

UNIVERZITA KARLOVA

Přírodovědecká fakulta

Katedra aplikované geoinformatiky a kartografie

Studijní program: Aplikovaná geografie (bakalářské studium)

Studijní obor: Fyzická geografie a geoinformatika



Zuzana HÝRKOVÁ

HODNOCENÍ VLHKOSTI PŮDY POMOCÍ DRUŽICOVÝCH DAT

SOIL MOISTURE MONITORING USING EARTH OBSERVATION METHODS

Bakalářská práce

Vedoucí bakalářské práce: doc. RNDr. Přemysl Štych, Ph.D.

Praha 2022

Prohlášení

Prohlašuji, že jsem závěrečnou práci zpracovala samostatně a že jsem uvedla všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

V Praze dne 5. 5. 2022

.....

podpis

Zadání bakalářské práce

pro Zuzanu Hýrkovou

obor Fyzická geografie a geoinformatika

Název tématu: Hodnocení vlhkosti půdy pomocí družicových dat

Zásady pro vypracování

Tato bakalářská práce se zabývá využitím/aplikací optických a radarových dat dálkového průzkumu Země pro monitoring půdní vlhkosti (soil moisture) se zaměřením na výzkum vlivu meteorologických charakteristik a zemědělských postupů (podrývání) na tuto zkoumanou tematiku. Hlavní použitou výzkumnou metodou je analýza časových řad vybraných spektrálních indexů (NSMI, NDMI, NDVI, RVI) vypočtených pro skupinu půdních bloků ležících v okrese Písek. Zdroji družicových dat jsou Sentinel-1 a Sentinel-2. Data jsou zpracována v cloudovém prostředí Google Earth Engine. Údaje o podrývání půdy jsou dodány od zemědělců, úhrny srážek a teploty jsou získány z ČHMÚ.

Konkrétní řešené úlohy jsou:

- Zevrubná rešerše relevantních literárních zdrojů.
- Zhodnocení současných metod pro získání informace o vlhkosti půdy z optických a radarových dat.
- Výběr vhodných spektrálních indexů pro určení vývoje soil moisture z dat Sentinel-1 a Sentinel-2.
- Vyhodnocení vývoje soil moisture na základě zvolených indexů ve zkoumaných lokalitách.
- Vyhodnocení meteorologických vlivů a zemědělských postupů (podrývání) na soil moisture.
- Porovnání vypovídajících schopností použitých indexů získaných z optických a radarových dat.
- Diskuse vhodnosti použitých dat a metod k určení soil moisture na úrovni zemědělských polí.

Rozsah grafických prací: dle potřeby

Rozsah průvodní zprávy: cca 40 stran

Seznam odborné literatury:

KORNELSEN, K. C., COULIBALY, P. (2013): Advances in soil moisture retrieval from synthetic aperture radar and hydrological applications. *Journal of Hydrology*, 476, s. 460 – 489.

DOBSON, M. C., ULABY, F. T. (1998): Mapping Soil Moisture Distribution With Imaging Radar. In: Henderson, F. M., Lewis, A. J. (eds.): *Principles & Applications of Imaging Radar*. John Wiley & Sons, New York, s. 407 – 433.

HORNACEK, M., WAGNER, W., SABEL, D. (2012): Potential for High Resolution Systematic Global Surface Soil Moisture Retrieval via Change Detection Using Sentinel-1. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5, č. 4, s. 1303 – 1311.

KOLÁŘ, J. (2008): Radarová obrazová data a jejich využití. Studie, Czech space office, Praha, 55 s.

OH, Y. (2004): Quantitative retrieval of soil moisture content and surface roughness from multipolarized radar observations of bare soil surfaces. *IEEE Transactions on Geoscience and Remote Sensing*, 42, č. 3, s. 596 – 601.

Vedoucí bakalářské práce: doc. RNDr. Přemysl Štych, Ph.D.

Datum zadání bakalářské práce: 1. 12. 2021

Doc. RNDr. Přemysl Štych, Ph.D.

.....

Vedoucí diplomové práce

.....

Vedoucí katedry

V Praze dne

Poděkování

Tímto bych chtěla poděkovat vedoucímu mé bakalářské práce doc. RNDr. Přemyslu Štychovi, Ph.D. za přínosné konzultace a připomínky, Mgr. Danielu Palubovi za cenné rady a Výzkumnému ústavu zemědělské techniky za poskytnutá data. Děkuji také Tomáši Jorovi za všechnu věnovaný čas a trpělivost a neposledně celé své rodině a přátelům, kteří mě podporovali.

