl obdělávané orné půdy je v okrese Česká lípa (36,9 % orné půdy v kraji). Ve srovnání s celorepublikovým průměrem byl v Libereckém kraji zjištěn nadprůměrný podíl osevních ploch pícnin na orné půdě. Produkci zde dominují obiloviny, cukrovka technická a olejnin (ČSÚ, 2009).

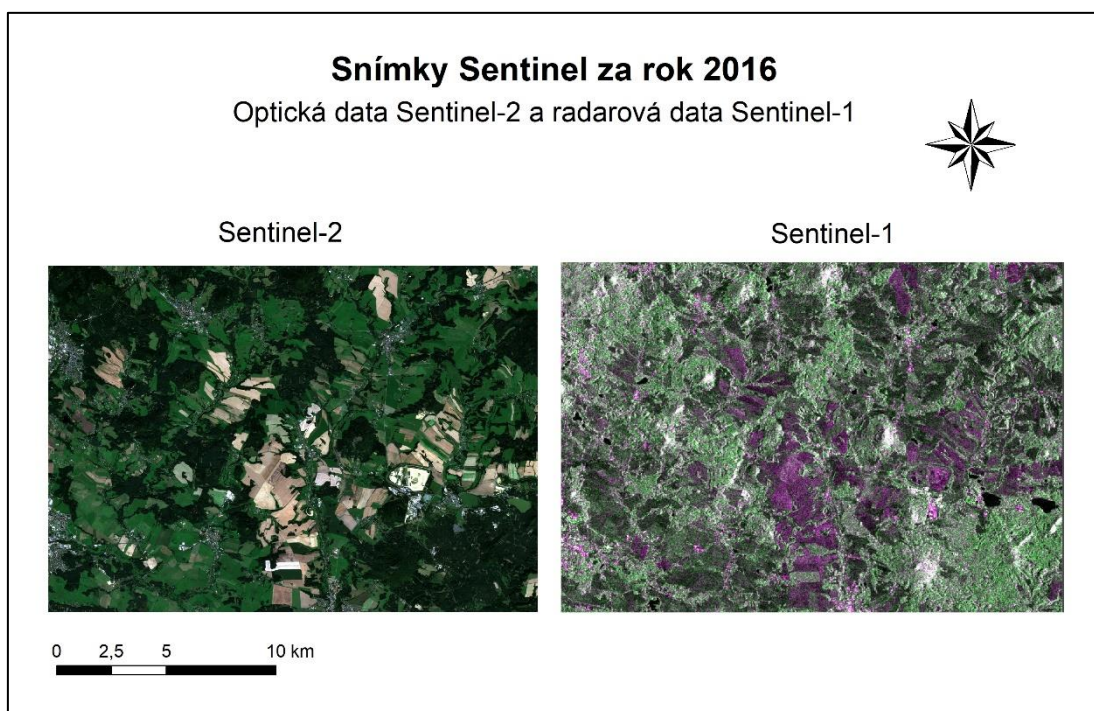
## 4.2 Data

K provedení vyhodnocení změn nastalých na zemědělské půdě v zájmovém území Libereckého kraje byla využita radarová data Sentinel-1, optická data Sentinel-2 a referenční data LPIS za období let 2015–2020. Pro každý rok byl vybrán jeden snímek. Důraz byl u optických dat kladen zejména na velmi nízký výskyt oblačnosti ve snímcích, proto byla volena data s oblačností pod 5 %. Taková data s nízkou oblačností se vyskytovala zejména v letních měsících od června do září. Data Sentinel-1 pak byla volena tak, aby časem pořízení co nejpřesněji odpovídala datům Sentinel-2 s přípustnou odchylkou  $\pm 2$  dny. Přehled použitých dat s termínem jejich pořízení je uveden v tabulce Tab. 1.

Rok pořízení Data	Sentinel-2	Sentinel-1
2015	4.7.	3.7.
2016	27.8.	26.8.
2017	7.8.	6.8.
2018	7.8.	7.8.
2019	23.7.	24.7.
2020	12.9.	13.9.

Tab. 1 Přehled dat pořízení jednotlivých snímků Sentinel-1 a Sentinel-2

Data Sentinel byla stažena z internetového datového skladu CollGS (*Sentinel Collaborative Ground Segment*), který umožňuje velmi rychlé a bezplatné stažení dat z družic Sentinel-1, Sentinel-2 a Sentinel-3 pro území České republiky (CollGS, 2021). Pro tuto práci byly využity Level-1C a Level-2A produkty Sentinel-2, jejichž dlaždice se skládají ze čtvercových obrazů o velikosti 100 x 100 km v projekci UTM/WGS84 a každé spektrální pásmo je tvořeno jednou dlaždicí (ESA, 2015). V případě dat Sentinel-1 byla použita data režimu snímání IW (*Interferometric Wide Swath Mode*), která mají šířku záběru 250 km a prostorové rozlišení 5 x 20 m (ESA, 2021). Všechny použité produkty Sentinel jsou distribuovány ve specifické podobě SAFE (*Standard Archive Format for Europe*) formátu, přičemž hlavní informace o produktu je uložena v souboru ‚manifest.safe‘. Příklady RGB kompozitů použitých snímků Sentinel-1 a Sentinel-2 zobrazujících zájmové území jsou uvedené na Obr. 5.



Obr. 5 Sentinel-2 (optické) a Sentinel-1 (radarové) snímky zájmové lokality v RGB kompozitu

Jako referenční data o využití území v jednotlivých obdobích byla použita data LPIS (*Land Parcel Identification System*). Jedná se o klíčovou součást tzv. Integrovaného administrativního kontrolního systému (IACS). Jeho hlavním účelem je identifikace zemědělských pozemků a slouží jako referenční databáze k ověřování údajů uvedených v žádostech o dotace (Trojáček, 2003). Základní sledovanou jednotkou jsou zde půdní bloky, které jsou veřejnosti dostupné online ke stažení ve formátu shapefile na portále eAgri ([www.eagri.cz](http://www.eagri.cz)).

Pro tuto práci byly hromadně staženy polygony jednotlivých katastrálních území Libereckého kraje, pokud možno co nejpřesněji odpovídající svým datem času pořízení jednotlivých snímků Sentinel. Těmto polygonům byl přiřazen souřadnicový systém S-JTSK a následně byly funkcí „Merge“ spojeny do jediné vrstvy. Takto upravená data byla pomocí nástroje „Clip“ oříznuta na rozsah zájmového území.

### 4.3 Předzpracování dat

Jedním z prvních kroků při práci s družicovými daty je jejich předzpracování do podoby vhodné k provádění analýz. V případě dat Sentinel-2, která se zdarma poskytují na úrovni 1C (tedy radiometricky korigovaná ToA data), se jedná o provedení atmosférické korekce, tj. kalibrace na odrazivost na úrovni povrchu – BoA (*Bottom-of-Atmosphere*). Korekce byla provedena v prostředí programu SNAP (*Sentinel Application Platform*) za pomoci pluginu Sen2Cor. Je třeba mít na paměti, že je korekce datově velmi náročná a samotný proces může trvat i desítky minut.

Atmosféricky korigovaná data Sentinel-2A byla poté převzorkována pomocí interpolační metody nejbližšího souseda na rozlišení 10m ve všech pásmech. Následovalo vytvoření výřezu obrazu na rozsah vybraného zájmového území, pomocí nástroje „Subset“.

Pro předzpracování radarových dat Sentinel-1 bylo jako první krok zvoleno odstranění šumu pomocí nástroje „Thermal Noise Removal“. Nutná byla úprava snímků pomocí radiometrické kalibrace, jelikož snímky úrovně 1, s kterými bylo pracováno, tyto korekce neobsahují. Pro kalibraci bylo použito nástroje „Calibrate“.

Dalším krokem bylo provedení terénních korekcí pomocí funkce „*Range Doppler Terrain Correction*“. Jako vztažný DMR (*digitální model reliéfu*) byl pro tuto funkci nastaven model SRTM 1sec. Převzorkovací metoda byla zvolena bilineární a projekce byla provedena do souřadnicového systému WGS84/UTM zone 33N, který je shodný se souřadnicovým systémem snímků Sentinel-2.

Takto upravená radarová data byla pomocí funkce „*Collocate*“ spojena do jednoho snímku s předzpracovanými optickými daty Sentinel-2. Funkce „*Collocate*“ umožňuje spojit dva prostorově se překrývající produkty tím, že hodnoty pixelů tzv. „*slave*“ produktu jsou převzorkovány do geografického rastru druhého produktu, tzv. „*master*“.

#### **4.4 Klasifikace**

Byly vytipovány tři třídy trénovacích dat pro klasifikaci povrchu, a to orná půda holá, orná půda s vegetací a trvalý travní porost. Samotná klasifikace byla provedena řízeně metodou Random Forest na úrovni jednotlivých pixelů. Jedná se o kombinovanou metodu strojového učení určenou pro klasifikaci a regresi. Principem je tvorba více rozhodovacích stromů při učení a následné vydání nejčastější hodnoty tříd vrácených jednotlivými stromy (Barrett et al., 2014).

Pro každou trénovací třídu bylo zvoleno cca 20 trénovacích polygonů, na základě referenčních dat LPIS pro daný rok. Orná půda holá byla od orné půdy s vegetací rozlišována vizuálně, případně na základě kompozitu v nepravých barvách. Pro klasifikaci jak samotných snímků Sentinel-2, tak i snímků s přidaným radarovým pásmem bylo zvoleno stejných parametrů klasifikátoru: každá třída byla klasifikována na základě tréninkových vzorků z 5000 pixelů a počet vytvořených stromů byl nastaven na hodnotu 10. Výsledné klasifikované obrazy byly poté uloženy do formátu GeoTIFF pro umožnění jejich analýzy v programu ArcGIS.



