

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE  
FAKULTA ŽIVOTNÍHO PROSTŘEDÍ  
KATEDRA PROSTOROVÝCH VĚD

Fenologie zemědělských plodin dle multispektrálních  
dat Sentinel-2  
Bakalářská práce

Vedoucí práce: doc. Ing. Petra Šímová, Ph.D.  
Bakalant: Jakub Fér

2022

## ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Jakub Fér

Geografické informační systémy a dálkový průzkum Země v životním prostředí

Název práce

**Fenologie zemědělských plodin dle multispektrálních dat Sentinel-2**

Název anglicky

**Crops phenology as derived from multispectral data of Sentinel-2**

---

### Cíle práce

Družicová data Sentinel-2 umožňují svým prostorovým i časovým rozlišením sledování fenologie plodin na jednotlivých půdních blocích (polích) a potažmo získávat důležité informace pro monitoring plodin na rozsáhlých plochách. V ČR je nicméně nedostatek studií popisujících fenologii plodin v souvislosti s podmínkami lokality (poloha, osevňovací postupy, sklon a expozice polí a podobně). Hlavním cílem práce je na příkladu zvolené farmy popsat pomocí vhodných vegetačních indexů spektrální změny zemědělských plodin v průběhu agronomického roku (zejména vegetační sezóny) a pro jednotlivé plodiny nalézt fenofáze, ve kterých se spektrálně nejvíce liší od ostatních plodin na lokalitě. Formulace dílčích cílů je úkolem autora.

### Metodika

Autor si zvolí modelové území a získá od farmáře potřebná data o osevňovacích postupech. Na základě literatury zvolí vhodný časový interval a vhodné vegetační indexy pro sledování spektrálního vývoje jednotlivých plodin. Výsledky představí slovně a v podobě grafů (zejména vývoje hodnot indexu či indexů pro danou plodinu v čase). Pokusí se pro každou plodinu definovat dobu (fenofázi), ve které lze plodinu nejlépe odlišit od ostatních.

## **Doporučený rozsah práce**

40 – 60 stran

## **Klíčová slova**

formulace klíčových slov je úkolem autora

---

## **Doporučené zdroje informací**

- Atzberger, C., G. Duveiller, R. Zurita-Milla, J. M. A. Duncan, J. Dash, and P. M. Atkinson. 2015. The potential of satellite-observed crop phenology to enhance yield gap assessments in smallholder landscapes. *Frontiers in Environmental Science* | [www.frontiersin.org](http://www.frontiersin.org) 1:56.
- 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.
- Belgiu, M., W. Bijker, O. Csillik, and A. Stein. 2021. Phenology-based sample generation for supervised crop type classification. *International Journal of Applied Earth Observation and Geoinformation* 95:102264.
- Bolton, D. K., J. M. Gray, E. K. Melaas, M. Moon, L. Eklundh, and M. A. Friedl. 2020. Continental-scale land surface phenology from harmonized Landsat 8 and Sentinel-2 imagery. *Remote Sensing of Environment* 240:111685.
- Meroni, M., R. D'Andrimont, A. Vrieling, D. Fasbender, G. Lemoine, F. Rembold, L. Seguini, and A. Verhegghen. 2021. Comparing land surface phenology of major European crops as derived from SAR and multispectral data of Sentinel-1 and -2. *Remote Sensing of Environment* 253:112232.

---

## **Předběžný termín obhajoby**

2021/22 LS – FZP

## **Vedoucí práce**

doc. Ing. Petra Šímová, Ph.D.

## **Garantující pracoviště**

Katedra prostorových věd

Elektronicky schváleno dne 21. 3. 2022

**doc. Ing. Petra Šímová, Ph.D.**

Vedoucí katedry

Elektronicky schváleno dne 21. 3. 2022

**prof. RNDr. Vladimír Bejček, CSc.**

Děkan

V Praze dne 21. 03. 2022

## ČESTNÉ PROHLÁŠENÍ

Prohlašuji, že jsem bakalářskou/závěrečnou práci na téma: Fenologie zemědělských plodin dle multispektrálních dat Sentinel-2 vypracoval samostatně a citoval jsem všechny informační zdroje, které jsem v práci použil a které jsem rovněž uvedl na konci práce v seznamu použitých informačních zdrojů.

Jsem si vědom, že na moji bakalářskou 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 vědom, že odevzdáním bakalářské 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 dne .....

.....

## PODĚKOVÁNÍ

Touto cestou bych chtěl poděkovat vedoucí své práce doc. Ing. Petře Šimové Ph.D., za vedení mé práce, za cenné rady při psaní této práce a za trpělivost, kterou prokázala. Vedení a zaměstnancům společnosti Kalenská Zemědělská a.s., jmenovitě Zdeňku Kobrlemu, Petru Jiříčkovi, Martinu Grofovi a Pavlu Máslovi, za poskytnutí klíčových informací potřebných k vypracování této práce, za možnost z blízka sledovat jejich práci a za trpělivost s mými dotazy. V neposlední řadě také rodině a přátelům z oboru za psychickou podporu.

**Abstrakt:** Dálkový průzkum země hraje v zemědělství stále větší roli. V České republice však tento trend zaostává za některými vyspělejšími státy. V ČR neexistuje aktuální databáze pěstovaných plodin, pro výzkum krajinného pokryvu, zdravotního stavu plodin, fenologie plodin atd. je tedy nutné získávat data přímo od majitelů, či správců pozemků, což je pro větší zájmová území komplikované a neefektivní. Druhou možností je spoléhat na různé klasifikační metody, jejich přesnost je ovšem závislá na mnoha faktorech, které nemusí být uživateli vždy známy.

Tato práce popisuje spektrální vývoj zemědělských plodin na pozemcích společnosti Kalenská Zemědělská a.s., které se nacházejí v Královéhradeckém kraji, v katastrálních územích Horní Kalná, Dolní Kalná, Slemeno v Podkrkonoší a Klášterská Lhota, a celková rozloha pozemků je přibližně 1045 ha. V průběhu roku 2021 sleduje vývoj indexů NDVI a SAVI pro dané plodiny a jejich souvislost s fenologií, a porovnává přesnosti řízené klasifikace v různých měsících. Výsledky ukázaly, že u širokořádkových plodin (kukuřice, čirok), vzhledem k náchylnosti na erozi a další negativní vlivy, je popsání vývoje vegetačních indexů v průběhu sezóny velmi obtížné a výsledky pro tyto plodiny nebyly průkazné. U ječmene, ovsa a řepky výsledky byly více konzistentní a fenologie těchto rostlin může být prostřednictvím vybraných vegetačních indexů dobře sledována. Samotné rozdíly mezi NDVI a SAVI se ukázaly být zanedbatelné. Co se týče přesnosti řízené klasifikace, pro klasifikaci všech plodin najednou, se jako nejvýhodnější jevil měsíc červenec, kdy hodnota indexu shodnosti Kappa byla 0,60. Rovněž byla testována klasifikace na základě kompozitu složeného z rastrů hodnot NDVI pro jednotlivé měsíce, ta dosáhla nejvyšší celkové přesnosti, index Kappa zde dosáhl přibližně 0,68. Rovněž se jeví jako nejvýhodnější pro odlišení ječmene a ovsa.

**Klíčová slova:** dálkový průzkum Země, fenologie, zemědělství, klasifikace plodin, vegetační indexy, NDVI, SAVI, Sentinel-2

**Abstract:** Remote sensing is playing an increasingly important role in agriculture. In the Czech Republic, however, this trend is lagging behind some more developed countries. There is no up-to-date database of cultivated crops in the Czech Republic, so for research on landcover, crop health, crop phenology, etc. it is necessary to obtain data directly from land owners or managers, which is complicated and inefficient for larger areas of interest. The other option is to rely on various classification methods, but their accuracy depends on many factors that may not be always known to the user.

This paper describes the spectral development of agricultural crops on the land of the company Kalenská Zemědělská a.s., located in the Hradec Králové region, in the cadastral areas of Horní Kalná, Dolní Kalná, Slemeno v Podkrkonoší and Klášterská Lhota. Total area of the land is approximately 1045 ha. It monitors the temporal patterns of the NDVI and SAVI indices for the crops and their relationship with phenology during 2021, and compares the accuracy of the supervised classification in different months. The results showed that for broad row crops (maize, sorghum), due to their susceptibility to erosion and other negative influences, describing the evolution of vegetation indices over the season is very difficult and the results for these crops were not conclusive. For barley, oats and rape, the results were more consistent and the phenology of these crops can be well monitored through the selected vegetation indices. The differences between NDVI and SAVI alone proved to be negligible. Regarding the accuracy of the supervised classification, the month of July appeared to be the most suitable for classifying all crops at once, with a Kappa index of agreement value of 0.60. A classification based on a composite of raster NDVI values for each month was also tested and achieved the highest overall accuracy, with a Kappa index of approximately 0.68. It also appears to be the most suitable for distinguishing between barley and oats.

Keywords: remote sensing, agriculture, phenology, crop classification, vegetation indices, NDVI, SAVI, Sentinel-2

## Obsah

1.	Úvod a cíle .....	1
2.	Literární rešerše.....	2
2.1.	Zemědělství a GIS .....	2
2.2.	Dálkový průzkum Země a fenologie plodin.....	3
2.3.	Vegetační indexy a fenologie plodin.....	4
2.4.	Využití sledování vegetačních indexů v zemědělství.....	6
2.5.	Sentinel-2.....	7
2.6.	Používané vegetační indexy .....	9
2.6.1.	NDVI.....	9
2.6.2.	SAVI .....	9
3.	Metodika .....	10
3.1.	Popis zájmového území .....	10
3.2.	Data .....	14
3.3.	Zjištění vývoje indexů NDVI pro jednotlivé plodiny .....	14
3.4.	Zjištění vývoje spektrálních křivek jednotlivých plodin.....	16
3.5.	Zjištění vývoje indexů SAVI pro jednotlivé plodiny .....	17
3.6.	Řízená klasifikace a posouzení její přesnosti .....	17
4.	Výsledky .....	19
4.1.	Vývoj NDVI.....	19
4.1.1.	Kukuřice.....	19
4.1.2.	Ječmen.....	20
4.1.3.	Oves .....	21
4.1.4.	Řepka.....	21
4.2.	Vývoj SAVI.....	22
4.2.1.	Kukuřice.....	22
4.2.2.	Ječmen.....	23
4.2.3.	Oves .....	23
4.2.4.	Řepka.....	24



4.3.	Vývoj spektrálních křivek .....	25
4.4.	Posouzení přesností řízených klasifikací.....	27
5.	Diskuse.....	32
6.	Závěr .....	34
7.	Seznam zdrojů.....	35
8.	Přílohy.....	39
8.1.	Příloha č. 1:.....	39

Obrázek 1 - Zájmové území (foto: archiv autora).....	10
Obrázek 2 - Přehled plodin v zájmovém území .....	11
Obrázek 3 - Sklizeň kukuřice na siláž – zájmové území, Slemeno (foto: archiv autora) .....	11
Obrázek 4 - Sklizeň ječmene – systém GPS (Ganzpflanzenschrot) – zájmové území, za autokempem (foto: archiv autora) .....	12
Obrázek 5 - Sklizeň sladovnického ječmene – zájmové území, Příčnice (foto: archiv autora) .....	12
Obrázek 6 - Oves – zájmové území, Nový Svět (foto: archiv autora) .....	13
Obrázek 7 - Sklizeň řepky – zájmové území, Příčnice (foto: archiv autora) .....	13
Obrázek 8 - Model pro získání hodnot NDVI jednotlivých plodin (výřez).....	15
Obrázek 9 - Model použitý pro získání hodnot pásem Sentinel-2 na vybraném poli (výřez) .....	16
Obrázek 10 - Script použitý pro spojení tabulek.....	16
Obrázek 11 - Model použitý pro získání hodnot SAVI (výřez).....	17
Obrázek 12 - Ukázka trénovacích vzorků použitých pro klasifikaci .....	18
Obrázek 13 - Vývoj indexu NDVI v průběhu roku na polích s kukuřicí.....	19
Obrázek 14 - Vývoj NDVI v průběhu roku na polích s ječmenem.....	20
Obrázek 15 - Vývoj NDVI v průběhu roku na polích s ovsem.....	21
Obrázek 16 - Vývoj NDVI v průběhu roku na polích s řepkou .....	21
Obrázek 17 - Vývoj SAVI v průběhu roku na polích s kukuřicí .....	22
Obrázek 18 - Vývoj SAVI v průběhu roku na polích s ječmenem .....	23
Obrázek 19 - Vývoj SAVI v průběhu roku na polích s ovsem .....	23
Obrázek 20 - Vývoj SAVI v průběhu roku na polích s řepkou.....	24
Obrázek 21 - Vývoj spektrální křivky kukuřice.....	25
Obrázek 22 - Vývoj spektrální křivky ječmene .....	25
Obrázek 23 - Vývoj spektrální křivky ovsa .....	26
Obrázek 24 - Vývoj spektrální křivky řepky.....	26
Obrázek 25 - Porovnání Producer's accuracy .....	29
Obrázek 26 - Porovnání User's accuracy .....	30

Obrázek 27 - Srovnání hodnot indexu shodnosti Kappa.....	30
Obrázek 28 - Porovnání výsledků klasifikací pro červenec (vlevo), NDVI kompozit (uprostřed) a referenčního rastru (vpravo) .....	31

# 1. Úvod a cíle

V posledních letech je ve všech sférách průmyslu kladen důraz na přesnost, kvalitu a efektivitu. Panuje snaha maximálně využít potenciál dostupných zdrojů a minimalizovat jakékoliv negativní vlivy na životní prostředí. Současně se zvyšují nároky na produkci veškerého zboží, neboť lidská populace neustále roste.

Tyto trendy se samozřejmě nevyhnuly ani zemědělství. Naopak zemědělství je v současné době stále důležitější a pokud chceme uživit stále rostoucí populaci, musíme vynaložit nemalé úsilí na jeho rozvoj.

Precision farming představuje významný krok pro zvýšení efektivity, maximalizaci výnosů, jejich ochranu a ochranu životního prostředí. V posledních letech lze zaznamenat rozvoj využití technologií GNSS v zemědělství, stoupající potenciál geografických informačních systémů a také zájem o využívání dat dálkového průzkumu Země.

Data ze systémů Landsat a Sentinel jsou poskytována bezplatně a jejich zpracování je možné v otevřeném software. Tyto systémy navíc umožňují sledování kteréhokoliv místa na Zemi a data z nich tedy mohou pomoci identifikovat problémy, se kterými se zemědělci potýkají ještě dříve, než dojde na jejich následky.