Abstrakt

Tato práce se zabývá možnostmi využití dálkového průzkumu Země pro monitoring vlhkosti zemědělské půdy. Konkrétně zkoumá vliv meteorologických charakteristik a podrývání orné půdy na vlhkost v půdě. Hlavní výzkumnou metodou je analýza časových řad spektrálních indexů (NSMI, NDMI, NDVI, RVI) spočtených pro půdní bloky v okrese Písek pro období 2017–2020. Indexy jsou vypočteny z družicových snímků Sentinel-1 a Sentinel-2A pomocí aplikace Google Earth Engine. Výsledky prokazují, že meteorologické faktory (srážky a teplota) a podrývání mají významný vliv na hodnoty sledovaných indexů použitých pro hodnocení půdní vlhkosti.

Klíčová slova: vlhkost půdy, dálkový průzkum Země, Sentinel-2, NSMI, vegetační indexy

Abstract

This work deals with the evaluation of soil moisture of agricultural land using remote sensing data. It examines an influence of the meteorological characteristics and the soil loosening on cover on the soil moisture. The main research method is a time series analysis of spectral indices (NSMI, NDMI, NDVI, RVI) calculated for soil blocks in the district of Písek for the period 2017–2020. The indices are calculated from Sentinel-1 and Sentinel-2A satellite data in Google Earth Engine. The results proved that meteorological factors (precipitation and temperature) and soil loosening have a significant effect on the values of the monitored indices used to assess soil moisture.

Key words: soil moisture, remote sensing, Sentinel-2, NSMI, vegetation indices

Obsah

Úvod a cíle práce	11
1. Vstup do problematiky.....	12
1.1. Měření vlhkosti půdy	12
1.1.1. In situ data	12
1.1.2. Modely založené na datech půdní vlhkosti	13
1.1.3. Určování půdní vlhkosti pomocí DPZ	13
1.2. Spektrální odrazivost vody	14
1.3. Spektrální odrazivost vegetace	15
1.4. Faktory ovlivňující radarové měření půdní vlhkosti	17
1.4.1. Vlnová délka nebo frekvence	18
1.4.2. Úhel dopadu	18
1.4.3. Polarizace	18
1.5. Vlhkostní indexy využívající optická data	19
1.5.1. Normalized Soil Moisture Index (NSMI)	19
1.5.2. Normalized Difference Moisture Index (NDMI)	20
1.5.3. Normalized Difference Water Index (NDWI)	21
1.6. Vegetační indexy využívající optická data	21
1.6.1. Normalized Difference Vegetation Index (NDVI).....	21
1.6.2. Enhanced Vegetation Index (EVI)	22
1.6.3. Difference Vegetation Index (DVI)	23
1.7. Radarové vegetační indexy.....	23
1.7.1. Radar Vegetation Index (RVI)	23
2. Charakteristika zájmového území	24
3. Data	26
4. Metody	29
4.1. Výběr a výpočet indexů	29
4.2. Zpracování dat a analýza časových řad	30
5. Výsledky	31
5.1. Pole podrytá v roce 2017 (Pole 17)	38
5.2. Pole podrytá v roce 2018 (Pole 18)	39
5.3. Pole podrytá v roce 2019 (Pole 19)	43