## 4.5 Změny na zemědělské půdě

Analýza změn na zemědělské půdě byla uskutečněna v programu ArcGIS. Klasifikované snímky byly reklasifikovány pomocí nástroje „*Reclassify*“ do dvou tříd – třída 1 představuje TTP, třída 2 je orná půda celkově (orná půda holá + orná půda s vegetací). Následujícím krokem bylo pomocí nástroje „*Zonal Statistics*“ a polygonové vrstvy orné půdy a TTP z dat LPIS přepočítat hodnoty rastru tak, aby hodnoty pixelů odpovídaly polygonům z referenčních dat LPIS a obsahovaly hodnotu té třídy, jejíž pixely se v polygonu vyskytovaly nejčastěji. Výsledný rastr byl s využitím nástroje „*Raster To Polygon*“ převeden na polygonovou vrstvu.

Pro srovnání takto vzniklé klasifikované vrstvy obsahující polygony orné půdy a TTP s referenčními daty LPIS bylo využito nástroje „*Clip*“. Jako ořezová vrstva funkce byly použity jednotlivé vrstvy orné půdy a TTP z dat LPIS, ořezávanou vrstvou pak byla klasifikovaná vrstva. Tímto způsobem vznikly pro každý rok dvě vrstvy, jedna vrstva orné půdy obsahovala informaci o výměře orné půdy, která se shodovala s výměrou dle LPIS a informaci o výměře zbytku plochy orné půdy dle LPIS, která však byla nesprávně klasifikována jako TTP. Druhá naopak obsahovala informace o výměře TTP, který se shodoval s výměrou dle LPIS a informaci o zbytku TTP, která byla nesprávně vyhodnocena jako orná půda. Po vypočítání prostorové geometrie jednotlivých tříd obsahovala každá ze dvou výsledných vrstev údaje o velikosti plochy třídy určené klasifikací, která se shodovala s třídou dle LPIS, ale také údaj o velikosti klasifikované třídy, která byla v porovnání s referenčními daty vyhodnocena špatně.

Ke grafické interpretaci změn byly vytvořeny mapy s výřezem části zájmového území, na kterém byly změny nejvíce patrné. K tomu bylo využito nástroje „*Intersect*“, kdy vzniklá mapa zobrazovala polygony orné půdy a TTP, které se v daných dvou letech nezměnily a polygony, které se změnily buďto z orné půdy na TTP nebo naopak. Nakonec byla vytvořena i celková mapa, která porovnává změny mezi lety 2015 a 2020.

## 4.6 NDVI

Vegetační indexy jsou údaje odvozené z multispektrálních dat na základě rozdílů v absorpci, propustnosti a odrazivosti povrchu vegetace v červeném a blízkém infračerveném pásmu. Mohou sloužit např. k měření biomasy nebo ke zjišťování fyziologického a zdravotního stavu vegetace. Vegetačních indexů existuje mnoho druhů, mezi nimi např. RVI (*Ratio Vegetation Index*), SAVI (*Soil Adjusted Vegetation Index*) nebo NDVI (*Normalized Difference Vegetation Index*) (Fung a Siu, 2010).

V této práci je dále využito normalizovaného diferenčního indexu (NDVI). Rastr s hodnotami NDVI byl vytvořen nad předzpracovanými satelitními snímky družice Sentinel-2 v programu ArcGIS pomocí nástroje „*Raster Calculator*“ užitím následujícího vzorce:

$$\text{Float}(B8 - B4) / \text{Float}(B8 + B4)$$

kde B8 představuje hodnoty pixelů z infračerveného pásma a B4 z pásma červeného. Výsledné hodnoty se pak pohybují mezi čísly -1 a 1. Pro interpretaci výsledných hodnot v závislosti na skutečných plochách orné půdy a TTP vedených v LPIS bylo použito nástroje „*Zonal Statistics*“. Takovýto snímek zobrazoval hodnoty NDVI ve sledovaném období na příslušných polygonech dle LPIS. Pro vytvoření vhodné grafické interpretace byly hodnoty NDVI extrahovány a vloženy do programu Excel, ve kterém poté bylo srovnání hodnot NDVI za jednotlivé roky provedeno pomocí krabicového grafu.

Mapy hodnot NDVI v jednotlivých letech, viz Příloha 2, byly vytvořeny v programu ArcGIS. Pomocí funkce „*Reclassify*“ byly rastry NDVI překlasifikovány do tří tříd. První třída obsahuje všechny hodnoty od 0 – 0,4 a představuje plochy holé orné půdy; druhá třída obsahuje hodnoty od 0,4 – 0,6 a představuje plochy orné půdy s vegetací a třetí třída obsahuje hodnoty 0,6 – 1 a představuje plochy TTP se vzrostlou vegetací. Mapy byly následně oříznuty na část vybraného území, kde se změny projevovaly nejvýrazněji.

## 5. Výsledky

### 5.1 Vyhodnocení přesnosti klasifikace

K posouzení přesnosti klasifikace bylo použito tzv. matice záměn, jež ve sloupcích obsahuje skutečnou hodnotu předpovídaného znaku a v řádcích předpověď klasifikátoru. Srovnávány jsou výměry výsledných ploch orné půdy a TTP vzniklé klasifikací samotných dat Sentinel-2 s výměrami ploch vzniklých po klasifikaci optických dat s přidaným radarovým pásmem Sentinelu-1. Největší shody jsou poté v tabulkách vyznačeny světle zelenou barvou pro TTP a světle žlutou pro ornou půdu.

Z tabulky změn za rok 2015, viz Tab. 2, je patrné, že klasifikace orné půdy dopadla o něco lépe po přidání radarových dat. Pouze 0,8 km<sup>2</sup> orné půdy bylo po přidání radarového pásma vyhodnoceno nesprávně. Vyhodnocení TTP však proběhlo znatelně lépe za použití pouze dat Sentinel-2. Celková přesnost klasifikace vyšla lépe za použití pouze optických dat a to 85 %, není to však velký rozdíl oproti klasifikaci za využití synergie dat, která vyšla s přesností 82 %.

2015				
[km <sup>2</sup> ]	Sentinel-2		Sentinel-2 + Sentinel-1	
	Orná půda (dle LPIS)	TTP (dle LPIS)	Orná půda (dle LPIS)	TTP (dle LPIS)
Orná půda (dle klasifikace)	32,6	5,5	47,6	25,1
TTP (dle klasifikace)	15,8	90,6	0,8	71,1
Celková přesnost (%)	85 %		82 %	

Tab. 2 Matice změn orné půdy a TTP za rok 2015. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda.

V roce 2016 můžeme pozorovat stejný trend v přesnosti klasifikace, jako v roce 2015. Klasifikace TTP je stále přesnější pouze za použití optických dat, avšak rozdíl už není tak velký, jako tomu je u předešlého roku. Klasifikace tudíž v tomto roce dosáhla velmi slibných výsledků jak za použití pouze optických dat, tak i po přidání radarového pásma, viz Tab. 3. Záměna TTP za ornou půdu proběhla pouze na 11,4 km<sup>2</sup>, což je oproti ostatním rokům (kromě roku 2018) velmi dobrý výsledek. Celková přesnost klasifikace je za celé pozorované období nejvyšší, pro Sentinel-2 je přesnost 93 %, pro synergii dat je to o něco méně (91 %).

2016				
[km <sup>2</sup> ]	Sentinel-2		Sentinel-2 + Sentinel-1	
	Orná půda (dle LPIS)	TTP (dle LPIS)	Orná půda (dle LPIS)	TTP (dle LPIS)
Orná půda (dle klasifikace)	46,7	7,0	48,2	11,4
TTP (dle klasifikace)	3,4	86,4	1,8	81,7
Celková přesnost (%)	93 %		91 %	

Tab. 3 Matice změn orné půdy a TTP za rok 2016. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda.

V roce 2017 vychází přesnost klasifikace lépe pouze za využití optických dat, viz Tab. 4. Nesprávně určené plochy TTP za využití synergie dat činí 25,7 km<sup>2</sup>. Celková přesnost klasifikace pro data Sentinel-2 je 90 %, synergická data dosahují přesnosti 80 %.

2017				
[km <sup>2</sup> ]	Sentinel-2		Sentinel-2 + Sentinel-1	
	Orná půda (dle LPIS)	TTP (dle LPIS)	Orná půda (dle LPIS)	TTP (dle LPIS)
Orná půda (dle klasifikace)	39,0	3,1	45,8	25,7
TTP (dle klasifikace)	10,7	91,8	3,7	68,0
Celková přesnost (%)	90 %		80 %	

Tab. 4 Matice změn orné půdy a TTP za rok 2017. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda.

Výsledky klasifikace za rok 2018 se částečně vymykají trendu z ostatních let. Velká část ploch orné půdy je naopak špatně klasifikována jako plocha TTP, viz Tab. 5. Zajímavým jevem je, že v obou případech klasifikace vyšla plocha správně určeného TTP totožná a to 90,6 km<sup>2</sup>. Celkově jsou výsledky obou klasifikací v tomto roce velmi podobné, rozdíl ve výměře orné půdy činí pouze 2 km<sup>2</sup>. Rozdíl v celkové přesnosti klasifikací obou metod pak činí pouze 2 %.