Pro efektivnější plánování místního rozvoje, alokace strategických zdrojů a pro možnost reagovat na nepředvídané události je potřeba mít co největší přehled o daném území. Sledování fenologie zemědělských plodin na velkých územích je v současné chvíli velmi obtížné. V ČR dnes není možné získat aktuální přehled pěstovaných plodin na jednotlivých pozemcích veřejného registru. Pokud chceme sledovat fenologii pěstovaných plodin, musíme mít data o plodinách pěstovaných na daném území v daném období. Tato data by nám mohla poskytnout řízená klasifikace, ovšem její přesnost se různí.

Hlavním cílem této práce bylo za pomoci vegetačních indexů v průběhu vegetační sezóny popsat spektrální změny jednotlivých zemědělských plodin na modelovém území o kterém mám dostupné referenční informace. Zároveň bylo cílem ze získaných dat určit období ve kterém se jednotlivé plodiny nejvíce liší. Vedlejším cílem bylo poté zjistit přesnost řízené klasifikace v různých obdobích a přesnost klasifikace kompozitu složeného z rastrů indexu NDVI pro jednotlivé měsíce.

## 2. Literární rešerše

### 2.1. Zemědělství a GIS

V současné době je ochrana životního prostředí stále více v centru pozornosti. Tuto tendenci lze pozorovat i v případě zemědělství, protože se klade důraz zejména na přímou či nepřímou spotřebu zdravých potravin člověkem. Důležitá je také otázka ekonomiky. V západní Evropě a USA je systém přesné rostlinné výroby, který zohledňuje proměnlivost na poli, dobře známý a stále populárnější. Současně mají výsledky výzkumu velmi nízkou spolehlivost. v praktických podmínkách.

Geografický informační systém (GIS) je výkonný soubor nástrojů pro sběr, ukládání a vyhledávání dat podle libosti, transformaci a zobrazení prostorových dat pro konkrétní účel (Burrough et al. 1998). Přesné zemědělství je způsob hospodaření, který zohledňuje proměnlivost na poli, technologie, při níž aplikace – setí, výměna živin, postřik atd. - působí na místní podmínky daného pole. Globální systém určování polohy (GPS) umožňuje zaznamenávat proměnlivost na poli jako geograficky zakódované údaje. Správnou polohu je možné určovat a zaznamenávat průběžně. Tato technologie zohledňuje zemědělské plochy, pole podrobněji než dříve, proto je uživateli k dispozici větší databáze. Pro ukládání a zpracování těchto dat je nezbytné použití geografického informačního systému (GIS). GIS vytvořený na základě výpočetního zázemí umožňuje vytvářet komplexní pohled na naše pole a činit agrotechnologická rozhodnutí (Pecze et al., 2001).

Produkce potravin, krmiv a hmoty závisí na množství a kvalitě půdy, rostlin, vody a vzduchu. Bez ohledu na to, jaké zemědělské systémy se používají, bez ochrany přírodních zdrojů budou výnosy klesat až do bodu, z něhož není návratu (Tayari et al., 2015).

Monitorování plodin je možná nejzásadnější součástí precizního zemědělství. Tradiční metoda monitorování plodin, která se provádí vážením sklizených plodin, poskytuje způsob, který může být v současné době užitečný při monitorování plodin v precizním zemědělství. Například při sklizni obilovin využívá moderní monitoring snímače, které jsou umístěny na kombajnu a zaznamenávají množství sklizené plodiny spolu s rychlostí sklizně (Tayari et al., 2015).

Schopnost GIS analyzovat a vizualizovat zemědělské prostředí a pracovní postupy se ukázala jako velmi přínosná pro ty, kteří se zabývají zemědělstvím. Vyváženost vstupů a výstupů na farmě je základem jejího úspěchu a ziskovosti. Prostorová data mají běžně podobu vrstev, které mohou zobrazovat topografii nebo prvky životního prostředí. V současné době se technologie GIS stává základním nástrojem pro kombinaci různých mapových a satelitních informačních zdrojů v modelech, které

simulují interakce složitých přírodních systémů. Pomocí GIS lze vytvářet nejen mapy, ale i kresby, animace a další kartografické produkty. Od mobilních GIS v terénu až po vědeckou analýzu výrobních dat v kanceláři manažera farmy – GIS hrají stále větší roli v zemědělské výrobě po celém světě, protože pomáhají zemědělcům zvyšovat produkci, snižovat náklady a efektivněji hospodařit s půdou. Přírodní vstupy v zemědělství sice nelze kontrolovat, ale lze je lépe pochopit a řídit pomocí aplikací GIS, jako jsou odhady výnosů plodin, analýzy půdních doplňků a identifikace a sanace eroze. Pro simulaci regionální produktivity plodin je v této studii nejprve vyvinut prostorový model plodin, který je integrace geografického informačního systému (GIS) s modelem Environmental Policy Integrated Climate (EPIC) (Neményi et al., 2003).

Schopnost GIS analyzovat a vizualizovat zemědělské prostředí a pracovní toky se ukázala jako velmi přínosná pro ty, kteří se zabývají zemědělstvím. Vyváženost vstupů a výstupů v zemědělském podniku je základem jeho úspěchu a ziskovosti. Prostorová data mají běžně podobu vrstev, které mohou zobrazovat topografii nebo prvky životního prostředí. V současné době se technologie GIS stává základním nástrojem pro kombinování různých mapových a satelitních informačních zdrojů v modelech, které simulují interakce složitých přírodních systémů (Rana, et al. 2015).

## 2.2. Dálkový průzkum Země a fenologie plodin

Co je dálkový průzkum Země? Jedná se o přesné získávání informací o objektu na dálku, aniž by došlo ke kontaktu s tímto objektem. Přestože je dálkový průzkum Země využíván již desítky let, jeho význam pro zemědělství v oblasti řízení prostorové variability je relativně nový. Dálkový průzkum měří viditelné a neviditelné vlastnosti pole nebo skupiny polí a převádí bodová měření na prostorové informace, aby bylo možné sledovat časově dynamický stav rostlin a půdy (Moran et al., 1997).

Pomocí DPZ a GIS lze identifikovat období zralosti, stresy plodin, jako je nedostatek živin a vody, choroby, napadení škůdci a plevelem. Informace shromážděné pomocí různých senzorů a referencované pomocí GPS lze integrovat za účelem vytvoření strategií pro aplikaci chemických látek, kultivaci, a sklizeň.

Terénní ekologické studie prokázaly, že fenologie vegetace má tendenci sledovat poměrně dobře definované časové vzorce. Například u listnaté vegetace a mnoha plodin následuje po rašení listů období rychlého růstu, po němž následuje relativně stabilní období maximální listové plochy (Zhang et al., 2003).

### 2.3. Vegetační indexy a fenologie plodin

K přípravě dat ze senzorů pro aplikace LSP (land surface phenology) se běžně používá řada spektrálních transformací. Tyto transformace jsou určeny ke zlepšení spektrálních odrazových a emisních charakteristik vegetace nebo podmínek prostředí, které souvisejí s fenologickým vývojem. Mezi tyto podmínky patří změna listové plochy, vlhkosti půdy a obsahu vody ve vegetaci. Soubor transformací souhrnně označovaných jako vegetační indexy (VI) využívá odrazové vlastnosti vegetace v červené a blízké infračervené vlnové délce. Rostliny obecně absorbují energii ve vlnových délkách 0,6-0,7  $\mu\text{m}$  elektromagnetického spektra (chlorofyl absorbuje červenou energii) a velmi silně odrážejí v blízké infračervené oblasti (NIR). Družicové senzory, které jsou určeny pro analýzy zemského povrchu, obvykle shromažďují data v pásmech, která se blíží červené a blízké infračervené vlnové délce, aby bylo možné rozlišit a zvýraznit měnící se podmínky zemského povrchu. Vegetační indexy využívají reflexních vlastností vegetace často pomocí určitého poměru a/nebo diferenciací červeného a NIR pásma odrazivosti nebo využívají jiné vlnové délky pro snížení vlivu atmosférických aerosolů nebo půdního pozadí (modrá odrazivost) a pro zvýraznění obsahu vody v listech. Normalized difference vegetation index (NDVI) je běžně používaný index pro studium vegetace (Defries & Townshend, 2007; Goward et al., 1985; Malingreau, 1989; Running et al., 1995; Tucker & Sellers, 1986). NDVI je silně vázán na červenou odrazivost, která souvisí s fotosyntetickou kapacitou vegetace a biofyzikálními proměnnými, jako je podíl fotosynteticky aktivního záření (fPAR) a frakční zelený pokryv (Huete et al., 1997). Dalšími indexy byly fenologie dálkového průzkumu Země: včetně soil adjusted vegetation index (SAVI) (A. R. Huete, 1988a) a soil and atmospheric resistant vegetation index (SARVI) (Kaufman & Tanré, 1992). SAVI a SARVI jsou těsněji spojeny s odrazivostí v blízkém infračerveném pásmu a s parametry, jako je Leaf area index (LAI) a biomasa. Enhanced vegetation index (EVI) je rozšířením pokroku dosaženého při snižování atmosférických vlivů (Huete et al., 2002), jehož cílem je zlepšit citlivost a snížit signál pozadí korun stromů a atmosférických vlivů. EVI zahrnuje modré pásmo odrazivosti, aby se korigoval vliv atmosférických aerosolů na červenou odrazivost.

Ahl et al., (2006) použili v roce 2002 data MODIS nad listnatým lesem v severním Wisconsinu a pozorovali, že družicové produkty měly tendenci předpovídat nástup zeleně a zralosti o 1 až 21 dní dříve než terénní pozorování. Autoři uvádějí, že je zapotřebí dalšího výzkumu vlivu fenologie na výměnu uhlíku a vody, zejména pro přechodné období mezi rašením pupenů a plnou fotosyntetickou kapacitou. Konkrétně je třeba získat více informací o délce vegetačního období jako limitujícím faktoru produktivity a toku uhlíku a je třeba lépe parametrizovat modely pro měnící se

povrchové podmínky, jako je albedo nebo drsnost povrchu. Větší znalosti v těchto oblastech by vedly ke zlepšení modelů, které mění hodnoty určitých parametrů v předem stanovených obdobích roku. Lepšího pochopení problematiky, která je základem těchto otázek, lze dosáhnout analýzou více současně shromážděných dat na místech intenzivního fenologického pozorování. Může se jednat o přístrojově vybavená výzkumná místa, jako jsou stanice Ameriflux nebo stanice dlouhodobého ekologického výzkumu, kde lze shromažďovat pozorování počasí, biogeochemie, satelitních snímků a fenologie rostlin.

Monitorování v reálném čase a krátkodobé předpovědi fenologie mohou významně přispět k obhospodařování půdy, lidskému zdraví a dalším aplikacím (White & Nemani, 2006). Fenologické předpovědi založené na datech dálkového průzkumu Země, ve spojení s odhady nejistot by mohly být využity pro odhad budoucích podmínek pro pěstování plodin, požárů a dalších činností. nebezpečí požárů a potenciálně přispět k včasnému varování před suchem. Kathuroju et al. (2007) použili LSP odvozené z AVHRR (advanced very high resolution radiometer) k vývoji prognóz fenologických modelů a testovali tyto modely s klimatologickými fenologickými hodnotami. Z AVHRR prognostický model nedosáhl lepších výsledků než při použití průměrného datového modelu. Autoři uvádějí, že jiné, pokročilejší senzory nebo přidání sněhových a atmosférických informací mohou přinést lepší výsledky. Naznačují také, že modely specifické pro jednotlivé druhy ve spojení s LSP mohou být vhodnějším přístupem.

Nedávný vývoj v oblasti bezplatných dat Landsat, která jsou dostupná přes web, může být také otevřít dveře rychlému pokroku ve fenologických studiích povrchu půdy. 30 m Landsat nabízí vhodné měřítko pro propojení pozemního s rodinou družicových senzorů s vysokou časovou frekvencí. Jakmile budou vyvinuty techniky pro efektivní využití družice Landsat pro fenologické studie, bude možné rozšířit fenologický záznam až do 70. let 20. století a získat tak cenné informace za několik desetiletí, které bude možné využít pro studie klimatických změn.

Sledování růstu plodin a fenologických proměnných odvozených z dat dálkového průzkumu Země může pomoci při rozlišování orné půdy od neorné půdy, protože orná půda má zjevně odlišný časový a spektrální podpis od nevegetačních povrchů (např. vodních ploch, měst). Důležité je, že hodnota dynamiky a fenologie růstu plodin je zřejmější při oddělení zpracování orné půdy od ostatních vegetačních půdních povrchů; například vícedatové snímky zachycující odlišné cykly zelenání a stárnutí obilovin se výrazně liší od cyklů lesů (Dash et al., 2010). Po identifikaci plodin mohou profily růstu plodin získané dálkovým průzkumem, které odrážejí fenologii plodin, poskytnout značné množství informací o jednotlivých plodinách. Časové řady



pozorování dálkového průzkumu Země nad obdělávanými pozemky a získání fenologických informací navíc usnadňují sledování prostorových vzorců intenzity pěstování plodin (tj. jednoplošného, dvouplošného a tříplošného pěstování (Biradar & Xiao, 2011; Dash et al., 2010; Vrieling et al., 2013).

Několik studií využilo rozdíly v růstových profilech plodin a fenologických proměnných v různých klasifikačních postupech k identifikaci různých typů plodin. (Wardlow et al., 2007) zdůraznili výhodu snímků z více období oproti snímkům z jednoho období pro monitorování obdělávaných ploch, a to i v případě, že snímky z jednoho období mají jemnější prostorové rozlišení, protože různé plodiny mohou v jednom časovém kroku vypadat spektrálně podobně, ale v průběhu vegetačního období mají různé profily. Xiao et al. (2005) používají časové profily měření EVI a Land Surface Water Index (LSWI) k identifikaci rýžových polí. Používají vyhledávací algoritmus, který identifikuje vrchol LSWI odpovídající zaplaveným polím na začátku vegetačního období rýže, po němž následuje rychlý nárůst EVI, když plodina vstupuje do fáze vegetativního vývoje. Techniky spektrálního porovnávání (SMT) využívají statistická měřítka podobnosti tvaru a amplitudy časových profilů vegetačních indexů ke klasifikaci pixelů do různých typů plodin, způsobů pěstování a charakteristik zavlažování ((Melesse et al., 2007). Thenkabail & Wu (2005) spojili snímky MODIS za delší období, zachycující fenologii různých typů obdělávaných ploch a půdního pokryvu, s dalšími soubory dat dálkového průzkumu Země v automatizovaném algoritmu klasifikace obdělávaných ploch, aby vytvořili mapy zavlažovaných vs. dešťových ploch nad Tádžikistánem. Jiné studie ukázaly, jak je možné rozlišovat mezi různými typy plodin na základě načasování různých fenologických fází (např. nástup zeleně, vrchol zeleně) pozorovaných z dat dálkového průzkumu Země z více dat (Wardlow et al., 2007).