2018				
[km <sup>2</sup> ]	Sentinel-2		Sentinel-2 + Sentinel-1	
	Orná půda (dle LPIS)	TTP (dle LPIS)	Orná půda (dle LPIS)	TTP (dle LPIS)
Orná půda (dle klasifikace)	36,4	0,3	34,5	0,3
TTP (dle klasifikace)	14,2	90,6	16,2	90,6
Celková přesnost (%)	90 %		88 %	

Tab. 5 Matice změn orné půdy a TTP za rok 2018. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda.

Při klasifikaci snímků za rok 2019 došlo k poměrně velkým nepřesnostem, viz Tab. 6, avšak trend zůstává pořád stejný – zlepšení přesnosti klasifikace orné půdy po přidání radarových dat, následovaná zhoršením klasifikace TTP. Špatně určené plochy TTP představují skoro polovinu celkové výměry TTP podle referenčních dat. Celková přesnost klasifikace je při využití synergie dat poměrně nízká, činí pouze 69 %. Přesnost klasifikace za použití pouze optických dat je stále vysoká a pohybuje se kolem 88 %.

2019				
[km <sup>2</sup> ]	Sentinel-2		Sentinel-2 + Sentinel-1	
	Orná půda (dle LPIS)	TTP (dle LPIS)	Orná půda (dle LPIS)	TTP (dle LPIS)
Orná půda (dle klasifikace)	41,8	8,5	48,6	43,8
TTP (dle klasifikace)	8,8	84,0	1,7	48,3
Celková přesnost (%)	88 %		69 %	

Tab. 6 Matice změn orné půdy a TTP za rok 2019. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda.

Výsledky klasifikace pro rok 2020 se velmi podobají výsledkům z roku 2019, především velkou mírou záměny TTP za ornou půdu po přidání radarových dat viz Tab. 7. Za využití pouze optických dat bylo správně vyhodnoceno 91,4 km<sup>2</sup>, což je druhý nejlepší výsledek po roce 2017 a odpovídá tomu i celková přesnost klasifikace s 92 %. Naproti tomu celková přesnost klasifikace za využití synergie dat byla velmi nízká, se 65 % se jedná o nejnižší přesnost za celé sledované období.

2020				
[km <sup>2</sup> ]	Sentinel-2		Sentinel-2 + Sentinel-1	
	Orná půda (dle LPIS)	TTP (dle LPIS)	Orná půda (dle LPIS)	TTP (dle LPIS)
Orná půda (dle klasifikace)	38,9	1,6	41,6	41,6
TTP (dle klasifikace)	10,0	91,4	6,9	50,9
Celková přesnost (%)	92 %		65 %	

Tab. 7 Matice změn orné půdy a TTP za rok 2019. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda.

Po vyhodnocení procentuální shody klasifikovaných tříd s referenčními daty LPIS byl zjištěn zajímavý trend, viz Tab. 8. TTP byly nejlépe vyhodnoceny jen za použití dat Sentinel-2, takto klasifikovaná data neměla nikdy menší než 90% shodu s referenčními daty, což se jeví jako velmi dobrý výsledek klasifikace. Avšak orná půda docílila lepších výsledků po klasifikaci za synergického využití dat Sentinel-1 a Sentinel-2. Takto klasifikovaná data dosáhla v průměru shody 89,6 %. Výsledné procento úspěšně určených ploch tedy vzrostlo průměrně o 11 %. Přesnost výsledků klasifikace TTP za využití synergie dat však výrazně klesla oproti klasifikaci pouze optických dat, a to na průměrnou hodnotu shody 72 %. Průměrně vzrostlo procento nesprávně určených ploch TTP o 23,5 %. Celková přesnost klasifikace vyšla nejlépe pro obě metody v roce 2016, za použití pouze optických dat činila 93 % a za využití synergie dat pouze o něco méně (91 %). Nejhorší přesnosti dosáhly klasifikace v roce 2019, přesnost za využití dat vyšla zhruba 88 %, avšak přesnost za použití synergie




dat činila pouhých 68 %. Celkově se pro data využitá v této práci za sledované období se ukázala jako nejvhodnější klasifikace pouze optických snímků Sentinel-2.

	Sentinel-2			Sentinel-2 + Sentinel-1		
	Orná půda (%)	TTP (%)	Celková přesnost (%)	Orná půda (%)	TTP (%)	Celková přesnost (%)
2015	67,2	94,3	85,0	98,3	72,4	82,0
2016	93,2	92,6	93,0	96,3	87,8	91,0
2017	78,4	96,7	90,0	92,6	64,0	80,0
2018	71,9	99,7	90,0	68,1	99,7	88,0
2019	82,6	90,8	88,0	96,6	52,5	68,0
2020	79,7	98,3	92,0	85,7	55,0	66,0

Tab. 8 Přesnost klasifikace orné půdy a TTP za využití snímků Sentinel-2 a Sentinel-1 vyjádřená v % správně klasifikované plochy a celková přesnost klasifikace za použití jednotlivých metod

## 5.2 Analýza změn NDVI

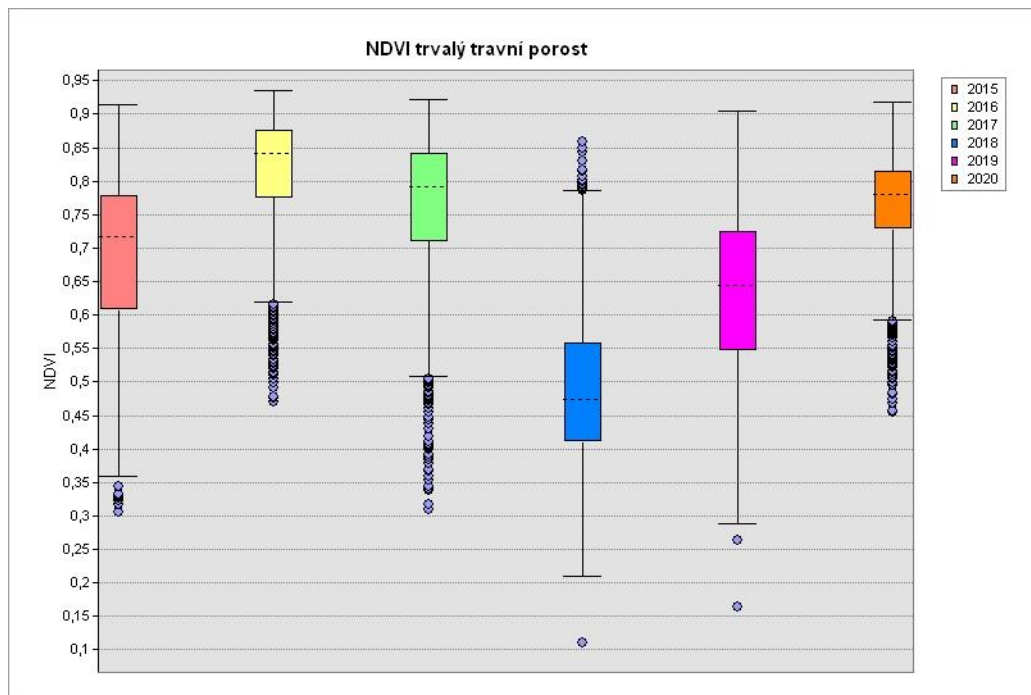
Pro tuto práci byly hodnoty NDVI rozděleny do tří tříd: hodnoty 0,0 – 0,4 představují plochy s ornou půdou holou, 0,4 – 0,6 jsou plochy orné půdy částečně pokryté vegetací a hodnoty vyšší, než 0,6 představují TTP nebo ornou půdu s hustou vegetací. Analýzou změn hodnot NDVI bylo zjištěno, že se tyto hodnoty na orné půdě pohybovaly v průběhu sledovaných let v relativně podobných intervalech, a to mezi hodnotami 0,25 – 0,60; přičemž medián se pohybuje kolem čísla 0,40. Z krabicového grafu, viz Obr. 6, jsou však patrné dvě odchylky, a to v roce 2015 a 2018, kdy se výsledné hodnoty NDVI výrazně lišily od ostatních.



Obr. 6 Krabicové grafy hodnot NDVI na orné půdě v období let 2015–2020

Při analýze grafu hodnot NDVI trvalého travního porostu, viz Obr. 7, je na první pohled patrná velká odchylka hodnot v roce 2018 stejně, jako tomu bylo v tomto roce u hodnot NDVI orné půdy. Většina hodnot v tomto roce se nachází v intervalu 0,40 – 0,55, což je oproti ostatním rokům výrazně méně a odpovídá to hodnotám, které mívá orná půda pokrytá řídkou vegetací. NDVI v ostatních letech dosahuje hodnot od 0,55 do 0,93, což odpovídá povrchům se středně až hustě zapojenou vegetací.

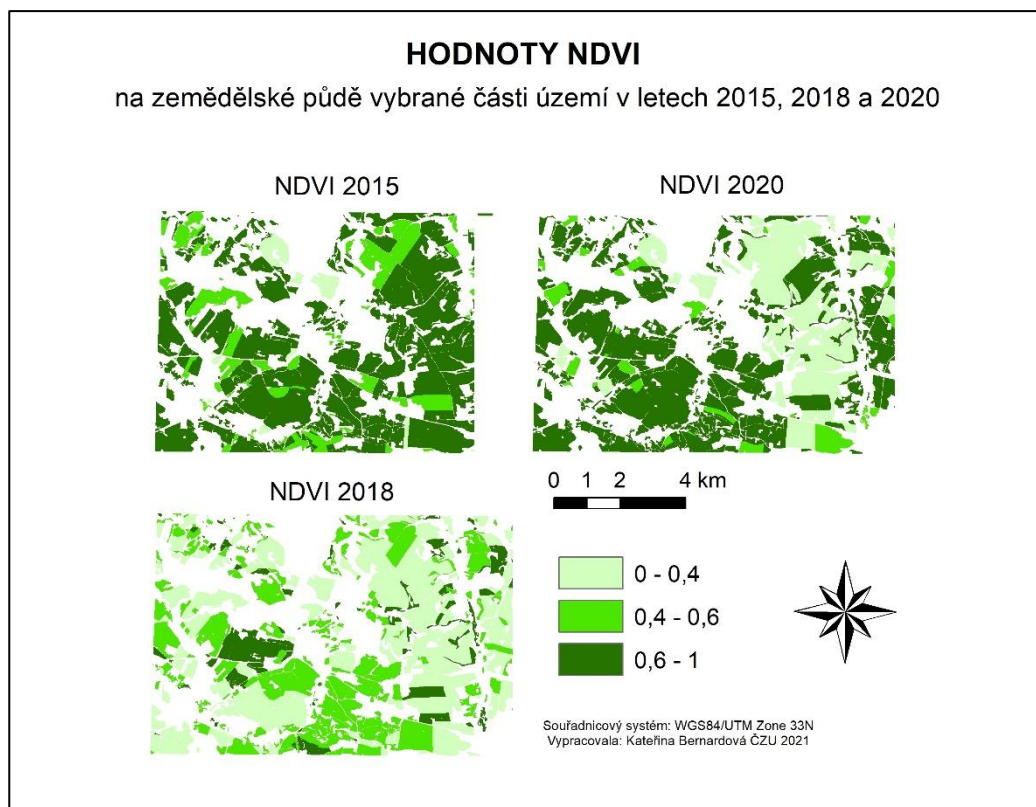
Většina výsledných hodnot NDVI v letech 2016, 2017 a 2020 dosahuje velmi podobných intervalů, a to v rozmezí poměrně vysokých hodnot od 0,75 do 0,87. Vegetace se v těchto letech jeví zdravá a vzrostlá na rozdíl roků 2018 a 2019, kdy byla zemědělská půda ve sledovaném období citelně zasažena suchem.



Obr. 7 Krabicové grafy hodnot NDVI na trvalém travním porostu v období let 2015–2020

Z obou grafů lze také vyvodit důvod lepších výsledků klasifikace dat v letech 2016 a 2017. V roce 2015 dosahují intervaly většinových hodnot NDVI pro ornou půdu a TTP téměř stejných čísel v rozmezí 0,60 – 0,75. Klasifikátor tudíž mohl mít problémy tyto dvě třídy od sebe rozeznat. V letech 2016 a 2017 se však NDVI pro obě třídy pohybují v rozdílných intervalech. U TTP je to zejména interval hodnot 0,70 – 0,88 a u orné půdy přibližně 0,23 – 0,60. Třídy jsou, co se týče spektrálních vlastností, velmi homogenní a z tohoto důvodu jsou i navzájem dobře rozlišitelné a při klasifikaci tak nedochází k intenzivní záměně.

Z Obr. 8 je patrné, že v roce 2015 pokrývala vegetace většinu zemědělské půdy na rozdíl od roku 2020, kde je většina orné plochy holá. Extrémem je rok 2018, který sužovala rekordní sucha, a to se odráží i na hodnotách NDVI, které jsou velmi nízké a pohybují se na většině území v intervalu 0 – 0,4. Tento interval hodnot odpovídá holé orné půdě nebo půdě s minimem vegetace. Snímky hodnot NDVI i pro ostatní roky sledovaného období, viz Příloha 2.

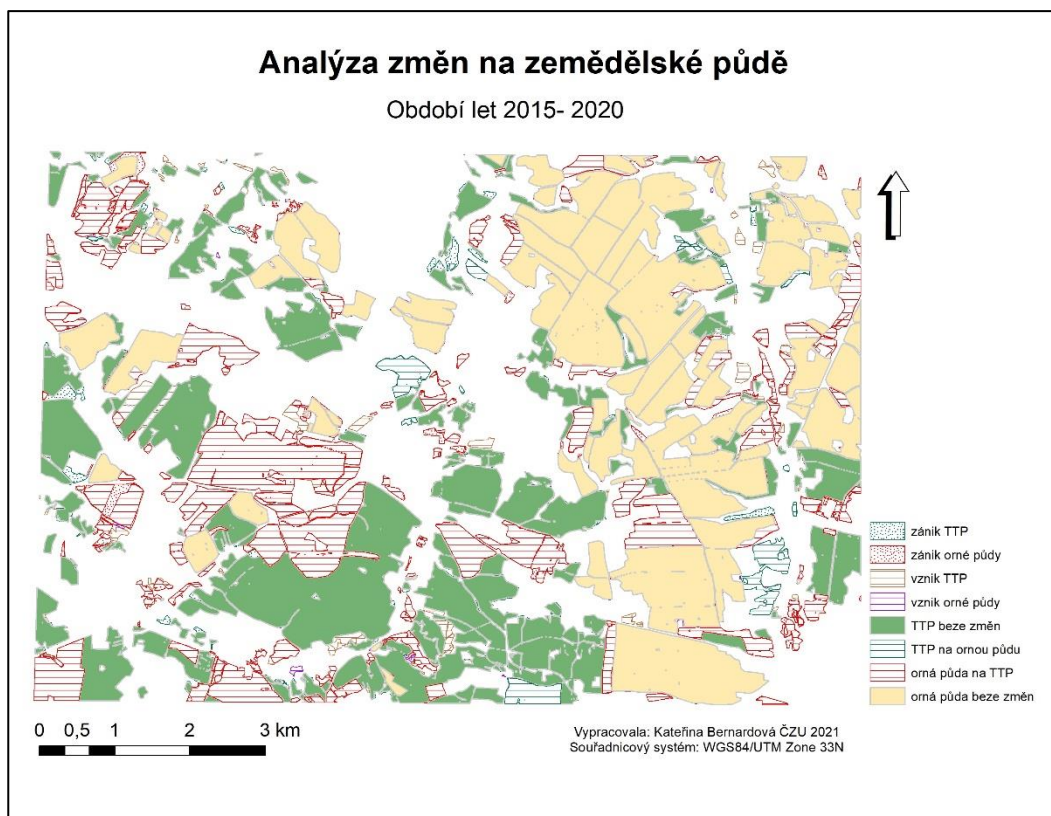


Obr. 8 Hodnoty NDVI na vybrané části zájmového území v letech 2015, 2018 a 2020 (Interval hodnot 0,0 – 0,4 představuje holou ornou půdy, interval 0,4 – 0,6 představuje plochy orné půdy s vegetací, interval 0,6 – 1,0 jsou plochy TTP)

### 5.3 Analýza trendu změn na zemědělské půdě

Dle statistických dat víme, že výměra orné půdy v ČR už více než 50 let klesá, naopak výměra TTP v tomto období kolísala, přičemž posledních 20 let opět stabilně stoupá. Od roku 2015 do roku 2020 klesla výměra orné půdy z 2 971 957 hektarů na 2 931 713 hektarů, tedy o zhruba o 40 000 hektarů (1,4 %). Nárůst plochy TTP činil v tomto období přibližně 22 000 hektarů (2,2 %) (ČÚZK, 2021).

Stejný trend, avšak s jinými procentuálními hodnotami můžeme na zájmové lokalitě konstatovat i po analýze výsledků této práce. Na základě výsledků klasifikovaných dat Sentinel-2 byl na zájmovém území zjištěn 11 % nárůst plochy TTP v období let 2015 – 2020. Výměra orné půdy klesla zásadně, a to o 28 %. Celková plocha orné půdy klesla z 57 km<sup>2</sup> v roce 2015 na 41 km<sup>2</sup> v roce 2020, plocha TTP naopak vzrostla z 93 km<sup>2</sup> na 103 km<sup>2</sup>.



Obr. 9 Mapa výsledných změn na orné půdě vybrané části zájmového území (2015–2020)

Z mapy výsledných změn na zemědělské půdě, viz Obr. 9, je pak patrné vysoké zastoupení ploch přeměněných z orné půdy na TTP, což potvrzuje výše popsany trend ve změnách na zemědělské půdě. Srovnání výše zmíněných hodnot s referenčními daty LPIS potvrzuje již zmíněný trend ve změnách, avšak pracuje s poněkud jinými čísly. Orná půda v zájmovém území činila v roce 2015 zhruba 49 km<sup>2</sup> (rozdíl 8 km<sup>2</sup> oproti výměře získané klasifikací), v roce 2020 činila 48 km<sup>2</sup> (rozdíl 7 km<sup>2</sup> oproti výměře získané klasifikací). Plocha TTP činila v roce 2015 přibližně 95 km<sup>2</sup> (rozdíl 2 km<sup>2</sup> oproti výměře získané klasifikací), v roce 2020 plocha TTP pokrývala zhruba 99 km<sup>2</sup> (rozdíl 4 km<sup>2</sup> oproti výměře získané klasifikací).

Průběh změn na zemědělské půdě na základě klasifikací synergických dat Sentinel-1 a Sentinel-2 je znázorněn v Příloze 1. Je zde patrné, že změny probíhaly na obou typech ploch velmi intenzivně a žádná ze tříd se nejeví jako příliš stabilní.

## 6. Diskuze

Se zvyšující se dostupností dat optického a radarového dálkového průzkumu Země, nabírá na rychlosti také výzkum využití komplementarity těchto dat ke studiu změn na zemědělské půdě. Nedávné studie naznačují, že synergickým využitím dat lze zajistit vylepšení výsledků analýz, například rozlišením informací, které se často projevují pouze jako jemné spektrální nebo strukturální změny na půdě. Většina těchto studií dospěla k závěru, že přesnost analýz za využití synergických produktů převyšuje ty, které pracují pouze s jedním zdrojem dat (Joshi et al., 2016).