#### 2.4. Využití sledování vegetačních indexů v zemědělství

Vegetační indexy a biofyzikální proměnné získané dálkovým průzkumem Země poskytují údaje o množství a stavu zelené vegetace na povrchu půdy a tyto informace lze následně použít k odhadu biomasy. Výnos plodin, který představuje hospodářsky nebo nutričně využívanou část rostliny, je podílem celkové biomasy a zeleného vegetačního krytu. Schopnost přesného odhadu výnosu plodin z dálkového průzkumu Země tedy závisí na míře korelace mezi celkovou biomasou a výnosem plodin a na schopnosti vegetačních indexů nebo biofyzikálních měř získaných dálkovým průzkumem Země zachytit změny biomasy. Poměr celkové biomasy plodin a výnosu plodin je znám jako index sklizně (HI) a v modelech pro odhad výnosu plodin je třeba zohlednit rozdíly v HI mezi plodinami ((Bastiaanssen & Ali, 2003). Také různé odrůdy téže plodiny mají různý HI; například mezi vysoce výnosnými a tradičními odrůdami

rýže existují rozdíly ve struktuře rostlin a rozdíly v HI v závislosti na podmínkách prostředí a způsobech hospodaření (Wassmann et al., 2009). Rozdíly v odrůdách vysazených v rámci osevních ploch je obtížné rozlišit z údajů dálkového průzkumu a vnášejí do odhadů výnosů určitou chybu. K odhadu výnosu plodin z dat dálkového průzkumu Země se používají dva hlavní přístupy; zaprvé regresní modely natrénované pomocí vegetační indexy nebo biofyzikálních měř a statistiky výnosu plodin a zadruhé začlenění vegetačních indexů, spektrální odrazivosti nebo biofyzikálních proměnných (např. LAI) do modelů simulace růstu plodin (Rembold et al., 2013). Vegetační indexy jsou často využívány jako nezávislé proměnné v regresních modelech pro předpověď výnosu plodin, zatímco míry spektrální odrazivosti jsou často používány k odhadu biofyzikálních proměnných (Lobell et al., 2003), které jsou následně začleněny do modelů simulace růstu plodin.

Snímky z delšího období umožňují odhalit prostorové vzorce intenzity pěstování plodin (Dash et al., 2010; Vrieling et al., 2013). Tyto informace mohou odhalit, kde by bylo možné zvýšit produkci plodin, a tedy i roční výnosy na jednotku půdy, tím, že by se půda obdělávala po větší část doby (na rozdíl od zvýšení produktivity pozemku v daném období). Duncan et al. (2014) ukazují, jak lze fenologii plodin získanou dálkovým průzkumem využít ke sledování prostorové dynamiky intenzity pěstování plodin v průběhu zhruba 20 let v severní Indii. To by mohlo mít významné důsledky pro potravinovou bezpečnost drobných zemědělců, protože zkrácení doby úhoru zvyšuje produktivní výnosy ze stávajících zdrojů (např. půdy nebo práce). V takových situacích však bude pravděpodobně nutná další pomoc (např. poradenství) nebo státní pobídky, aby drobní zemědělci byli motivováni a mohli plně využít zvýšené intenzity pěstování plodin.

## 2.5.Sentinel-2

Mise Copernicus Sentinel-2 se skládá ze soustavy dvou družic umístěných na stejné heliosynchronní dráze, vzájemně rozfázovaných v úhlu 180°. Jejím cílem je sledovat proměnlivost podmínek na zemském povrchu a jejich široký záběr (290 km) a vysoká doba přeletu (10 dní na rovníku s jednou družicí a 5 dní se dvěma družicemi za bezoblačných podmínek, což znamená 2-3 dny ve středních zeměpisných šířkách) umožňuje sledování změn zemského povrchu. Polohu každé družice SENTINEL-2 na její oběžné dráze měří dvoufrekvenční přijímač globálního navigačního družicového systému (GNSS). Přesnost oběžné dráhy udržuje speciální pohonný systém.

Každá družice SENTINEL-2 váží přibližně 1,2 tuny. Družice SENTINEL-2A a SENTINEL-2B byly vypuštěny evropskou nosnou raketou VEGA.

Životnost družice je 7,25 roku, což zahrnuje i tříměsíční fázi uvedení do provozu na oběžné dráze. Baterie a pohonné hmoty byly zajištěny na 12 let provozu, včetně manévru na oběžné dráze na konci životnosti.

Družicový systém SENTINEL-2 vyvinulo průmyslové konsorcium vedené společností Astrium GmbH (Německo). Za multispektrální přístroj (MSI) odpovídá společnost Astrium SAS (Francie).

Multispektrální senzor pracuje pasivně, sbírá sluneční světlo odražené od Země. Nová data jsou do přístroje získávána při pohybu družice po její dráze. Příchozí světelný paprsek je rozdělen na filtru a zaostřen na dvě samostatné ohniskové roviny v přístroji; jedna pro viditelná a blízká infračervená pásma (VNIR) a druhá pro krátkovlnná infračervená pásma (SWIR). Spektrální rozdělení každého pásma na jednotlivé vlnové délky se provádí pomocí proužkových filtrů namontovaných na horní straně detektorů (Sentinel Online, n.d.).

## 2.6. Používané vegetační indexy

### 2.6.1. NDVI

NDVI je jedním z nejpoužívanějších vegetačních indexů pro studium fenologie vegetace (Yan & Roy, 2014), redukuje spektrální šum způsobený určitými světelnými podmínkami, topografickými změnami nebo stíny mraků (A. Huete et al., 2002).

Vzorec pro jeho výpočet je:

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

Je nutno poznamenat, že jeho nevýhodou je nadhodnocování vegetačního pokryvu na začátku vegetační sezóny a jeho podhodnocování na konci vegetační sezóny (Bannari et al., 1995).

### 2.6.2. SAVI

Huete (1988b) prokázal, že existuje rozpor mezi způsobem, jakým NDVI a Perpendicular vegetation index (PVI) popisují spektrální chování vegetace a půdního pozadí. Následně vyvinul nový vegetační index, tzv. "Soil Adjusted Vegetation Index" (SAVI), který je do jisté míry kompromisem mezi poměrovými indexy (NDVI) a ortogonálními indexy (PVI).

Je definován vzorcem:

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

kde  $L$  je faktor úpravy půdy. Na základě zjednodušeného modelu přenosu záření Huete, (1988) ukázal, že hodnota  $L = 0,5$  umožňuje nejlepší přizpůsobení, tj. minimalizuje vliv sekundárního zpětného rozptylu odraženého záření půdního pozadí. Pokud je hodnota  $L$  nulová ( $L = 0$ ), SAVI se rovná NDVI (Bannari et al., 1995).

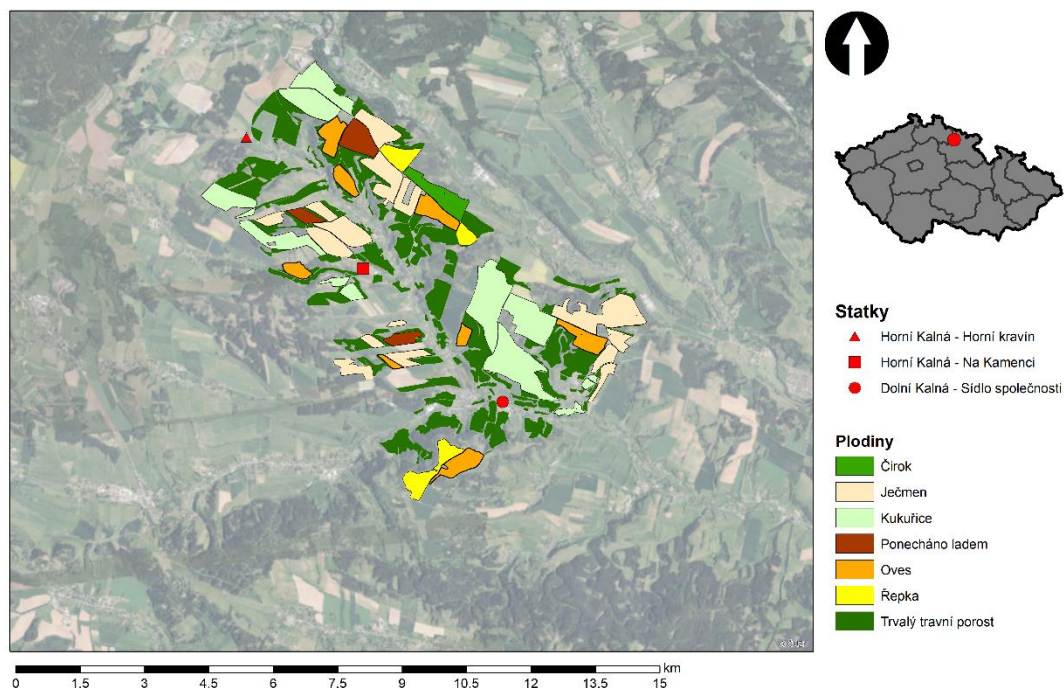
### 3. Metodika

#### 3.1. Popis zájmového území

Zájmové území se nachází v Králověhradeckém kraji, v katastrálních územích Horní Kalná, Dolní Kalná a Slemeno v Podkrkonoší. Území je kopcovité, nadmořské výšky se pohybují v rozmezí 380–470 m. n. m. Pro svou práci jsem používal data vztahující se ke společnosti Kalenská zemědělská a. s. Společnost se zabývá hlavně chovem českého strakatého skotu, ke krmení jsou využívány senáže a kukuřičná siláž. Dalšími pěstovanými plodinami ve sledovaném období byly ječmen, oves a řepka. Informace o plodinách, jejich zdravotním stavu, technologických postupech při jejich pěstování a vlivech na jejich zdravotní stav poskytli zaměstnanci společnosti nebo byla získána při terénním průzkumu, který jsem prováděl v období od července do října.



Obrázek 1 - Zájmové území (foto: archiv autora)



Obrázek 2 - Přehled plodin v zájmovém území

Kukuřice měla ve zkoumaném období různou kvalitou. Na některých polích došlo k výraznému splavení osiva a na těchto polích byla tedy velmi malá hustota vegetace. Část úrody byla též poškozena divokými prasaty. Tam, kde k těmto problémům nedošlo však rostliny dosahovaly vyšší kvality než v předešlém roce. Výsev probíhal koncem března a sklizeň na siláž v průběhu října (obr. 3).



Obrázek 3 - Sklizeň kukuřice na siláž – zájmové území, Slemeno (foto: archiv autora)

Ozimý ječmen byl pěstován především pro sladovnictví, jeho výsev probíhal v listopadu předešlé sezóny, sklizeň pak probíhala v průběhu srpna (obr. 5). Malé množství bylo sklizeno v červenci ve fázi mléčné zralosti a silážováno (GPS –



Ganzpflanzenschrot, obr. 4). Hlavními problémy u ječmene bylo poškození rostlin větrem, srážkami a velké množství plevelů.



Obrázek 4 - Sklizeň ječmene – systém GPS (Ganzpflanzenschrot) – zájmové území, za autokempem (foto: archiv autora)



Obrázek 5 - Sklizeň sladovnického ječmene – zájmové území, Příčnice (foto: archiv autora)

Oves (obr. 6) se vesměs potýkal se stejnými problémy jako ječmen, rovněž docházelo k poškození rostlin srážkami a větrem. Jeho výsev probíhal koncem března a sklizeň v průběhu srpna.



*Obrázek 6 - Oves – zájmové území, Nový Svět (foto: archiv autora)*

Řepka se vyznačovala poměrně nízkou kvalitou, semena byla malá a sklizeň bylo nutné dodatečně čistit. Rovněž docházelo k významnému zaplevelení. Výsev probíhal v druhé polovině srpna předchozího roku a sklizeň koncem července (obr. 7).



*Obrázek 7 - Sklizeň řepky – zájmové území, Příčnice (foto: archiv autora)*



### 3.2. Data

Pro tuto práci jsem využíval snímky dostupných ve webové aplikaci Sentinel Hub EO Browser. Snímky jsem vybíral, s ohledem na minimální pokrytí oblačností a sněhem. Celkově se jednalo o 7 snímků od března do září, které jsem stahoval v „RAW“ podobě, tedy jednotlivé rastry snímaných pásem ve formátu TIFF.

Polygonovou vrstvu polí jsem získal z veřejného registru půdy LPIS. Jednalo se o soubory SHAPEFILE z katastrálních území Horní Kalná, Dolní Kalná, Slemeno v Podkrkonoší a Klášterská Lhota. Z těchto jsem vybral pouze polygony s „ID\_UZ“ „49198“ tj. Kalenská Zemědělská a.s. Získanou vrstvu jsem dále transformoval do souřadnicového systému WGS 1984 Web Mercator Auxiliary Sphere s kódem 3857. Dle informací z průzkumu zájmového území jsem přidal atribut „plodina“ a polygony roztřídil dle pěstovaných plodin. Výsledné vrstvy jsem spojil funkcí Merge a získal vrstvu pro celé zájmové území. Tuto jsem si rozdělil na vrstvy polí dle jednotlivých plodin pro snazší práci s funkcí Zonal statistics.

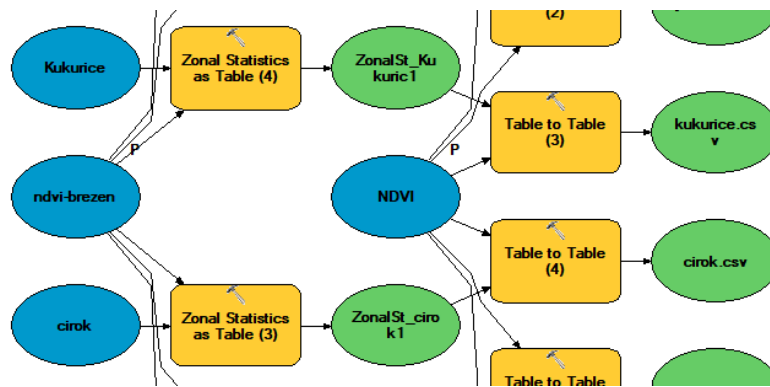
### 3.3. Zjištění vývoje indexů NDVI pro jednotlivé plodiny

Index NDVI jsem volil s ohledem na to, že je pravděpodobně nejpoužívanějším vegetačním indexem v současné době. Tato popularita, společně s dostupností bezplatných družicových dat a programů pro jejich zpracování, z něj činí potenciálně vhodný index pro používání zemědělci bez nutnosti rozsáhlého studia problematiky DPZ.

Nejprve jsem z „RAW“ souborů pásem B04 a B08 ve formátu TIFF pomocí modelu s funkcí Raster calculator získal rastry s hodnotami NDVI. Funkci jsem nastavil pro rovnici:

$$\frac{B08 - B04}{B08 + B04}$$

Dále jsem sestavil model (obr. 8) s funkcemi Zonal statistics as table a Table to table, který pro jednotlivé plodiny vytvářel tabulky s hodnotami průměrnými hodnotami NDVI pro jednotlivé měsíce ve formátu CSV. Tyto jsem spojil do jednoho souboru a následně pro jednotlivé plodiny vytvořil tabulky a grafy vývoje NDVI.



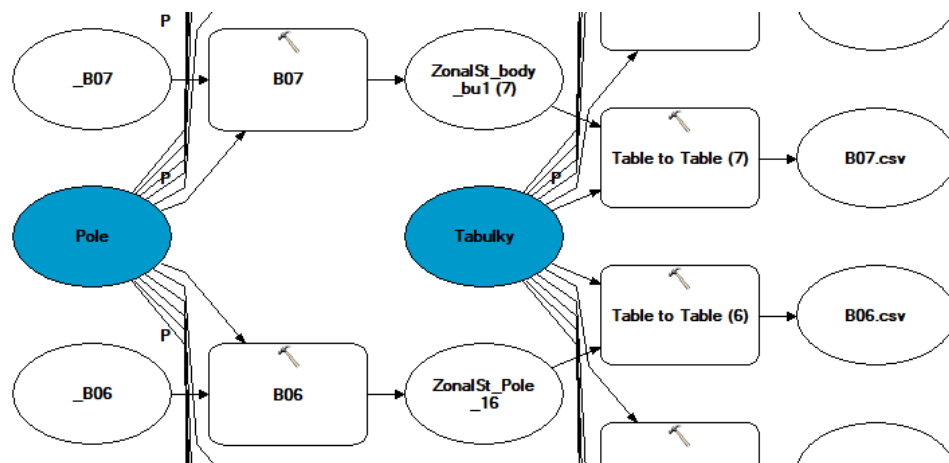
Obrázek 8 - Model pro získání hodnot NDVI jednotlivých plodin (výřez)

Do modelu vstupují polygony polí rozříděné dle plodin a rastr hodnot NDVI pro zkoumaný měsíc. Vystupují tabulky průměrných hodnot NDVI ve formátu CSV. Tyto tabulky jsem dále spojil do jednoho dokumentu MS Excel, a sestrojil grafy vývoje.

### 3.4. Zjištění vývoje spektrálních křivek jednotlivých plodin

Pro znázornění vývoje spektrálních křivek jednotlivých plodin, jsem volil pole, na kterých plodiny dosahovaly nejlepšího zdravotního stavu (dle terénního průzkumu). Z tohoto důvodu jsem mohl využít i snímky, na kterých byla ostatní pole zakryta oblačností, čímž došlo částečně k nahuštění dat. Snímky pro tuto analýzu jsem volil pro každé zkoumané pole individuálně, dle vizuálního posouzení RGB kompozitu.

Pro samotné získání hodnot jsem sestavil model (obr. 9), do kterého vstupovala jednotlivá pásma ve formátech TIFF a polygon zvoleného pole. Pomocí funkce Zonal statistics as table model generoval tabulky průměrných hodnot pro jednotlivá pásma a následně pomocí funkce Table to table převáděl vzniklé tabulky z formátu DBF do formátu CSV aby bylo snadnější s nimi dále pracovat.



Obrázek 9 - Model použitý pro získání hodnot pásem Sentinel-2 na vybraném poli (výřez)

Pro další zpracování bylo nutné vzniklé tabulky spojit, pro tuto operaci jsem zvolil script v programovacím jazyce Python 3.10 (obr. 10). Ze vzniklé tabulky se všemi hodnotami jsem vytvořil grafy vývoje spektrálních křivek v čase.

```
import pandas as pd
import glob, os
import csv

os.chdir("E:\Bakalarka\Repka\Zari")
results = pd.DataFrame([])

for counter, file in enumerate(glob.glob("B*.csv")):
    namedf = pd.read_csv(file, skiprows=0)
    results = results.append(namedf)

results.to_csv('E:\Bakalarka\Repka\Zari\combinedfile.csv')
```

Obrázek 10 - Script použitý pro spojení tabulek

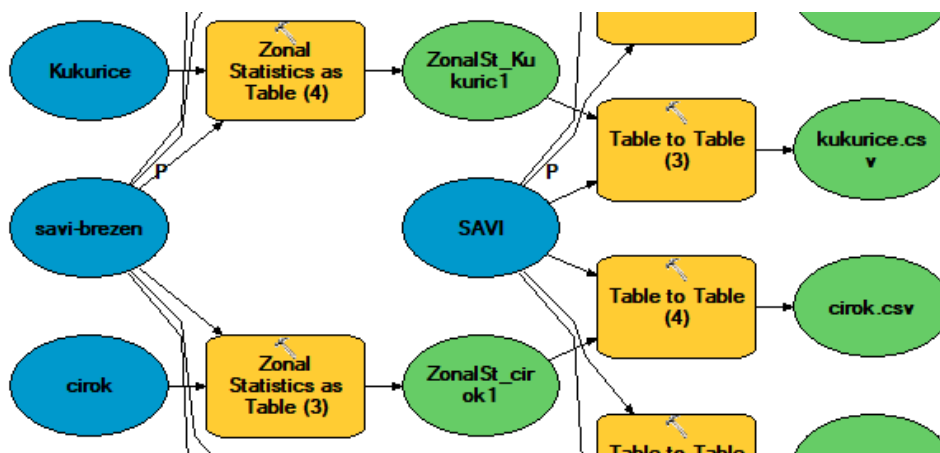
### 3.5. Zjištění vývoje indexů SAVI pro jednotlivé plodiny

Index SAVI oproti NDVI koriguje vlivy záření odraženého od půdy. Pro tuto práci jsem ho zvolil abych ho porovnal s NDVI a zjistil, zda není lepším indikátorem fenologie sledovaných zemědělských plodin na daném území.

SAVI jsem zjišťoval obdobným způsobem jako NDVI. Použil jsem model s funkcí Raster calculator, do kterého vstupovaly polygonové vrstvy polí a potřebná pásma Sentinel-2 výstupem byly rastry SAVI dle následující rovnice:

$$\frac{B08 - B04}{B08 + B04 + 0,5} \times (1 + 0,5)$$

Získané rastry jsem použil v modelu (obr. 11) společně s polygonovými vrstvami polí dle jednotlivých plodin a výstupem byly CSV tabulky s hodnotami indexů pro dané plodiny.



Obrázek 11 - Model použitý pro získání hodnot SAVI (výřez)

### 3.6. Řízená klasifikace a posouzení její přesnosti

Dalším cílem této práce bylo určit dobu, kdy se od sebe plodiny nejvíce odlišují, a tedy kdy je vhodné provádět řízené klasifikace, za předpokladu, že uživatel nemá k dispozici multitemporální snímky nebo je pro něj nevýhodné vytvářet kompozity z různých pásem a dob.

Klasifikace jsem prováděl v softwaru Arcmap. Nejprve jsem musel spojit TIFF soubory jednotlivých pásem do kompozitního snímku. Toto jsem provedl pomocí funkce Create composit v okně image analysis, do kompozitu vstupovaly soubory všech pásem (tj. B01 – B12). Rovněž jsem vytvořil kompozitní rastr z rastrů hodnot NDVI pro jednotlivé měsíce. Předpokládal jsem, že kompozit NDVI bude klasifikován

s vyšší přesností, neboť lépe zobrazuje rozdíly mezi plodinami. Poté jsem vytvořil trénovací vzorky pro jednotlivé plodiny – 5 kategorií, jmenovitě ječmen, oves, řepka, kukuřice a traviny (čirok nebyl zahrnut z důvodu nedostatečného počtu vzorků) v počtu cca 7 vzorků na kategorii. Vzorky jsem volil tak, aby pokryly různé části polí s vegetací v různé kondici, čímž jsem se snažil maximalizovat úspěšnost klasifikace. Poté jsem pro jednotlivé měsíce provedl Maximum likelihood classification.



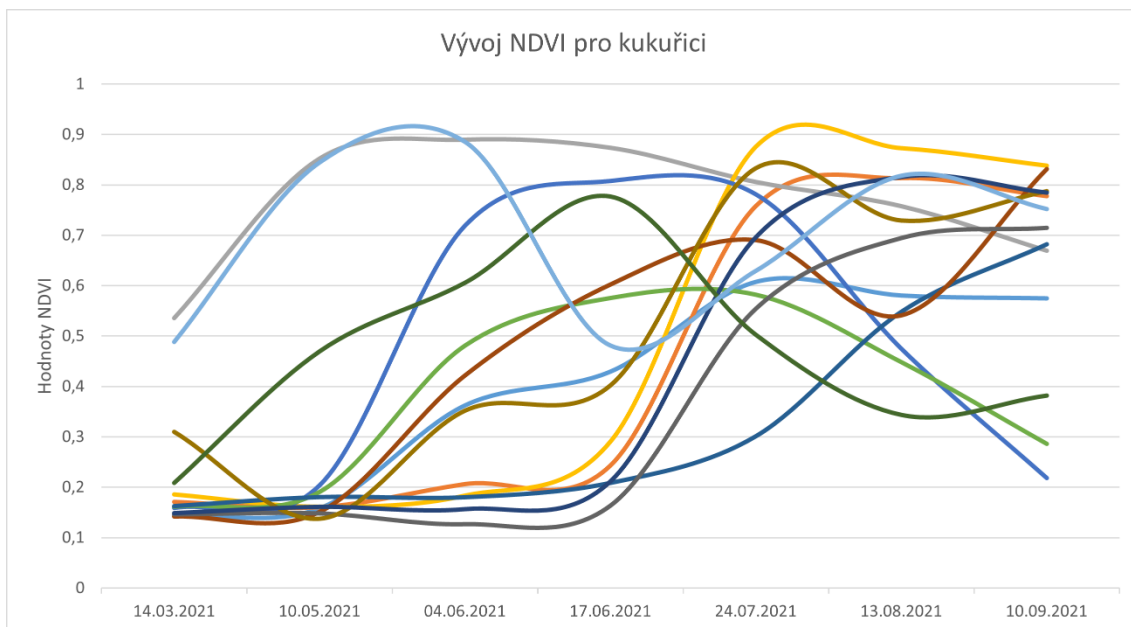
Obrázek 12 - Ukázka trénovacích vzorků použitých pro klasifikaci

Pro určení přesnosti klasifikací jsem musel získat referenční rastr s plochami jednotlivých kategorií dle jejich skutečného stavu. Tento rastr jsem vytvořil pomocí funkce Polygon to raster z polygonových vrstev jednotlivých plodin. Pomocí funkce Reclassify jsem jim přiřadil odpovídající hodnoty kategorií. Dále jsem vygeneroval accuracy assesment points, pomocí stejnojmenné funkce, v počtu 750 a s parametrem rozmístění Stratified random. Atribut Ground truth byl přiřazen dle referenčního rastru. Pomocí funkce Update accuracy assesment points jsem pak přiřadil bodům hodnoty atributu Classified a získal accuracy assesment points pro jednotlivé měsíce. Dalším krokem bylo generování chybových matic. Ty jsem generoval pomocí funkce Compute confusion matrix. Získané chybové matice jsem pomocí funkce Table to table převedl do formátu CSV, abych je mohl dále zpracovávat v softwaru MS Excel. V MS Excel jsem vytvořil grafy User's accuracy, Producer's accuracy.

## 4. Výsledky

### 4.1. Vývoj NDVI

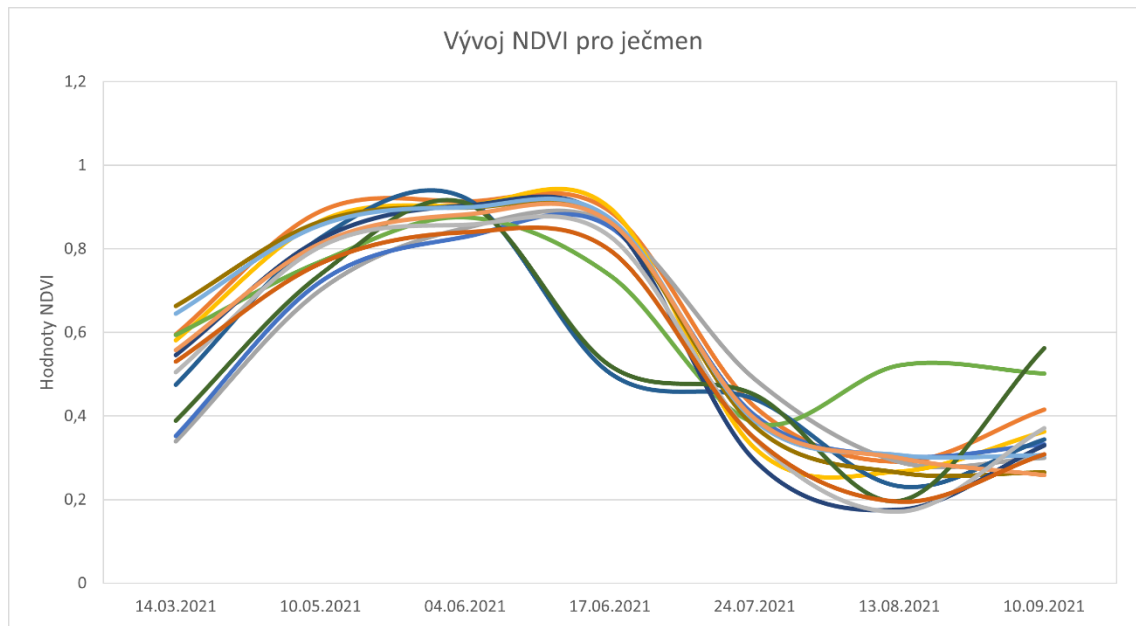
#### 4.1.1. Kukuřice



Obrázek 13 - Vývoj indexu NDVI v průběhu roku na polích s kukuřicí

V grafu si můžeme povšimnout poměrně velkých rozdílů mezi jednotlivými křivkami. Kukuřice byla seta na počátku května. U části polí můžeme již v květnu pozorovat stoupání hodnot NDVI, u některých dochází k výrazným změnám až na přelomu června a července. Tyto rozdíly mohou způsobeny zaplevelením. Sklizeň probíhala začátkem října, pro toto období však již nebyly dostupné bezoblačné snímky pro celé území.