Lorencová et al. (2013) ve svém výzkumu popisují změny na zemědělské půdě v České republice za období let 1948 – 2010. Dospěli k závěru, že výměra orné půdy klesla o zhruba 6 %, přičemž výměra trvalého travního porostu vzrostla o 3 %. Podobný trend ve změnách využití zemědělské půdy byl také zaznamenán analýzou v této diplomové práci. Na základě klasifikovaných dat se výměra trvalého travního porostu na zájmovém území ve sledovaném období 2015 – 2020 zvýšila o 11 %, oproti tomu výměra orné půdy klesla průměrně o 28 %.

Výsledky této práce potvrzují zvýšenou účinnost synergického využití optických a radarových dat při klasifikaci orné půdy, která byla popsána i v několika dalších studiích (Esch et al., 2014; Barrett et al., 2014; Soria-Ruiz, Fernandez-Ordoñez a Woodhouse, 2010). Soria-Ruiz, Fernandez-Ordoñez a Woodhouse (2010) zjistili, že u klasifikace pouze optických dat vznikaly nepřesnosti mezi klasifikací orné půdy s vegetací (např. kukuřicí) a trvalým travním porostem, a že období pořízení snímku je velmi důležitým faktorem pro úspěšnost klasifikace. Nepřesnosti v rozlišení trvalého travního porostu a orné půdy s vegetací zaznamenávají ve své práci také Klouček et al. (2018). Problémy s rozlišením těchto dvou tříd eviduje i tato diplomová práce. Nepřesné rozlišování tříd bylo patrné zejména v roce 2018, jenž se nesl ve znamení rekordního sucha. Plochy trvalého travního porostu byly často holé nebo se suchou a nezdravou vegetací, a tudíž se jejich spektrální vlastnosti velmi podobaly holé orné půdě, s kterou také byly často zaměňovány.

K provedení klasifikací byla využita metoda Random Forest, jejíž vhodnost pro mapování změn je v této práci posuzována. Touto klasifikační metodou se zabývá

hned několik publikací. Kulkarni a Lowe (2016) ve své studii srovnávali využitelnost metody Random Forest pro klasifikaci land cover s několika dalšími metodami, mezi nimiž jsou např. maximum likelihood, minimum distance nebo support vector machine (SVM). Dospěli k závěru, že při pečlivém výběru homogenních dat převyšuje Random Forest svou celkovou přesností a kappa koeficientem všechny výše uvedené metody.

Přesnost klasifikátoru Random Forest byla analýzou v této práci vyhodnocena jako velmi dobrá. Průměrná přesnost klasifikace orné půdy napříč sledovaným obdobím dosahovala 90 % v případě synergických dat, což znamená nárůst oproti čistě multispektrálním datům. Průměrná přesnost určení TTP za využití pouze snímků Sentinel-2 činila dokonce 95 %. S využitím synergie dat se naopak přesnost klasifikace TTP snížila na 72 %. Celková přesnost klasifikace obou tříd na zájmovém území ve sledovaném období však dosáhla nejlepších hodnot za použití pouze optických dat Sentinel-2, výsledná hodnota v žádném roce neklesla pod 85 %. Klasifikátor Random Forest se tak jeví jako velmi vhodná metoda pro určování typů land cover.

Z analýzy NDVI vyplývá, že jsou data použita v této práci napříč sledovanými roky poměrně heterogenní, zejména co se týče vegetačního pokryvu. V letech 2016 a 2017 byla oproti ostatním rokům separabilita tříd podle hodnot NDVI vyšší. Většina hodnot NDVI pro ornou půdu a TTP se pohybovala v odlišných intervalech, a proto tato data dosáhla lepších výsledků klasifikace. Velká heterogenita vegetačního pokryvu napříč daty může způsobovat odlišné výsledky klasifikací, zejména v případech, kdy dosahují povrchy TTP a orné půdy velmi podobných charakteristik, například právě v důsledku sucha (nezdravá, suchá, případně žádná vegetace na TTP se jeví podobně jako holá orná půda).

Vysoké hodnoty NDVI v roce 2015 blíží se TTP a husté vegetaci mohou být přisouzeny období pořízení dat, kdy je už ze samotného snímku patrné, že na velkém počtu ploch orné půdy je plně vzrostlá plodina. Naopak poměrně nízké hodnoty NDVI v roce 2018 blíží se spíše hodnotám pro holou ornou půdu, je možné vysvětlit tím, že se jednalo o rekordně suchý rok, který se odrazil i na stavu vegetace. Na mnoha plochách, které jsou zařazeny jako TTP, proto nerostla žádná zdravá vegetace, nebo se zde vyskytovala pouze ojediněle, což způsobovalo záměnu s plochami orné půdy, které byly vlivem sucha většinou taktéž holé.

## 7. Závěr

TTP a orná půda tvoří nejzastoupenější složku krajinného pokryvu na světě. V posledních letech však v České republice dochází k úbytku ploch orné půdy na úkor trvalých travních porostů. Dle statistických dat výměra orné půdy v ČR od roku 2015 do roku 2020 klesla o zhruba 1,4 % své celkové plochy. Nárůst výměry TTP naopak činil cca 2,2 %. Dopadů takových změn ve využívání půdy je mnoho, jedná se např. o dopady na biologickou rozmanitost, degradaci půdy a schopnost biologických systémů uspokojovat lidskou potřebu. Z těchto a mnoha dalších důvodů je sledování těchto změn klíčovým prvkem udržitelného zemědělství.

Neustále probíhající pokrok v oblasti dálkového průzkumu Země nabízí mnoho metod, jak tyto změny kvantifikovat a analyzovat. Jedním z aktuálních přístupů je využití synergie optických a radarových dat pro lepší klasifikaci snímků. Synergie dat Sentinel-1 a Sentinel-2 využívá i tato práce, která se snaží objasnit výhodu takovýchto dat oproti datům z jednoho zdroje, zhodnotit využitelnost klasifikátoru Random Forest pro klasifikaci změn na zemědělské půdě a popsat probíhající trend změn na zemědělské půdě v České republice.

Na zájmovém území v zemědělské oblasti Libereckého kraje je demonstrován současný trend nárůstu ploch trvalého travního porostu na úkor orné půdy, viz výzkumná otázka e). Uskutečněná klasifikace dat Sentinel za období let 2015–2020 zjistila velký potenciál synergických dat a využití klasifikátoru Random Forest pro klasifikaci orné půdy, která dosáhla nevyšší přesnosti výsledků právě za využití synergie dat, viz výzkumná otázka b). Klasifikace TTP naopak dosáhla nejlepších výsledků za použití pouze dat optických. Takovéto odchylky můžeme přisuzovat zejména období pořízení dat, kdy se na některých snímcích zřetelně projevoval dopad rekordního sucha, nebo různým fázím růstu plodin na orné půdě, což způsobuje častou záměnu ploch orné půdy za plochy trvalého travního porostu. Celková přesnost klasifikace obou tříd dosahovala konstantně vyšších hodnot za použití pouze optických dat Sentinel-2, přičemž přesnost v žádném roce neklesla pod 85 %. Random Forest byl však prokázán jako uživatelsky příjemná klasifikační metoda, která nevyžaduje mnoho vstupních parametrů a zároveň podává velmi uspokojivé výsledky, viz výzkumná otázka d).



Analýza NDVI potvrdila velkou heterogenitu dat z hlediska půdního pokryvu, viz výzkumná otázka c). Dle výsledných nízkých hodnot NDVI za rok 2018 můžeme usuzovat narušení zdravotního stavu vegetace na TTP v důsledku rekordního sucha, který tento rok sužovalo. Oproti tomu hodnoty NDVI v roce 2015 dosahovaly celkově vysokých hodnot, což koresponduje s vizuální interpretací snímku, na němž je patrné velké zastoupení ploch orné půdy pokrytých vzrostlou vegetací.

Výsledky této práce poskytují informace pro ucelenou představu o využití synergických dat a klasifikátoru Random Forest, pro sledování změn na zemědělské půdě a popisují současný trend v těchto změnách. Na základě výsledků této práce se snímky družic Sentinel-1 a Sentinel-2 jeví jako velmi vhodný zdroj dat pro mapování změn na zemědělské půdě, viz výzkumná otázka a). I přesto, že klasifikace dosáhla velmi přesných výsledků, je možné tuto přesnost ještě zvýšit, a to například přidáním dat z dalšího vegetačního období např. jara, kdy mohou být změny na zemědělské půdě ještě více patrné nebo vhodnějším výběrem tréninkových dat.

## 8. Přehled literatury a použitých zdrojů

ABBAS, A. W. et al., 2016. K-Means and ISODATA Clustering Algorithms for Landcover Classification Using Remote Sensing. *Sindh University Research Journal (Science Series)* [online]. Pakistan, **48**, 315-318 [cit. 2021-03-27].

AGGARWAL, S., 2004. Principles of remote sensing. *Satellite remote sensing and GIS applications in agricultural meteorology*. Switzerland: World Meteorological Organisation, 22-38.

AL-DOSKI, J., S. B. MANSOR a H. Z. M. SHAFRI, 2013. Image Classification in Remote Sensing. *Journal of Environment and Earth Science* [online]. Malaysia, **3**(10) [cit. 2021-03-27]. ISSN 2225-0948.