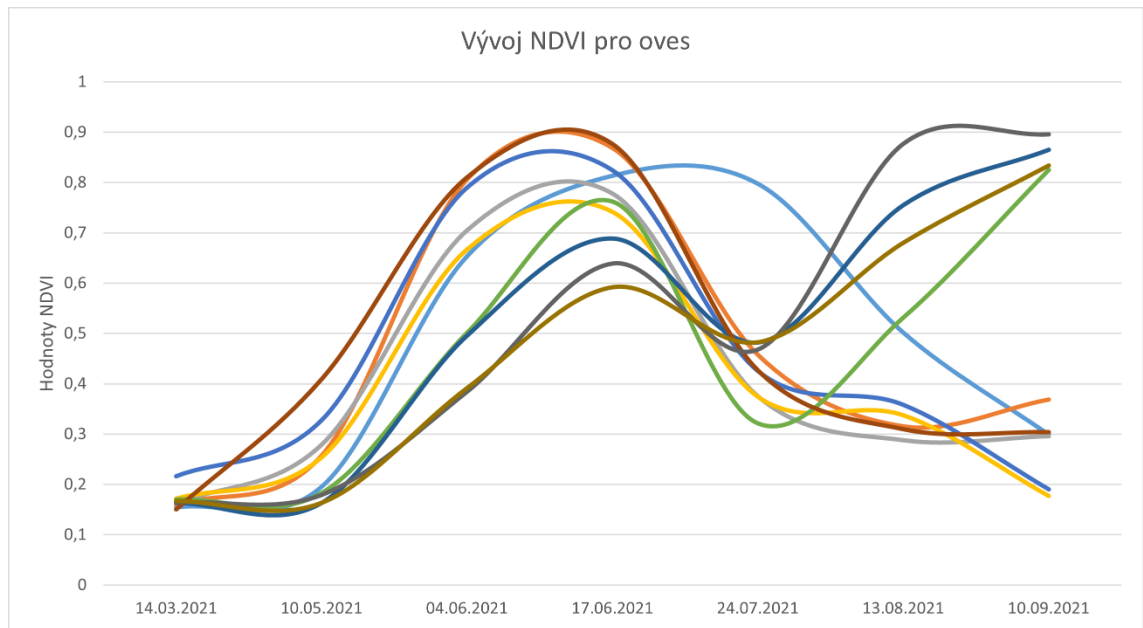
#### 4.1.2. Ječmen



Obrázek 14 - Vývoj NDVI v průběhu roku na polích s ječmenem

Ozimý ječmen byl setý v listopadu předchozí sezóny, vzhledem k sněhové pokrývce byly první dostupné snímky zájmového území z března, kde, již můžeme zaznamenat zvýšené hodnoty NDVI, a tedy počátek vegetace. Tyto hodnoty dosáhly maxima v polovině června, tou dobou již dochází k dozrávání. Po dosažení maxima, můžeme vidět pokles hodnot způsobený postupným sesycháním dozrávajících rostlin. Rovněž je patrné mírné stoupání hodnot v září, přestože tou dobou již byly rostliny sklizeny.

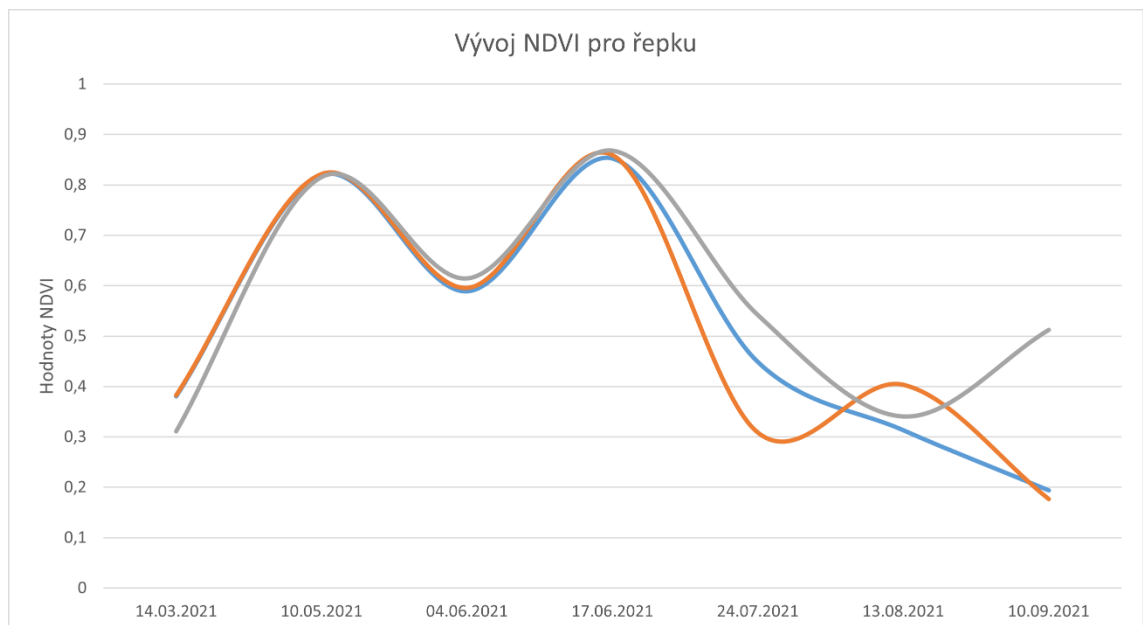
#### 4.1.3. Oves



Obrázek 15 - Vývoj NDVI v průběhu roku na polích s ovsem

U Ovsy (obr. 15) probíhalo setí koncem března. Vegetace začínala v průběhu května. Maximálních hodnot dosahoval již v průběhu června, tou dobou již docházelo ke zrání. Stejně jako u ječmene i zde můžeme pozorovat pokles hodnot NDVI s postupným sesycháním rostlin. Sklizeň probíhala na přelomu července a srpna.

#### 4.1.4. Řepka



Obrázek 16 - Vývoj NDVI v průběhu roku na polích s řepkou

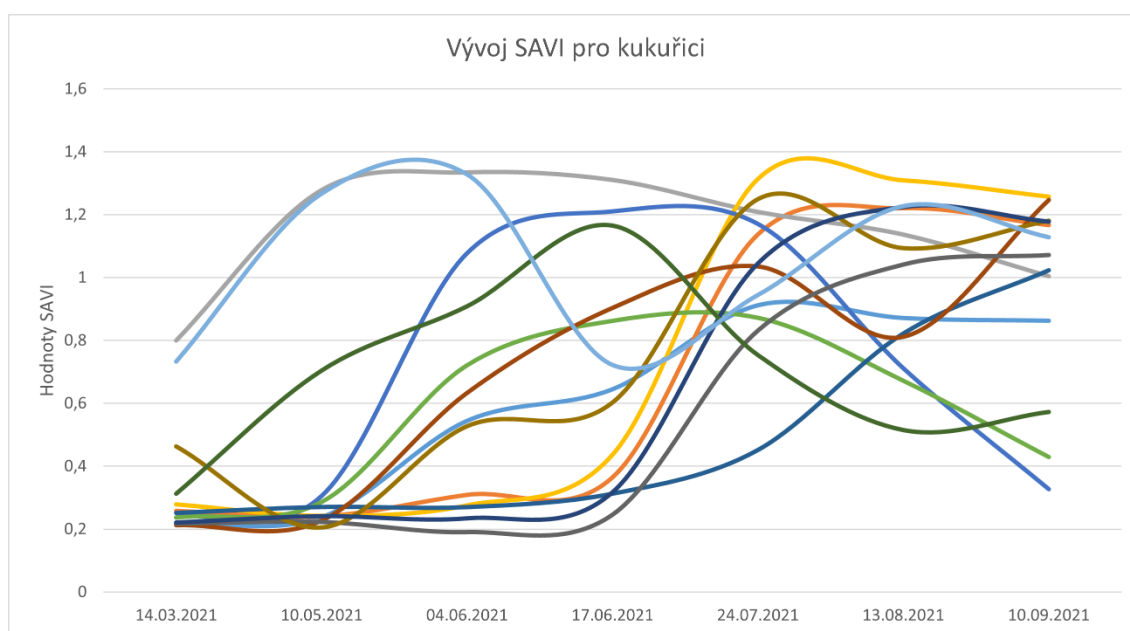


U řepky (obr. 16) probíhalo setí v srpnu předchozí sezóny, pozorovatelná vegetace začala v březnu. Došlo k výraznému nárůstu v květnu, kdy rostliny začínaly kvést, poté hodnoty NDVI klesly na počátku června, pravděpodobně v důsledku odkvětu. V průběhu června docházelo opět k růstu hodnot a následně k prudkému poklesu po dosažení maxima. Tento pokles je způsoben dozráváním a sesycháním rostlin. Sklizeň probíhala koncem července.

## 4.2. Vývoj SAVI

Index SAVI jsem volil s ohledem na charakteristickou načervenalou barvu půdy v zájmovém území, která je způsobena vysokým obsahem železa. Mým předpokladem bylo, že výsledky NDVI budou touto půdou ovlivněny, proto jsem jako druhý index zvolil SAVI, který by měl tento vliv redukovat. Výsledky můj předpoklad nepotvrdily, neboť rozdíl v samotném průběhu vývoje, se dají považovat za zanedbatelné.

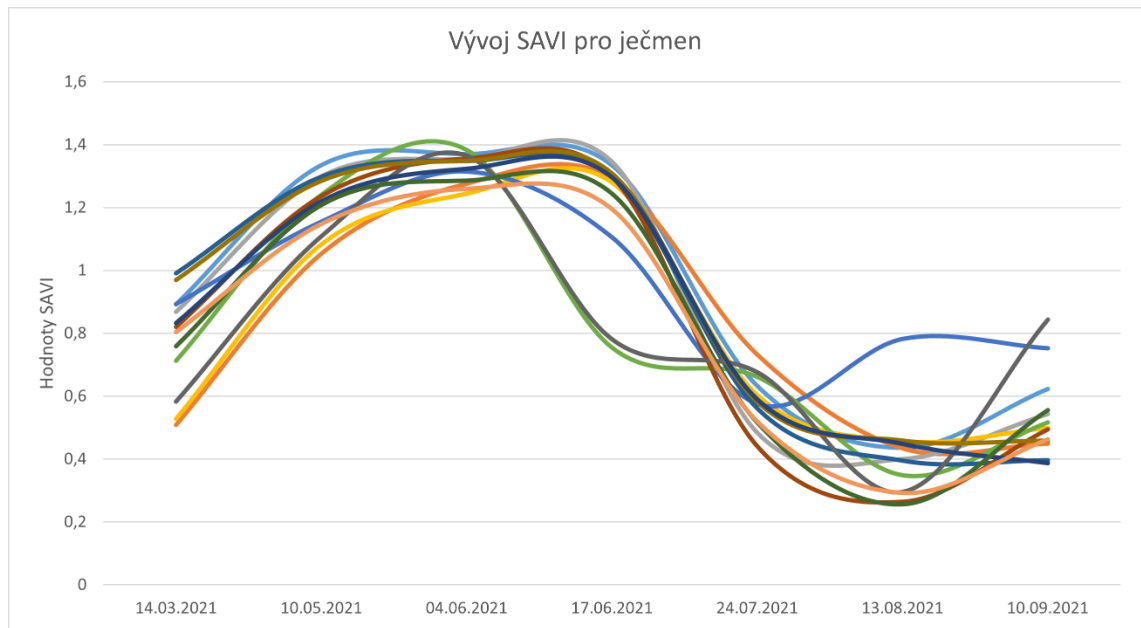
### 4.2.1. Kukuřice



Obrázek 17 - Vývoj SAVI v průběhu roku na polích s kukuřicí

U kukuřice (obr. 17) můžeme vidět velké rozdíly mezi křivkami jednotlivých polí, Nelze spolehlivě identifikovat konkrétní charakteristický průběh. Tyto rozdíly mohou být způsobeny zaplevelením, erozí, či jinými vlivy. Přesto můžeme pozorovat, že nejvyšších hodnot kukuřice dosahuje většinou na přelomu července a srpna.

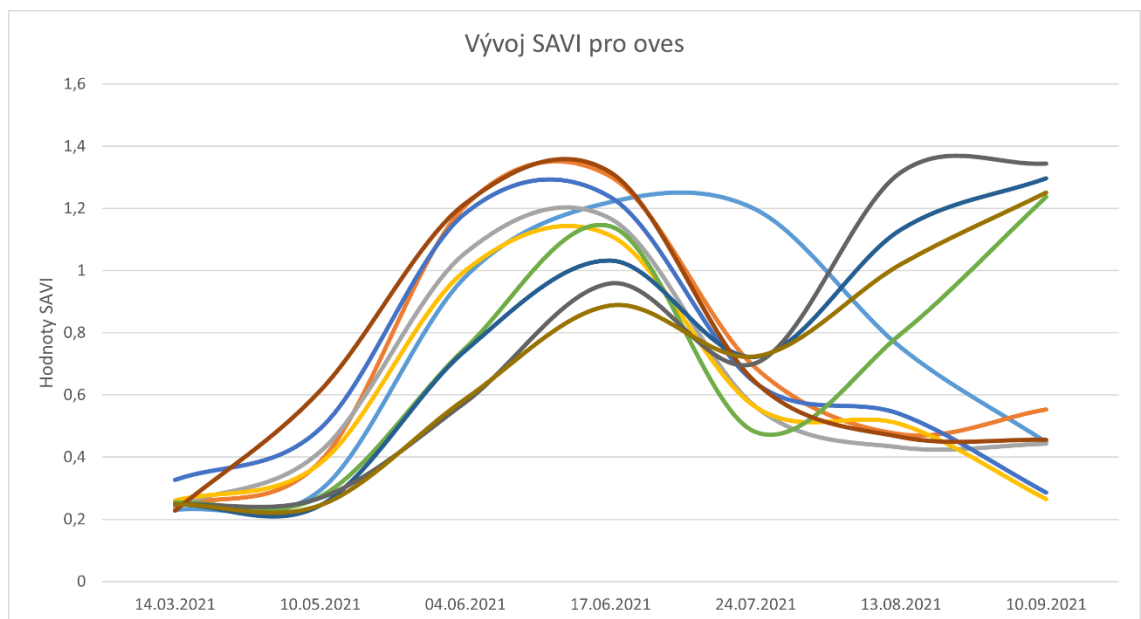
#### 4.2.2. Ječmen



Obrázek 18 - Vývoj SAVI v průběhu roku na polích s ječmenem

U ječmene (obr. 18) je průběh podstatně více konzistentní. Můžeme pozorovat charakteristický průběh křivek. Vegetace probíhá již v březnu, v květnu dochází k metání, a v průběhu června začíná zrání. Maxima hodnoty dosahují v druhé polovině června, poté již klesají z důvodu sesychání rostlin. Minima hodnoty dosahují v srpnu v průběhu sklizně. Můžeme si rovněž povšimnout mírného růstu hodnot v září, zde se může jednat o plevel, či posklizňové zbytky.