BAGHDADI, N. a M. ZRIBI, ed., 2016. *Optical Remote Sensing of Land Surface* [online]. Elsevier [cit. 2021-02-16]. ISBN 9781785481024. Dostupné z: doi:10.1016/C2015-0-01220-5

BARRETT, B. et al., 2014. Assessment of multi-temporal, multi-sensor radar and ancillary spatial data for grasslands monitoring in Ireland using machine learning approaches. *Remote Sensing of Environment* [online]. **152**, 109-124 [cit. 2021-03-25]. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2014.05.018

BIČÍK, I. et al., 2001. Land Use/Land Cover Changes in Czechia over the past 150 Years – An Overview. HIMIYAMA, Y. et al. *Land Use/Cover Change in Selected Regions in the World*. 1. Asahikawa: IGU SG LUCC, s. 29-39. ISBN 4-907651-02-3.

BREIMAN, L., 2001. Random Forests. *Machine Learning* [online]. **45**(1), 5-32 [cit. 2021-03-27]. ISSN 08856125. Dostupné z: doi:10.1023/A:1010933404324

CAMPBELL, J. B. a R. H. WYNNE, 2011. *Introduction to remote sensing*. 5th edition. New York: Guilford Press. ISBN 978-1-60918-176-5.

CENIA, 2021. *Národní geoportál INSPIRE* [online]. [cit. 20.3.2021]. Dostupné z: <https://geoportal.gov.cz/web/guest/wms>

COLLGS, 2021. Data z družic Sentinel v ČR. *CollGS* [online]. Czech Space Portal [cit. 2021-03-21]. Dostupné z: <https://collgs.czechspaceportal.cz/>

ČSÚ, 2009. *Postavení venkova v Libereckém kraji*. Liberec: Český statistický úřad. Souborné informace. ISBN 978-80-250-1939-9.

ČÚZK, 2021. *Souhrnné přehledy o půdním fondu z údajů katastru nemovitostí České republiky*. Praha: Český úřad zeměměřický a katastrální. ISBN 978-80-88197-21-8. ISSN 1804-2422.

DUSSEUX, P. et al., 2014. Combined Use of Multi-Temporal Optical and Radar Satellite Images for Grassland Monitoring. *Remote Sensing* [online]. **6**(7), 6163-6182 [cit. 2021-03-20]. ISSN 2072-4292. Dostupné z: [doi:10.3390/rs6076163](https://doi.org/10.3390/rs6076163)

ENVI, 2009. *Atmospheric Correction Module: QUAC and FLAASH User's Guide*. Version 4.7. USA: ITT Visual Information Solutions.

ESA, 2015. *Sentinel-2 User Handbook*. European Space Agency, 64 s. Dostupné také z: <https://sentinel.esa.int/documents>

ESA, 2021. Sentinel-1 SAR User Guide Introduction. *Sentinel Online* [online]. European Space Agency [cit. 2021-03-21]. Dostupné z: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-1-sar>

ESCH, T. et al., 2014. Combined use of multi-seasonal high and medium resolution satellite imagery for parcel-related mapping of cropland and grassland. *International Journal of Applied Earth Observation and Geoinformation* [online]. **28**, 230-237 [cit. 2021-03-23]. ISSN 03032434. Dostupné z: [doi:10.1016/j.jag.2013.12.007](https://doi.org/10.1016/j.jag.2013.12.007)

FUNG, T. a W. SIU, 2010. Environmental quality and its changes, an analysis using NDVI. *International Journal of Remote Sensing* [online]. **21**(5), 1011-1024 [cit. 2021-03-27]. ISSN 0143-1161. Dostupné z: [doi:10.1080/014311600210407](https://doi.org/10.1080/014311600210407)

GREEN, E. P., C. D. CLARK a A. J. EDWARDS, 2000. Geometric correction of satellite and airborne imagery. *Remote Sensing Handbook for Tropical Coastal Management*. Paris: UNESCO, s. 93-108.

HADJIMITSIS, D. G. et al., 2010. Atmospheric correction for satellite remotely sensed data intended for agricultural applications: impact on vegetation indices. *Natural Hazards and Earth System Sciences* [online]. **10**(1), 89-95 [cit. 2021-03-28]. ISSN 1684-9981. Dostupné z: doi:10.5194/nhess-10-89-2010

HALOUNOVÁ, L. a K. PAVELKA, 2005. *Dálkový průzkum Země*. Vyd. 1. Praha: Vydavatelství ČVUT. ISBN 80-01-03124-1.

HEROLD, N. D. a B. N. HAACK, 2006. Comparison and Integration of Radar and Optical Data for Land Use/Cover Mapping. *Geocarto International* [online]. **21**(4), 9-19 [cit. 2021-03-20]. ISSN 1010-6049. Dostupné z: doi:10.1080/10106040608542398

HOSSAIN, M. D. a D. CHEN, 2019. Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing* [online]. **150**, 115-134 [cit. 2021-03-21]. ISSN 09242716. Dostupné z: doi:10.1016/j.isprsjprs.2019.02.009

HUETE, A.R., 2004. Remote Sensing For Environmental Monitoring. *Environmental Monitoring and Characterization* [online]. Elsevier, s. 183-206 [cit. 2021-03-20]. ISBN 9780120644773. Dostupné z: doi:10.1016/B978-012064477-3/50013-8

CHEN, G. et al., 2011. Object-based change detection. *International Journal of Remote Sensing* [online]. **33**(14), 4434-4457 [cit. 2021-03-19]. ISSN 0143-1161. Dostupné z: doi:10.1080/01431161.2011.648285

JAIN, S.K. a V.P. SINGH, 2003. Acquisition and Processing of Water Resources Data. *Water Resources Systems Planning and Management* [online]. 51. Elsevier, s. 47-121 [cit. 2021-03-09]. Developments in Water Science. ISBN 9780444514295. Dostupné z: doi:10.1016/S0167-5648(03)80056-4

JANSSEN, L. a W. BAKKER, 2001. *Principles of remote sensing: an introductory textbook*. 2nd ed. Enschede, The Netherlands: International Institute for Aerospace Survey and Earth Sciences. ISBN 90-6164-199-3.

JANZEN, D. T., A. L. FREDEEN a R. D. WHEATE, 2014. Radiometric correction techniques and accuracy assessment for Landsat TM data in remote forested regions. *Canadian Journal of Remote Sensing* [online]. **32**(5), 330-340 [cit. 2021-03-28]. ISSN 0703-8992. Dostupné z: doi:10.5589/m06-028

JOSHI, N. et al., 2016. A Review of the Application of Optical and Radar Remote Sensing Data Fusion to Land Use Mapping and Monitoring. *Remote Sensing* [online]. **8**(1) [cit. 2021-03-21]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs8010070

KLOUČEK, T. et al., 2018. Selecting appropriate variables for detecting grassland to cropland changes using high resolution satellite data. *PeerJ* [online]. **6** [cit. 2021-03-19]. ISSN 2167-8359. Dostupné z: doi:10.7717/peerj.5487

KOLÁŘ, J., 1990. *Dálkový průzkum Země*. 1. vyd. Praha: Nakladatelství technické literatury. ISBN 8003005175.

KULKARNI, A. D. a B. LOWE, 2016. Random Forest Algorithm for Land Cover Classification. *International Journal on Recent and Innovation Trends in Computing and Communication* [online]. **4**(3), 58-63 [cit. 2021-03-27]. ISSN 2321-8169.

LAMBIN, E. F. a H. GEIST, ed., 2006. *Land-Use and Land-Cover Change* [online]. Berlin: Springer Berlin Heidelberg [cit. 2021-03-19]. Global Change - The IGBP Series. ISBN 978-3-540-32201-6. Dostupné z: doi:10.1007/3-540-32202-7

LEFSKY, M. A. et al., 2002. Lidar Remote Sensing for Ecosystem Studies. *BioScience* [online]. **52**(1), 19-30 [cit. 2021-02-21]. ISSN 0006-3568. Dostupné z: doi:10.1641/0006-3568(2002)052[0019:LRSFES]2.0.CO;2

LIAW, A. a M. WIENER, 2002. Classification and Regression by RandomForest. *R News* [online]. **2**, 18-22 [cit. 2021-03-27]. ISSN 1609-3631.

LILLESAND, T. M., R. W. KIEFER a J. W. CHIPMAN, 2015. *Remote Sensing and Image Interpretation*. 7th edition. Hoboken: John Wiley & Sons. ISBN 978-1-118-34328-9.

LORENCOVÁ, E. et al., 2013. Past and future impacts of land use and climate change on agricultural ecosystem services in the Czech Republic. *Land Use Policy* [online]. **33**, 183-194 [cit. 2021-03-23]. ISSN 02648377. Dostupné z: doi:10.1016/j.landusepol.2012.12.012

MAIN-KNORN, M. et al., 2017. Sen2Cor for Sentinel-2. In: *Image and Signal Processing for Remote Sensing XXIII* [online]. Warsaw: SPIE [cit. 2021-03-24]. ISBN 9781510613188. Dostupné z: doi:10.1117/12.2278218

NATIONAL RESEARCH COUNCIL, 2001. *Transforming Remote Sensing Data into Information and Applications* [online]. Washington, D.C: National Academies Press [cit. 2021-02-16]. ISBN 978-0-309-08271-6. Dostupné z: doi:10.17226/10257

NICULESCU, S. et al., 2018. Random forest classification using Sentinel-1 and Sentinel-2 series for vegetation monitoring in the Pays de Brest (France). In: *Remote Sensing for Agriculture, Ecosystems, and Hydrology XX* [online]. SPIE [cit. 2021-03-21]. ISBN 9781510621497. Dostupné z: doi:10.1117/12.2325546

NINOMIYA, Y. a B. FU, 2019. Thermal infrared multispectral remote sensing of lithology and mineralogy based on spectral properties of materials. *Ore Geology Reviews* [online]. **108**, 54-72 [cit. 2021-03-09]. ISSN 01691368. Dostupné z: doi:10.1016/j.oregeorev.2018.03.012

PAZÚR, R. et al., 2014. Spatial determinants of abandonment of large-scale arable lands and managed grasslands in Slovakia during the periods of post-socialist transition and European Union accession. *Applied Geography* [online]. **54**, 118-128 [cit. 2021-03-19]. ISSN 01436228. Dostupné z: doi:10.1016/j.apgeog.2014.07.014

PEDDLE, D.R. et al., 2001. Reflectance processing of reremote sensing spectroradiometer data. *Computers & Geosciences*. Canada: Pergamon, (27), 203-213.