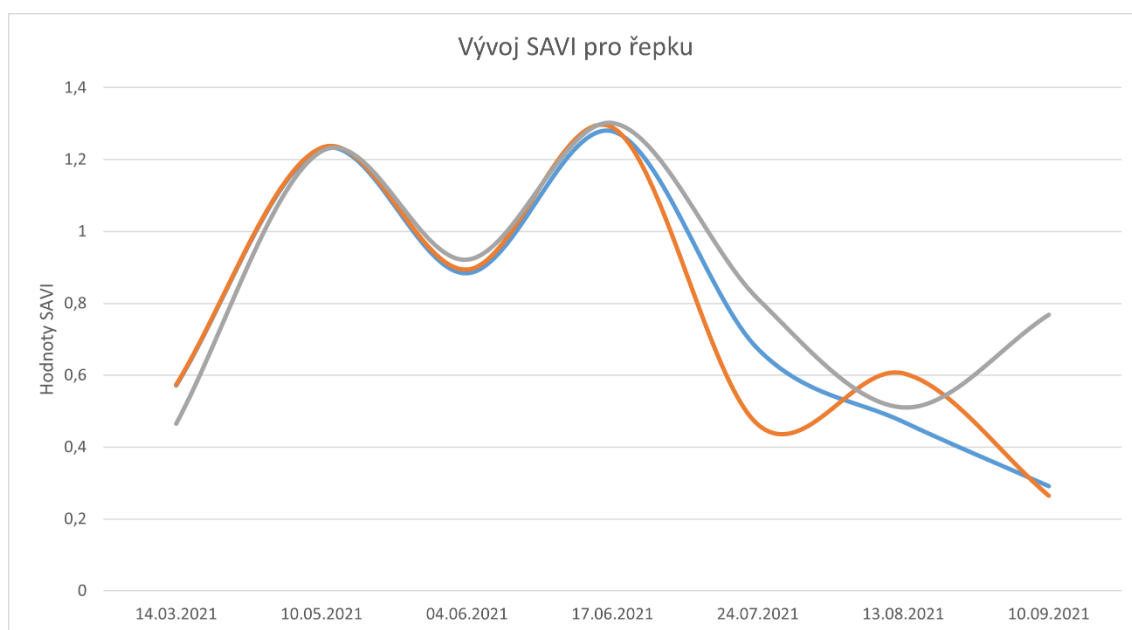
#### 4.2.3. Oves



Obrázek 19 - Vývoj SAVI v průběhu roku na polích s ovsem

U ovsa (obr. 19) můžeme rovněž pozorovat charakteristický tvar křivek, nicméně méně konzistentní než u ječmene. Setí probíhá koncem března, vegetaci můžeme pozorovat již v květnu, samotná doba zrání se rovněž jeví kratší a k sesychání rostlin a poklesu hodnot indexu dochází rychleji. Samotný pokles není však tak velký. Rovněž zde u některých polí dochází k zpětnému nárůstu hodnot, to je opět pravděpodobně způsobeno zaplevelením.

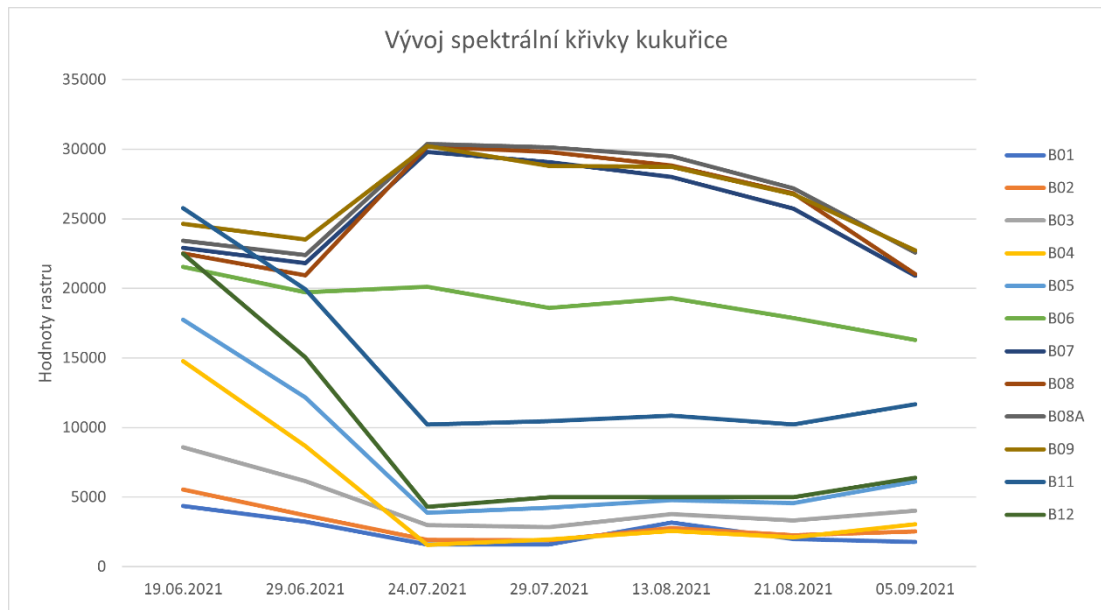
#### 4.2.4. Řepka



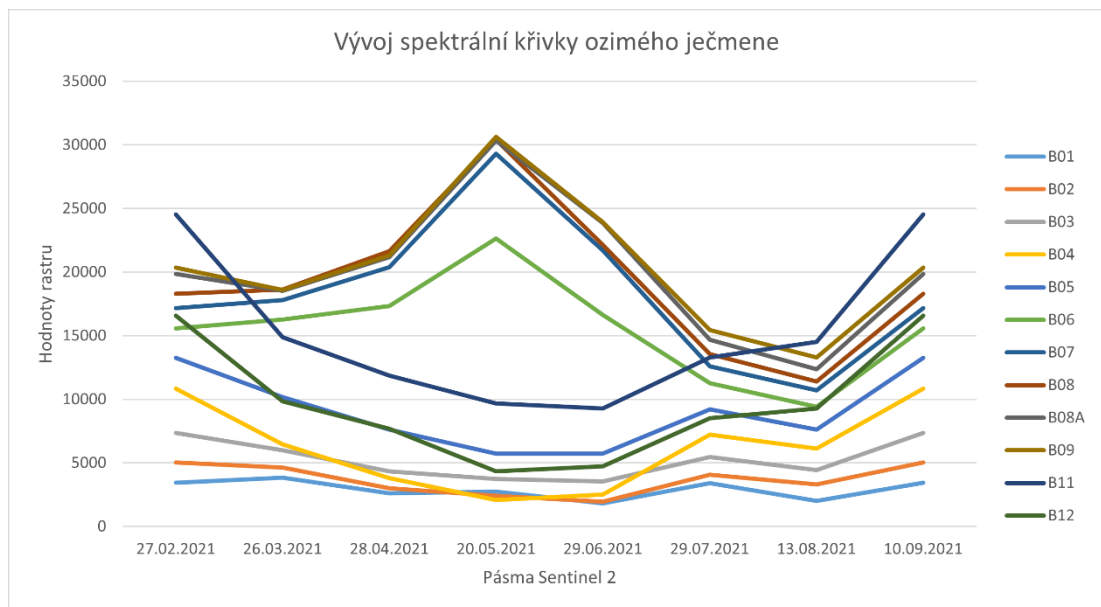
Obrázek 20 - Vývoj SAVI v průběhu roku na polích s řepkou

U řepky (obr. 20) lze v průběhu vegetace pozorovat nejkonzistentnější průběh vývoje. Přestože byly dostupná pouze tři pole, je zde velmi dobře viditelná charakteristická křivka. Vegetace začíná již pod sněhovou pokrývkou, s prvním dostupným snímkem můžeme již pozorovat zvýšené hodnoty. V průběhu května dosahují tyto hodnoty prvního lokálního maxima před začátkem kvetení, v průběhu květu dochází k poklesu hodnot. V druhé polovině června nastává druhé lokální maximum, kdy dochází k zrání. Poté hodnoty klesají až do období sklizně, to je opět způsobeno sesycháním rostlin.


### 4.3. Vývoj spektrálních křivek



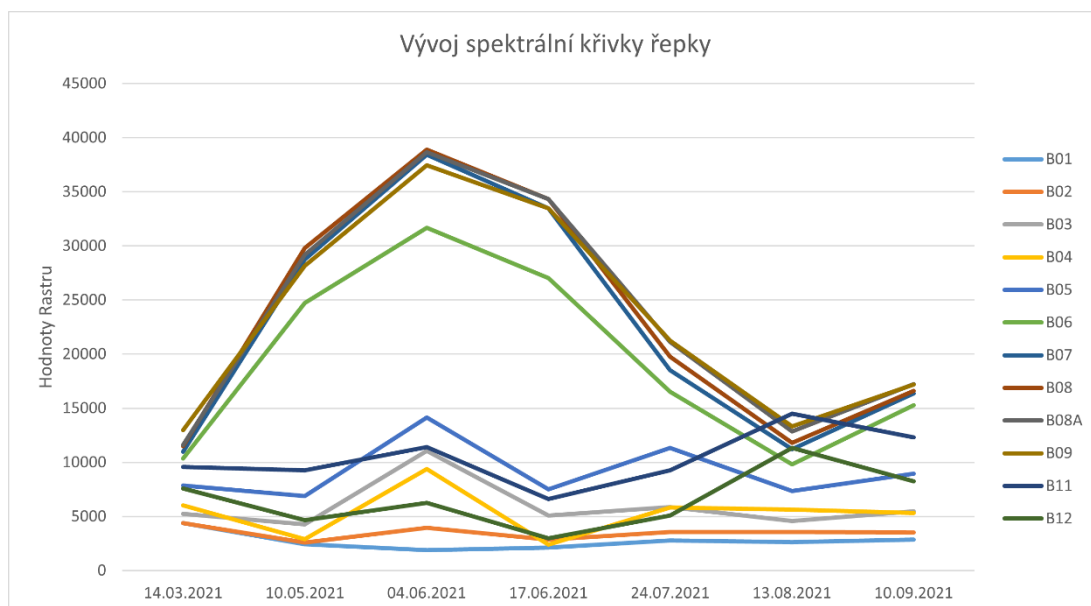
Obrázek 21 - Vývoj spektrální křivky kukuřice



Obrázek 22 - Vývoj spektrální křivky ječmene



Obrázek 23 - Vývoj spektrální křivky ova



Obrázek 24 - Vývoj spektrální křivky řepky

Z grafů je patrné, že plodiny mají křivky vývoje podobné, nicméně jsou mezi nimi dostatečné rozdíly, které by měly umožnit úspěšnou klasifikaci. U kukuřice (obr. 21) můžeme vidět relativně plochý průběh křivky v průběhu celého sledovaného období. U ječmene, ova a řepky (obr. 22-24) pak můžeme pozorovat výrazná lokální maxima v pásmech B06 – B08A (665 – 865nm), která se vyskytují v různá období. Ječmen se ostatních plodin liší nejvíce v průběhu května, oves v druhé polovině června a řepka začátkem června.

Pokud uživatel nemá možnost pro klasifikaci všech plodin použít snímky z období několika měsíců, spektrální křivky naznačily výrazné rozdíly mezi plodinami v období

druhé poloviny července. Tento poznatek jsem dále ověřoval experimentálními klasifikacemi a porovnáním jejich přesností.

#### 4.4. Posouzení přesností řízených klasifikací

Dle výsledků z předchozích částí jsem předpokládal, že nejvhodnějším obdobím pro klasifikaci plodin, bude období jejich vrcholné vegetace – tedy pro mnou sledované plodiny by se jednalo o období července. Výsledky provedených klasifikací a porovnání chybových matic tento předpoklad potvrdily.

Květen								
ClassValue	Ječmen	Oves	Řepka	Kukuřice	Traviny	Total	U_Accuracy	Kappa
Ječmen	0	27	0	38	3	68	0,000	0
Oves	1	31	1	51	2	86	0,360	0
Řepka	0	0	0	0	0	0	0,000	0
Kukuřice	123	24	24	44	133	348	0,126	0
Traviny	1	0	8	31	191	231	0,827	0
Total	125	82	33	164	329	733	0,000	0
P_Accuracy	0	0,378	0	0,268	0,581	0	0,363	0
Kappa	0	0	0	0	0	0	0	0,119

Tabulka 1 - Chybová matice řízené klasifikace pro květen

V chybové matici pro květen (tab. 1) můžeme vidět, že kategorie ječmen, a řepka, nebyly úspěšně rozpoznány na žádném z kontrolních bodů. Nejvyšší úspěšnosti klasifikace bylo dosaženo u kategorie traviny. Celková přesnost hodnocená indexem shodnosti Kappa je 0,119, což se dá považovat za velmi nespolehlivou klasifikaci.

Červen								
ClassValue	Ječmen	Oves	Řepka	Kukuřice	Traviny	Total	U_Accuracy	Kappa
Ječmen	8	0	0	18	73	99	0,081	0
Oves	13	11	30	21	5	80	0,138	0
Řepka	0	0	0	0	0	0	0	0
Kukuřice	104	70	2	121	71	368	0,329	0
Traviny	0	1	1	4	180	186	0,968	0
Total	125	82	33	164	329	733	0	0
P_Accuracy	0,064	0,134	0	0,738	0,547	0	0,437	0
Kappa	0	0	0	0	0	0	0	0,237

Tabulka 2 - Chybová matice řízené klasifikace pro červen

V chybové matici pro červen (tab. 2) můžeme opět vidět, že některé plodiny nebyly úspěšně klasifikovány na žádném z kontrolních bodů. Konkrétně se zde jedná o řepku. Index shodnosti Kappa je o něco vyšší 0,237, ovšem stále se jedná o velmi nepřesnou klasifikaci.