PHIRI, D. et al., 2020. Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing* [online]. **12**(14) [cit. 2021-03-19]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs12142291

PILOYAN, A. a M. KONEČNÝ, 2017. Semi-Automated Classification of Landform Elements in Armenia Based on SRTM DEM using K-Means Unsupervised Classification. *Quaestiones Geographicae* [online]. **36**(1), 93-103 [cit. 2021-03-27]. ISSN 2081-6383. Dostupné z: doi:10.1515/quageo-2017-0007

PRIETO-AMPARAN, J. et al., 2018. Atmospheric and Radiometric Correction Algorithms for the Multitemporal Assessment of Grasslands Productivity. *Remote Sensing* [online]. **10**(2) [cit. 2021-03-22]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs10020219

SHIVAKUMAR, B. R. a S. V. RAJASHEKARARADHYA, 2018. Investigation on Land Cover Mapping Capability of Maximum Likelihood Classifier: A Case Study on North Canara, India. *Procedia Computer Science* [online]. India: Elsevier, **143**, 579-586 [cit. 2021-03-27]. ISSN 18770509. Dostupné z: doi:10.1016/j.procs.2018.10.434

SORIA-RUIZ, J., Y. FERNANDEZ-ORDOÑEZ a I. H. WOODHOUSE, 2010. Land-cover classification using radar and optical images: a case study in Central Mexico. *International Journal of Remote Sensing* [online]. **31**(12), 3291-3305 [cit. 2021-03-27]. ISSN 0143-1161. Dostupné z: doi:10.1080/01431160903160777

SPRACKLEN, B. a D. V. SPRACKLEN, 2021. Synergistic Use of Sentinel-1 and Sentinel-2 to Map Natural Forest and Acacia Plantation and Stand Ages in North-Central Vietnam. *Remote Sensing* [online]. **13**(2) [cit. 2021-03-21]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs13020185

TAS, 2021. *Sentinel-2 Products Specification Document* [online]. France: The European Space Agency, 524 s. [cit. 20.3.2021]. Dostupné z: <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/document-library/>

THIEL, C. et al., 2006. Radar remote sensing for the delineation of forest cover maps and the detection of deforestation. *Forestry* [online]. **79**(5), 589-597 [cit. 2021-02-21]. ISSN 0015-752X. Dostupné z: doi:10.1093/forestry/cpl036

TORRES, R. et al., 2012. The Sentinel-1 mission and its application capabilities. In: *2012 IEEE International Geoscience and Remote Sensing Symposium* [online]. The Netherlands: IEEE, s. 1703-1706 [cit. 2021-03-20]. ISBN 978-1-4673-1159-5. Dostupné z: doi:10.1109/IGARSS.2012.6351196

TROJÁČEK, P., 2003. New land parcel identification system for agricultural subsidies in the Czech Republic. In: BENES, Tomas, ed. *Geoinformation for European-wide Integration*. Rotterdam: Millpress, s. 557-559. ISBN 90-77017-71-2.

WULDER, M. A. a S. E. FRANKLIN, 2003. *Remote sensing of forest environments: concepts and case studies*. Boston: Kluwer Academic Publishers. ISBN 1-4020-7405-0.

ZEESHAN, M., R.R. DESHMUKH a S. SHAFIUDDIN, 2017. An Overview of Different Optical Remote Sensing Techniques. *International Journal of Engineering and Advanced Technology*. Maharashtra, (6), 181-183.

ZEKI, A. a M. ZAID, 2015. A supervised Multi-Spectral Image Classification for Remote Sensing Data. In: *Proceedings of the 2015 International Conference on Recent Advances in Computer Systems* [online]. Paris: Atlantis Press, s. 119-123 [cit. 2021-03-30]. ISBN 978-94-6252-146-9. Dostupné z: doi:10.2991/racs-15.2016.20

ZHU, L. et al., 2018. A Review: Remote Sensing Sensors. RUSTAMOV, R. B., S. HASANOVA a M. H. ZEYNALOVA, ed. *Multi-purposeful Application of Geospatial Data* [online]. InTech [cit. 2021-02-21]. ISBN 978-1-78923-108-3. Dostupné z: doi:10.5772/intechopen.71049



## Seznam tabulek

Tab. 1 Přehled dat pořízení jednotlivých snímků Sentinel-1 a Sentinel-2.....	29
Tab. 2 Matice změn orné půdy a TTP za rok 2015. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda.....	35
Tab. 3 Matice změn orné půdy a TTP za rok 2016. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda.....	36
Tab. 4 Matice změn orné půdy a TTP za rok 2017. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda.....	37
Tab. 5 Matice změn orné půdy a TTP za rok 2018. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda.....	38
Tab. 6 Matice změn orné půdy a TTP za rok 2019. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda.....	39
Tab. 7 Matice změn orné půdy a TTP za rok 2019. Diagonály každé z uvedených matic (Sentinel-2 a Sentinel-1+Sentinel-2) představují plochy, na kterých nedošlo ke změně, zbylá pole představují změnu na některou z hledaných	

tříd. Zelená barva představuje nejvyšší shodu třídy TTP, žlutá barva zvýrazňuje nejvyšší shodu třídy orná půda..... 40

Tab. 8 Přesnost klasifikace orné půdy a TTP za využití snímků Sentinel-2 a Sentinel-1 vyjádřená v % správně klasifikované plochy a celková přesnost klasifikace za použití jednotlivých metod..... 41

## Seznam příloh

Příloha 1 Mapy změn proběhlých na zemědělské půdě v modelové oblasti zájmového území za období let 2015–2020 ..... 59

Příloha 2 Mapa hodnot NDVI za období let 2015–2020 na vybrané části zájmového území ..... 60

## Seznam obrázků

Obr. 1 Princip DPZ (<http://maps.unomaha.edu> (upraveno)) ..... 13

Obr. 2 Spektrum elektromagnetického záření (<https://labguide.cz>)..... 14

Obr. 3 Spektrální křivky vody, půdy a zelené vegetace (<https://seos-project.eu>)..... 17

Obr. 4 Zájmové území sledování změn na zemědělské půdě – Liberecký kraj ..... 28

Obr. 5 Sentinel-2 (optické) a Sentinel-1 (radarové) snímky zájmové lokality v RGB kompozitu ..... 30

Obr. 6 Krabicové grafy hodnot NDVI na orné půdě v období let 2015–2020 ..... 42

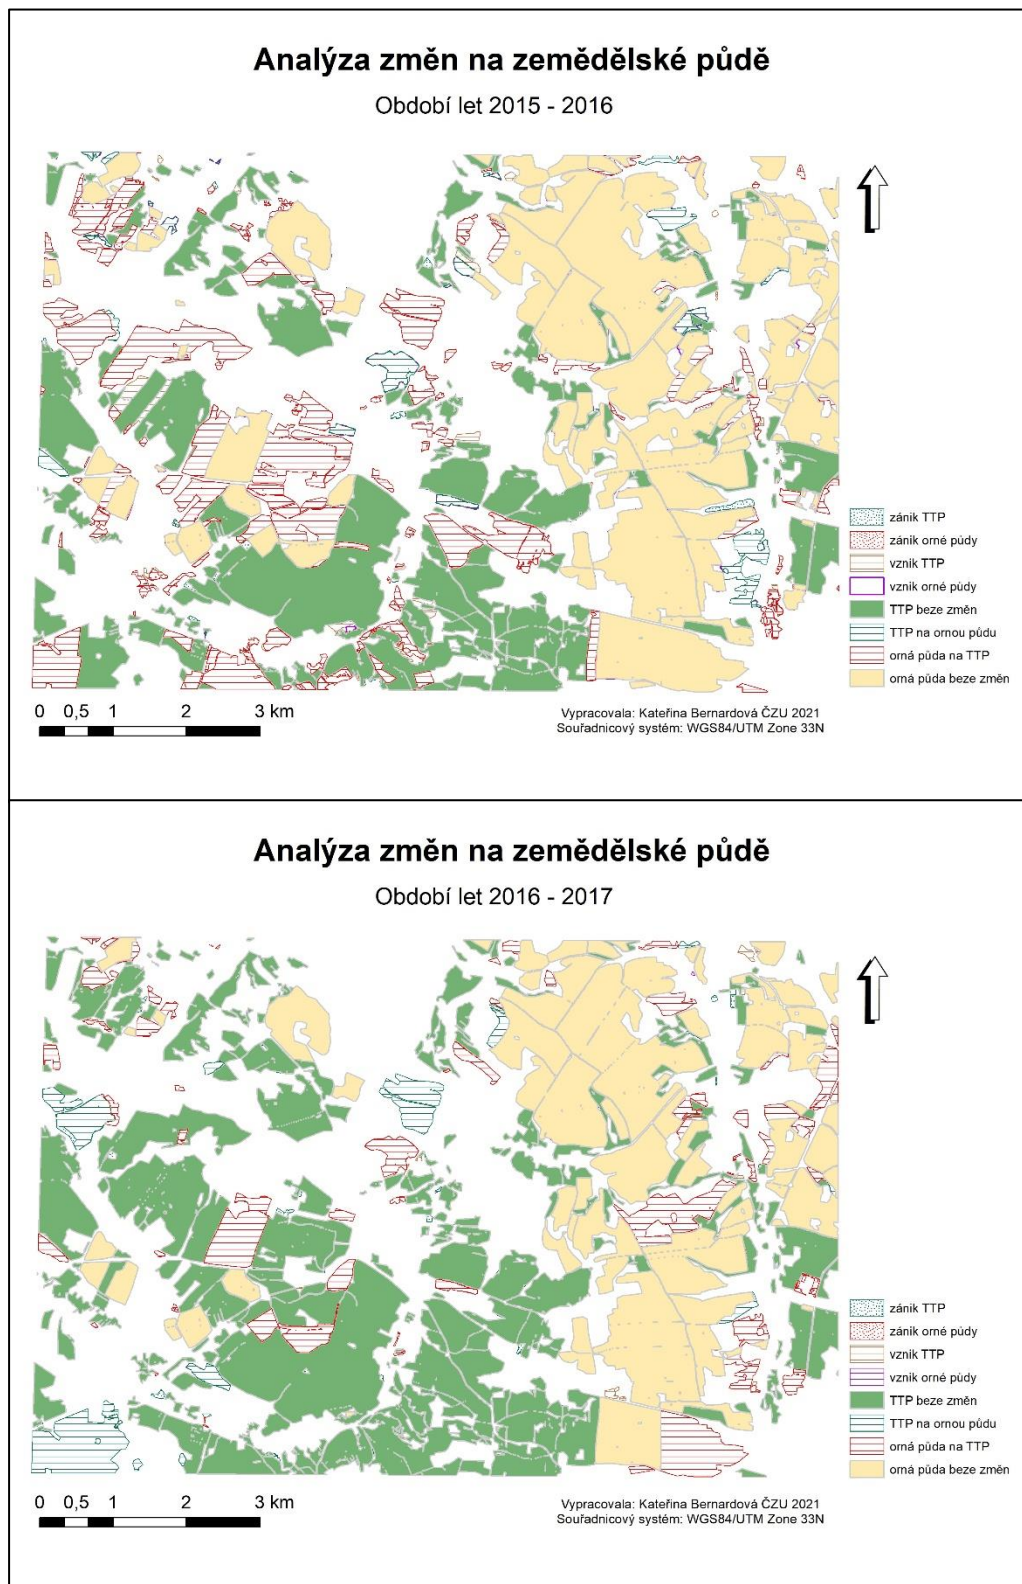
Obr. 7 Krabicové grafy hodnot NDVI na trvalém travním porostu v období let 2015–2020..... 43

Obr. 8 Hodnoty NDVI na vybrané části zájmového území v letech 2015, 2018 a 2020 (Interval hodnot 0,0 – 0,4 představuje holou ornou půdu, interval 0,4 – 0,6 představuje plochy orné půdy s vegetací, interval 0,6 – 1,0 jsou plochy TTP) ..... 44

Obr. 9 Mapa výsledných změn na orné půdě vybrané části zájmového území (2015–2020) ..... 45

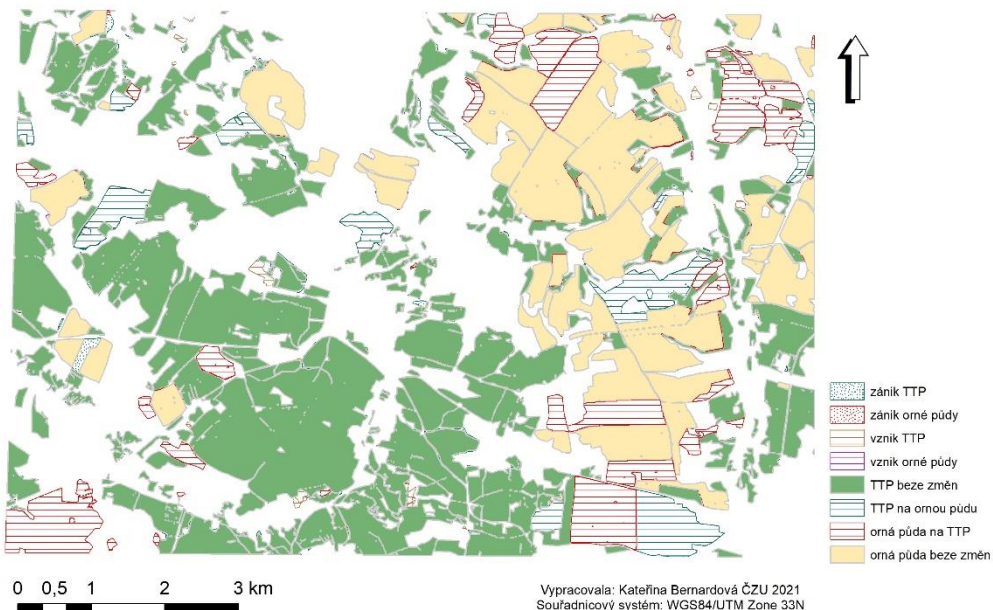
## Přílohy

Příloha 1 Mapy změn proběhlých na zemědělské půdě v modelové oblasti zájmového území za období let 2015–2020



## Analýza změn na zemědělské půdě

Období let 2017 - 2018



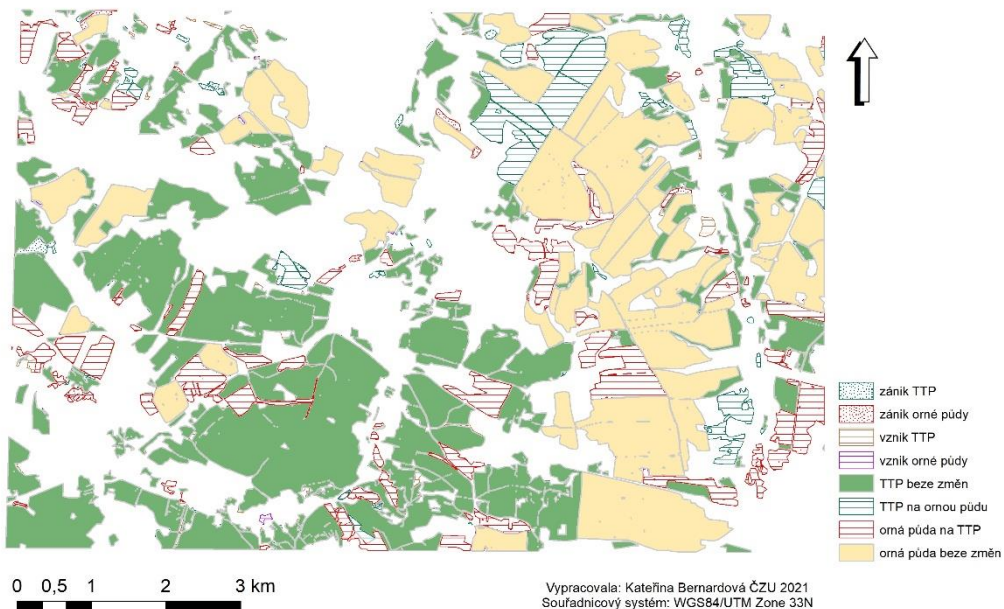
## Analýza změn na zemědělské půdě

Období let 2018 - 2019



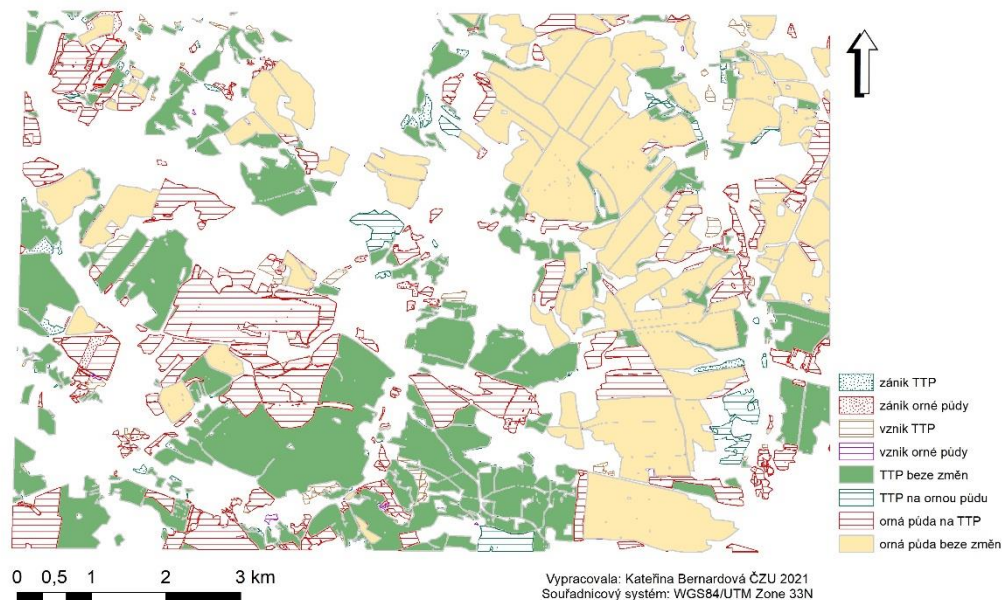
## Analýza změn na zemědělské půdě

Období let 2019 - 2020



## Analýza změn na zemědělské půdě

Období let 2015- 2020



Příloha 2 Mapa hodnot NDVI za období let 2015–2020 na vybrané části zájmového území