Červenec								
ClassValue	Ječmen	Oves	Řepka	Kukuřice	Traviny	Total	U_Accuracy	Kappa
Ječmen	83	29	5	12	30	159	0,522	0
Oves	6	42	1	21	2	72	0,583	0
Řepka	0	0	18	4	0	22	0,818	0
Kukuřice	34	11	9	105	22	181	0,580	0
Traviny	2	0	0	22	275	299	0,920	0
Total	125	82	33	164	329	733	0	0
P_Accuracy	0,664	0,512	0,545	0,640	0,836	0	0,714	0
Kappa	0	0	0	0	0	0	0	0,598

Tabulka 3 - Chybová matice řízené klasifikace pro červenec

V červenci (tab. 3) vykazuje řízená klasifikace nejvyšší hodnoty přesností pro většinu plodin. Klasifikace obilnin není příliš spolehlivá, nicméně relativně úspěšná je zde klasifikace řepky. U kukuřice nelze vysokou přesnost klasifikace očekávat, neboť její kvalita a spektrální vlastnosti se mezi jednotlivými poli výrazně liší. Klasifikace travin dosahuje opět nejvyšší přesnosti ze všech kategorií. Číslo Kappa je zde 0,598 což se dá považovat za relativně úspěšnou klasifikaci (srovnáváme-li s ostatními měsíci).

Srpen								
ClassValue	Ječmen	Oves	Řepka	Kukuřice	Traviny	Total	U_Accuracy	Kappa
Ječmen	89	52	13	31	15	200	0,445	0
Oves	0	3	0	5	3	11	0,273	0
Řepka	9	0	8	8	0	25	0,320	0
Kukuřice	21	17	12	94	33	177	0,531	0
Traviny	6	10	0	26	278	320	0,869	0
Total	125	82	33	164	329	733	0	0
P_Accuracy	0,712	0,037	0,242	0,573	0,845	0	0,644	0
Kappa	0	0	0	0	0	0	0	0,492

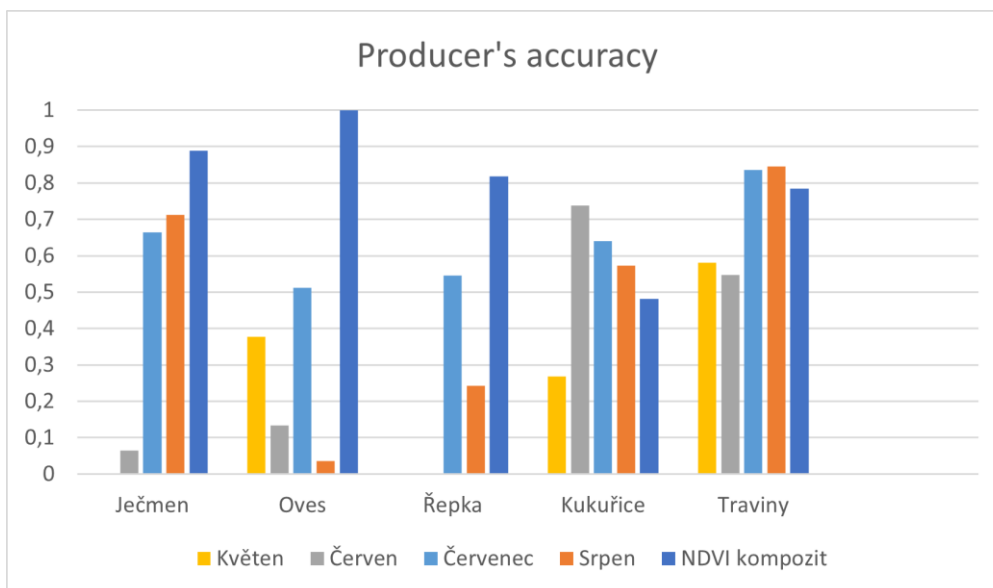
Tabulka 4 - Chybová matice řízené klasifikace pro srpen

V srpnu (tab. 4) již přesnosti klasifikace jednotlivých kategorií opět klesají, nejvýraznější je zde pokles přesnosti klasifikace řepky a ovsu. Kukuřice nevykazuje tak významný pokles. Travniny i zde mají nejvyšší úspěšnost klasifikace. Číslo Kappa je zde 0,492, což je oproti červenci významný pokles.

NDVI kompozit								
ClassValue	Ječmen	Oves	Řepka	Kukuřice	Travniny	Total	U_Accuracy	Kappa
Ječmen	111	0	1	14	27	153	0,725	0
Oves	8	82	1	63	10	164	0,500	0
Řepka	0	0	27	7	10	44	0,614	0
Kukuřice	5	0	3	79	24	111	0,712	0
Travniny	1	0	1	1	258	261	0,989	0
Total	125	82	33	164	329	733	0	0
P_Accuracy	0,888	1,000	0,818	0,482	0,784	0	0,760	0
Kappa	0	0	0	0	0	0	0	0,677

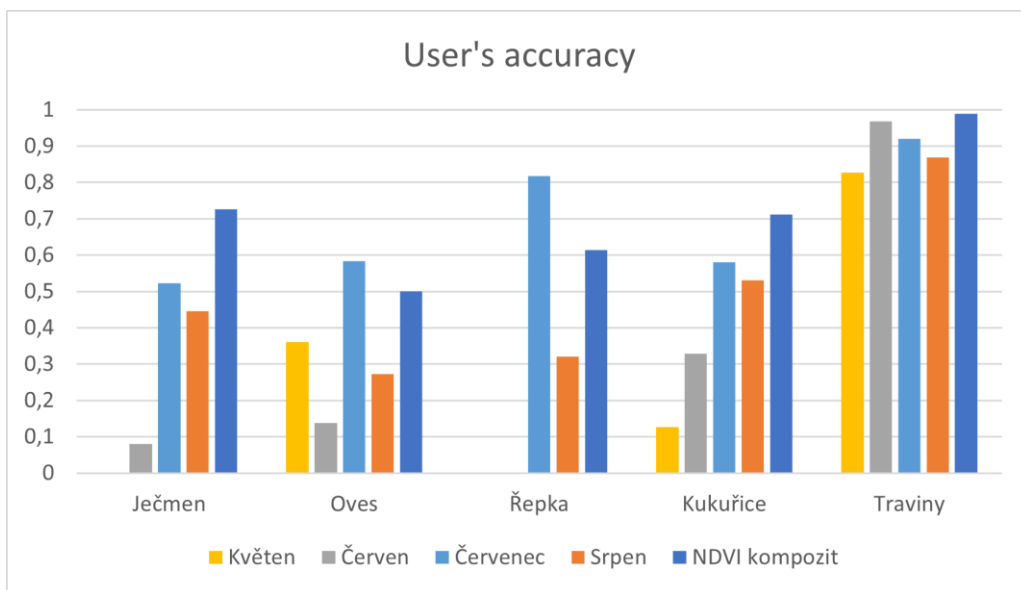
Tabulka 5 - Chybová matice řízené klasifikace kompozitu složeného z rastrů NDVI

NDVI kompozit (tab. 5) vykázal celkově vyšší přesnost klasifikace. Nejvyšší přesnosti bylo dosaženo u ječmene, ovsu a řepky, což bylo předpokládáno. Kukuřice byla naopak klasifikována s přesností nižší, zřejmě kvůli více rozdílným hodnotám na jednotlivých polích. Index Kappa zde dosahuje zcela nejvyšší hodnoty ze všech provedených klasifikací a to 0,677.

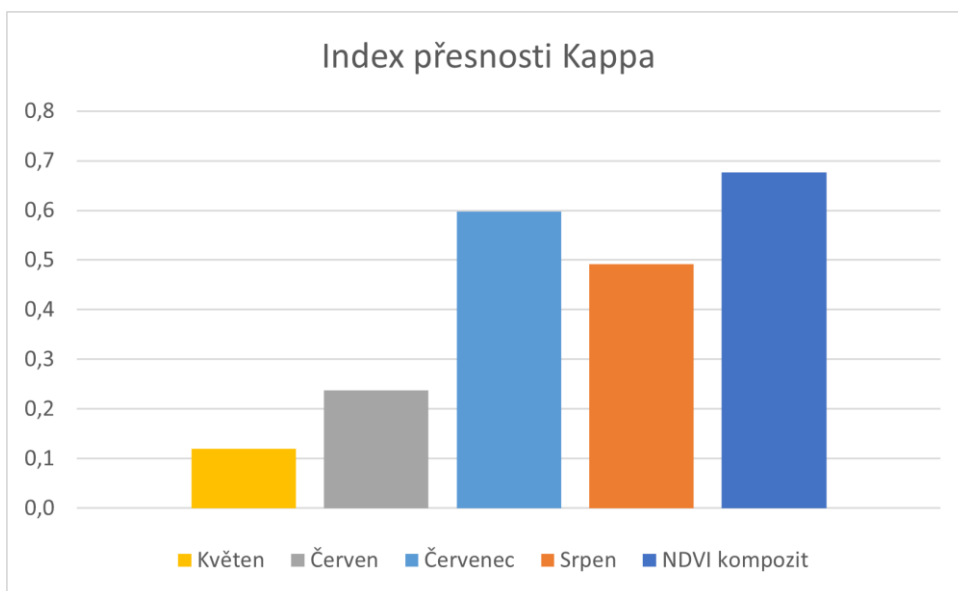


Obrázek 25 - Porovnání Producer's accuracy






Obrázek 26 - Porovnání User's accuracy



Obrázek 27 - Srovnání hodnot indexu shodnosti Kappa

Z porovnání hodnot přesností (obr. 25, 26) je patrná hlavně již zmiňovaná vyšší přesnost v případě klasifikací ječmene, ova a řepky, což odpovídá očekávání vycházejícího z výsledků sledování vývoje hodnot NDVI v čase. U těchto plodin byl vývoj nejkonzistentnější. Porovnáme-li vizuálně výstupy klasifikací z července s NDVI kompozitem (obr. 28), je vidět rovněž vidět, že kompozit o něco lépe kopíruje skutečný tvar polí.



*Obrázek 28 - Porovnání výsledků klasifikací pro červenec (vlevo), NDVI kompozit (uprostřed) a referenčního rastru (vpravo)*

## 5. Diskuse

Jak je patrné z výsledků, data pro kukuřici nepřinesla jednoznačně průkazné výsledky. To může být způsobeno mnoha ovlivňujícími faktory. Na několika polích došlo v průběhu roku ke splavení osiva, vegetační pokryv byl na těchto plochách tedy výrazně méně hustý než jinde, to mohlo výrazně ovlivnit hodnoty indexů a schopnost algoritmu úspěšně klasifikovat kategorie. Kvalita a zdravotní stav rostlin, se rovněž výrazně lišily, na rozdíl od ostatních plodin, kde byly rozdíly mnohem méně nápadné.

Belgiu & Csillik (2018) rovněž popisují vzorce ve vývoji NDVI, nicméně pracují s jinými plodinami. Porovnávají přesnosti několika klasifikačních metod na třech testovacích územích. Pro účely svých klasifikací však nerozlišují jednotlivé ozimé obilniny, a ostatní plodiny se rovněž liší. Mým cílem bylo porovnat přesnosti klasifikace v různých měsících a určit nejvhodnější období pro provádění klasifikací. Naše cíle tedy nebyly shodné a lišily se i zkoumané kategorie, přesto můžeme alespoň zběžně porovnat přesnosti klasifikací. Belgiu & Csillik (2018), dosahují se svými klasifikacemi podstatně vyšší přesnosti ve většině případů, mé klasifikace dosáhly obdobných přesností pouze u kategorie travin. Nicméně v této práci jsem použil méně komplexní metody klasifikace, neboť cílem nebylo dosáhnout nejvyšší úspěšnosti, nýbrž ověřit vhodnou dobu pro provádění těchto klasifikací. Různé metody by pravděpodobně mohly dosáhnout obdobných výsledků. Pro účely ověření přesnosti v čase se domnívám, že mnou použitá metoda dostatečně ilustruje tuto problematiku.

Srovnáme-li křivky vývoje vegetačních indexů s agrotechnickými lhůtami setí a sklizně pro ČR, zjistíme že vývoj tyto lhůty celkem přesně kopíruje. Výjimkou je v případě této práce kukuřice, u které jsou výsledky nekonzistentní a těžko se identifikuje její charakteristická křivka vývoje. V případě ječmene je dobře patrná již probíhající vegetace v období března a nejnižší hodnoty odpovídají období sklizně v průběhu srpna. V případě ovsa, jelikož se nejedná o ozimou plodinu a setí probíhá koncem března, můžeme očekávat nárůst hodnot indexů později, což výsledky opět potvrdily. Rovněž období sklizně na přelomu července a srpna je dobře patrné. Řepka je seta v průběhu srpna, v průběhu března již v grafech můžeme pozorovat její vegetaci. Zde stojí za zmínku výrazný pokles hodnot na začátku června, který je s velkou pravděpodobností způsoben kvetením. Sklizeň probíhala koncem července, což se v grafech projevuje jako další lokální minimum.

Peña-Barragán et al. (2011) vyvinuli metodiku object-based crop identification and mapping (OCIM) pro 13 hlavních plodin pěstovaných v Yolo county v Californii. Pro svou studii používali několik vegetačních indexů a jejich model využíval snímky pořízené během dvou nebo tří vegetačních období. Ve své studii se jim podařilo

dosáhnout celkové přesnosti 79 %, přičemž kolem 90 % do modelu přispívaly samotné vegetační indexy. Pro odlišení sadů, vinic, trvalých travních porostů apod. pak využívali porovnání textur. Co se týče období, tak snímky z pozdního léta přispěly ke klasifikaci 60 %.

Vyvinout univerzální metodiku, která by byla pro klasifikaci plodin vysoce spolehlivá pro každé území a každé klimatické podmínky je prakticky nemožné. V této práci jsem se snažil porovnat přesnost klasifikace, pokud by do ní vstupovaly snímky z jednoho období a nebyly použity komplexní metody jaké popisují Peña-Barragán et al. (2011). Toto vhodné období se může lišit pro různá zájmová území a sledované plodiny, nicméně zdá se, že letní měsíce obecně poskytují lepší přesnost klasifikace.

Jevy sledované v této práci za použití satelitních snímků jsou výrazně ovlivněny mnoha faktory. Oblačnost hraje v použitelnosti snímků významnou roli, ne vždy jsou dostupné snímky pro použití komplexních metod klasifikace, či pro přesné sledování fenologie rostlin. V případě zájmových území o velké rozloze (např. celé kraje), může být velmi obtížné či nemožné získat dostatek bezoblačných snímků pro celé území, či pro vytvoření smysluplných bezoblačných mozaik pro jednotlivá vegetační období. Dalším faktorem jsou samotné sledované plodiny a technologické postupy při jejich pěstování. Pokud nejsou postupy řádně dodržovány, či dojde k poškození rostlin v důsledku přírodních jevů, má to za následek různou kvalitu rostlin na jednotlivých polích. Tyto rozdíly mohou výrazně ovlivnit výsledky klasifikací. Plevelé ovlivňují hodnoty vegetačních indexů, což komplikuje sledování fenologie plodin, stejně jako výsledky klasifikací. Vliv všech těchto faktorů lze do jisté míry snížit, například použitím kompozitních snímků, kde použijeme pásma z jiných období, či různými kombinacemi použitých vegetačních indexů. Vždy se však bude jednat o kompromis mezi kvalitou výsledků a složitostí metodických postupů. Kompletní eliminace vlivů zmíněných faktorů není však z praktického hlediska reálná.

## 6. Závěr

Na modelové lokalitě společnosti Kalenská Zemědělská a.s. byly za pomoci informací z terénního průzkumu a od zaměstnanců a multispektrálních snímků z družic Sentinel-2 provedeny analýzy časového vývoje vegetačních indexů NDVI a SAVI a na základě výsledných dat určena nejvýhodnější doba pro provádění klasifikací zemědělských plodin. K ověření nejvhodnější doby klasifikace byla použita řízená klasifikace Maximum likelihood a její přesnosti pro jednotlivá období byly vyhodnoceny chybovými maticemi.

Z výsledků vyplynulo, že obilniny a řepka byly v modelovém území méně náchylné na negativní vlivy, křivky vývoje hodnot vegetačních indexů byly pro jednotlivé plodiny charakteristické a umožňují efektivní sledování fenologie těchto plodin. U kukuřice došlo výrazným rozdílům mezi hodnotami jednotlivých polí, a přestože nešlo určit charakteristickou křivku vývoje, data naznačují potenciál pro budoucí sledování vlivu negativních faktorů jako jsou splavení osiva, eroze a další.

Jako nejvhodnější období pro klasifikaci plodin pěstovaných na modelové lokalitě byl na základě posouzení dat zvolen červenec. Následně byl tento předpoklad experimentálně ověřen pomocí řízené klasifikace. Pro řízenou klasifikaci byla použita pásma B01 až B12. Pro měsíc červenec následně řízená klasifikace vykázala i nejvyšší celkovou přesnost, a to v průměru 70 %. Nejnižší přesnost klasifikace vykázalo období května a to pouhých 36 %. Pro porovnání, byla provedena i klasifikace pomocí kompozitu NDVI, která dosáhla celkové přesnosti 76 %.

Tato práce by mohla v budoucnu přispět k dalším rozsáhlejšími analýzám fenologie plodin pomocí prostředků DPZ. Určení vhodného období pro klasifikaci plodin sledovaných v této práci může pomoci k rychlejšímu klasifikování v případech, kde není vyžadována extrémně vysoká přesnost, neboť v těchto případech odbourává nutnost vytvářet kompozitní snímky, či komplexní modely porovnávající další parametry, jako např. texturu, či kombinace vegetačních indexů.

## 7. Seznam zdrojů

- Agrotechnické lhůty setí (S-sowing) a sklizně (H-harvest) hlavních polních plodin v ČR – Mendelova univerzita v Brně. (n.d.). Retrieved March 30, 2022 from <http://user.mendelu.cz/xvaltyni/systemy/projekt/files/03-op-soubory/Terminy-seti-a-sklizne.pdf>
- Ahl, D. E., Gower, S. T., Burrows, S. N., Shabanov, N. v, Myneni, R. B., & Knyazikhin, Y. (2006). *Monitoring spring canopy phenology of a deciduous broadleaf forest using MODIS*. <https://doi.org/10.1016/j.rse.2006.05.003>
- Bannari, A., Morin, A. D., Bonn, D. F., & Huete, F. (1995). *A review of vegetation indices*. 13, 95–120. <https://doi.org/10.1080/02757259509532298>
- Bastiaanssen, W. G. M., & Ali, S. (2003). A new crop yield forecasting model based on satellite measurements applied across the Indus Basin, Pakistan. In *Ecosystems and Environment* (Vol. 94).
- Belgiu, M., & Csillik, O. (2018). Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sensing of Environment*, 204, 509–523. <https://doi.org/10.1016/J.RSE.2017.10.005>
- Biradar, C. M., & Xiao, X. (2011). Quantifying the area and spatial distribution of double- and triple-cropping croplands in India with multi-temporal MODIS imagery in 2005. [Http://Dx.Doi.Org/10.1080/01431160903464179](http://Dx.Doi.Org/10.1080/01431160903464179), 32(2), 367–386. <https://doi.org/10.1080/01431160903464179>
- Dash, J., Jeganathan, C., & Atkinson, P. M. (2010). The use of MERIS Terrestrial Chlorophyll Index to study spatio-temporal variation in vegetation phenology over India. *Remote Sensing of Environment*, 114, 1388–1402. <https://doi.org/10.1016/j.rse.2010.01.021>
- Defries, R. S., & Townshend, J. R. (2007). NDVI-derived land cover classifications at a global scale. [Http://Dx.Doi.Org/10.1080/01431169408954345](http://Dx.Doi.Org/10.1080/01431169408954345), 15(17), 3567–3586. <https://doi.org/10.1080/01431169408954345>
- Duncan, J. M. A., Dash, J., & Atkinson, P. M. (2014). Spatio-temporal dynamics in the phenology of croplands across the Indo-Gangetic Plains. *Advances in Space Research*, 54(4), 710–725. <https://doi.org/10.1016/J.ASR.2014.05.003>
- Goward, S. N., Tucker, C. J., & Dye, D. G. (1985). North American vegetation patterns observed with the NOAA-7 advanced very high resolution radiometer. *Vegetatio* 1985 64:1, 64(1), 3–14. <https://doi.org/10.1007/BF00033449>

- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1–2), 195–213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Huete, A. R. (1988a). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Huete, A. R. (1988b). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Huete, A. R., Liu, H. Q., Batchily, ° K, & van Leeuwen, W. (n.d.). A Comparison of Vegetation Indices over a Global Set of TM Images for EOS-MODIS. In *REMOTE SENS. ENVIRON* (Vol. 5). ©Elsevier Science Inc.
- Kathuroju, N., White, M. A., Symanzik, J., Schwartz, M. D., Powell, J. A., & Nemani, R. R. (2007). On the use of the advanced very high resolution radiometer for development of prognostic land surface phenology models. *Ecological Modelling*, 201(2), 144–156. <https://doi.org/10.1016/J.ECOLMODEL.2006.09.011>
- Kaufman, Y. J., & Tanré, D. (1992). Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 261–270. <https://doi.org/10.1109/36.134076>
- Lobell, D. B., Asner, G. P., Ivan Ortiz-Monasterio, J., & Benning, T. L. (2003). Remote sensing of regional crop production in the Yaqui Valley, Mexico: estimates and uncertainties. In *Ecosystems and Environment* (Vol. 94).
- Malingreau, J. P. (1989). The Vegetation Index and the Study of Vegetation Dynamics. *Applications of Remote Sensing to Agrometeorology. Proc. Ispra-Course, Ispra, 1987*, 285–303. [https://doi.org/10.1007/978-94-009-2235-8\\_12](https://doi.org/10.1007/978-94-009-2235-8_12)
- Melesse, A. M., Weng, Q., Thenkabail, P. S., & Senay, G. B. (2007). Remote Sensing Sensors and Applications in Environmental Resources Mapping and Modelling. *Sensors*, 7, 3209–3241. <http://earth.google.com>
- Moran, M. S., Inoue, Y., & Barnes, E. M. (1997). Opportunities and limitations for image-based remote sensing in precision crop management. *Remote Sensing of Environment*, 61(3), 319–346. [https://doi.org/10.1016/S0034-4257\(97\)00045-X](https://doi.org/10.1016/S0034-4257(97)00045-X)
- Neményi, M., Mesterházi, P. Á., Pecze, Z., & Stépán, Z. (2003). The role of GIS and GPS in precision farming. *Computers and Electronics in Agriculture*, 40(1–3), 45–55. [https://doi.org/10.1016/S0168-1699\(03\)00010-3](https://doi.org/10.1016/S0168-1699(03)00010-3)

- Pecze, Zs., Neményi, M., Mesterházi, P. Á., & Stépán, Zs. (2001). The Function of the Geographic Information System (GIS) in Precision Farming. *IFAC Proceedings Volumes*, 34(26), 15–18. [https://doi.org/10.1016/S1474-6670\(17\)33625-X](https://doi.org/10.1016/S1474-6670(17)33625-X)
- Peña-Barragán, J. M., Ngugi, M. K., Plant, R. E., & Six, J. (2011). Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment*, 115(6), 1301–1316. <https://doi.org/10.1016/J.RSE.2011.01.009>
- Peter A. Burrough, R. A. M. C. D. L. (1998). *Principles of Geographical Information Systems* (Vol. 2).
- Rana, A. (n.d.). *Application of GIS in precision agriculture Establishment of GIS monitoring system for HP Crop Diversification Promotion Project ,JICA-ODA View project To develop sustainable ecotourism in Himalayan region View project Kunal Sood CSK HPKV Palampur.* <https://doi.org/10.13140/RG.2.1.2221.3368>
- Rembold, F., Atzberger, C., Savin, I., & Rojas, O. (2013). Remote Sensing Using Low Resolution Satellite Imagery for Yield Prediction and Yield Anomaly Detection. *Remote Sens*, 5, 1704–1733. <https://doi.org/10.3390/rs5041704>
- Running, S. W., Loveland, T. R., Pierce, L. L., Nemani, R. R., & Hunt, E. R. (1995). A remote sensing based vegetation classification logic for global land cover analysis. *Remote Sensing of Environment*, 51(1), 39–48. [https://doi.org/10.1016/0034-4257\(94\)00063-S](https://doi.org/10.1016/0034-4257(94)00063-S)
- Sentinel-2 - Satellite Description - Sentinel Online - Sentinel Online.* (n.d.). Retrieved March 30, 2022, from <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/satellite-description>
- Tayari, E., Jamshid, A. R., & Goodarzi, H. R. (2015). Role of GPS and GIS in precision agriculture. *Journal of Scientific Research and Development*, 2(3), 157–162. [www.jsrad.org](http://www.jsrad.org)
- Thenkabail, P. S., & Wu, Z. (2005). *Remote Sensing An Automated Cropland Classification Algorithm (ACCA) for Tajikistan by Combining Landsat, MODIS, and Secondary Data.* 4, 2890–2918. <https://doi.org/10.3390/rs4102890>
- Tucker, C. J., & Sellers, P. J. (1986). Satellite remote sensing of primary production. *International Journal of Remote Sensing*, 7(11), 1395–1416. <https://doi.org/10.1080/01431168608948944>
- Vrieling, A., de Leeuw, J., & Said, M. Y. (2013). Length of Growing Period over Africa: Variability and Trends from 30 Years of NDVI Time Series. *Remote*



*Sensing* 2013, Vol. 5, Pages 982-1000, 5(2), 982–1000.  
<https://doi.org/10.3390/RS5020982>

- Wardlow, B. D., Egbert, S. L., & Kastens, J. H. (2007). Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains. *Remote Sensing of Environment*, 108(3), 290–310. <https://doi.org/10.1016/J.RSE.2006.11.021>
- Wassmann, R., Jagdish, S. V. K., Sumfleth, K., Pathak, H., Howell, G., Ismail, A., Serraj, R., Redona, E., Singh, R. K., & Heuer, S. (2009). Chapter 3 Regional Vulnerability of Climate Change Impacts on Asian Rice Production and Scope for Adaptation. *Advances in Agronomy*, 102, 91–133. [https://doi.org/10.1016/S0065-2113\(09\)01003-7](https://doi.org/10.1016/S0065-2113(09)01003-7)
- White, M. A., & Nemani, R. R. (2006). Real-time monitoring and short-term forecasting of land surface phenology. *Remote Sensing of Environment*, 104(1), 43–49. <https://doi.org/10.1016/J.RSE.2006.04.014>
- Xiao, X., Boles, S., Liu, J., Zhuang, D., Froking, S., Li, C., Salas, W., & Moore, B. (2005). Mapping paddy rice agriculture in southern China using multi-temporal MODIS images. *Remote Sensing of Environment*, 95(4), 480–492. <https://doi.org/10.1016/J.RSE.2004.12.009>
- Yan, L., & Roy, D. P. (2014). Automated crop field extraction from multi-temporal Web Enabled Landsat Data. *Remote Sensing of Environment*, 144, 42–64. <https://doi.org/10.1016/J.RSE.2014.01.006>
- Zhang, X., Friedl, M. A., Schaaf, C. B., Strahler, A. H., Hodges, J. C. F., Gao, F., Reed, B. C., & Huete, A. (2003). Monitoring vegetation phenology using MODIS. *Remote Sensing of Environment*, 84(3), 471–475. [https://doi.org/10.1016/S0034-4257\(02\)00135-9](https://doi.org/10.1016/S0034-4257(02)00135-9)

## 8. Přílohy

### 8.1. Příloha č. 1:

Agrotechnické lhůty setí (S-sowing) a sklizně (H-harvest) hlavních polních plodin v ČR

OBILNINY	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen	listopad	prosinec
PŠENICE ozimá							H H			S S		
PŠENICE jarní			S S					H H H				
JEČMEN ozimý							H H H		S S S			
JEČMEN jarní			S S S				H H H					
ŽITO ozimé							H H		S S S			
TRITICALE ozimé							H H H		S S S			
OVES			S S S				H H H					
KUKUŘICE				S S S						H H H H		

OLEJNINY	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen	listopad	prosinec
ŘEPKA ozimá							H H	S S				
MÁK ozimý							H H		S S			
MÁK jarní			S S S				H H H					
LEN				S S S				H H H H				
SLUNEČNICE				S S S				H H H H				
SÓJA				S S S				H H H				
SAFLOR			S S S					H H				

OKOPANINY	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen	listopad	prosinec
ŘEPA cukrovka			S S S							H H H H		
ŘEPA krmná			S S							H H H		
BRAMBORY rané			S S S			H H						
BRAMBORY poloran.				S S S				H H H				
BRAMBORY pozdní				S S S					H H H H			

LUSKOVINY	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen	listopad	prosinec
HRÁCH			S S S				H H					
BOB				S S					H H			
SÓJA				S S S				H H H				

PÍCNINY	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen	listopad	prosinec
VOJTĚŠKA rok zal.			S S S				H H H			H H H		
1. užitkový rok					H H H		H H		H H			
2. užitkový rok					H H H		H H H					
JETEL rok založení			S S S					H H H				
1. užitkový rok						H H H		H H				
JTS rok založení			S S S					H H				
1. užitkový rok						H H		H H H				
LOS jarní			S S S			H H						
KUKUŘICE silážní				S S S						H H		