5.4. Pole podrytá v roce 2020 (Pole 20)	44
6. Diskuze	48
7. Závěr	50
8. Seznam literatury a zdrojů	50
9. Přílohy.....	58

Seznam obrázků

Obrázek 1: Spektrální odrazivost čisté a zakalené vody.	15
Obrázek 2: Spektrální odrazivost půdy v závislosti na její vlhkosti.....	15
Obrázek 3: : Spektrální odrazivost zdravé a poškozené vegetace.	16
Obrázek 4: Spektrální odrazivost borovice vejmutovky.	17
Obrázek 5: Poloha jednotlivých polí (modře - pole podrytá v roce 2016, žlutě - pole podrytá v roce 2017, fialově - pole podrytá v roce 2018, zeleně - pole podrytá v roce 2019, červeně - pole podrytá v roce 2020).....	25
Obrázek 6: Problematická plocha na zájmovém půdním bloku.	26
Obrázek 7: Problematická holá plocha na zájmovém půdním bloku.	26
Obrázek 8: Pásma s prostorovým rozlišením 10 m.	27
Obrázek 9: Pásma s prostorovým rozlišením 20 m.	28
Obrázek 10: Pásma s prostorovým rozlišením 60 m.	28
Obrázek 11: Průběh hodnot indexů NSMI, NDMI, RVI a NDVI na Polích 20 za období 2017–2020.	32
Obrázek 12: Srovnání průběhu hodnot NSMI pro jednotlivá pole v období 2017–2020.....	33
Obrázek 13: Teploty a srážky naměřené ve Strakonících (levá osa) v porovnání s NSMI, NDMI a NDVI (pravá osa) Polí 20 v období 2017–2020	34
Obrázek 14: Srovnání průběhu hodnot NDMI pro jednotlivá pole v období 2017–2020.	36
Obrázek 15: Srovnání průběhu hodnot NDVI pro jednotlivá pole v období 2017–2020.....	36
Obrázek 16: Srovnání průběhu hodnot NDMI pro jednotlivá pole v období 2017–2020.	37
Obrázek 17: NSMI, NDMI, NDVI a RVI polí podrytých v roce 2017 za období 2017–2020.	39
Obrázek 18: Teploty a srážky naměřené ve Strakonících (levá osa), NSMI a NDMI (pravá osa) polí podrytých v roce 2017 v období 2017–2020. Černá přerušovaná přímka znázorňuje termín, kdy bylo provedeno podrytí.....	40
Obrázek 19: NSMI, NDMI, NDVI a RVI polí podrytých v roce 2018 za období 2017–2020.	41
Obrázek 20: Teploty a srážky (levá osa) naměřené ve Strakonících, NSMI a NDMI (pravá osa) polí podrytých v roce 2018 v období 2017–2020. Černá přerušovaná přímka znázorňuje termín, kdy bylo provedeno podrytí.....	42
Obrázek 21: NSMI, NDMI, NDVI a RVI polí podrytých v roce 2019 za období 2017–2020.	44
Obrázek 22: Teploty a srážky (levá osa) naměřené ve Strakonících, NSMI a NDMI (pravá osa) polí podrytých v roce 2019 v období 2017–2020.....	45
Obrázek 23: NSMI, NDMI, NDVI a RVI polí podrytých v roce 2020 za období 2017–2020.	46
Obrázek 24: Teploty a srážky naměřené ve Strakonících (levá osa), NSMI a NDMI (pravá osa) polí podrytých v roce 2020 v období 2017–2020.....	47

Seznam příloh

Příloha 1: Přehledová mapa Polí 16.....	58
Příloha 2: Údaje o Polích 16.....	58
Příloha 3: Přehledová mapa Polí 17.....	59
Příloha 4: Údaje o Polích 17.....	59
Příloha 5: Přehledová mapa Polí 18.....	60
Příloha 6: Údaje o Polích 18.....	60
Příloha 7: Přehledová mapa Polí 19.....	61
Příloha 8: Údaje o Polích 19.....	61
Příloha 9: Přehledová mapa Polí 20.....	62
Příloha 10: Údaje o Polích 20.....	62
Příloha 11: Měsíční úhrny srážek a průměrné měsíční teploty vzduchu v roce 2017 naměřené ve Strakonících.....	63
Příloha 12: Měsíční úhrny srážek a průměrné měsíční teploty vzduchu v roce 2018 naměřené ve Strakonících.....	63
Příloha 13: Měsíční úhrny srážek a průměrné měsíční teploty vzduchu v roce 2019 naměřené ve Strakonících.....	64
Příloha 14: Měsíční úhrny srážek a průměrné měsíční teploty vzduchu v roce 2020 naměřené ve Strakonících.....	64

Úvod a cíle práce

Množství vody v krajině je ovlivňováno řadou faktorů, jako např. úhrnem srážek, teplotou, transpirací nebo odtokem. V průběhu posledních desetiletí došlo ke zvýšení frekvence a intenzity sucha a k nárůstu trendu vysušování. Je velmi pravděpodobné, že v důsledku klimatických změn bude otázka sucha a tepla stále aktuální také v budoucnu. Nedostatek vody má dopad na různé aspekty života a způsobuje řadu ekonomických a ekologických problémů. Informace o půdní vlhkosti (*soil moisture*) tak nachází využití nejen při predikci sucha, ale také povodní, plánování závlah nebo efektivnějším hospodaření s vodními zdroji. Pro lepší rozvoj politik, které mají snahu riziku vodního stresu předejít, je důležitá především detekce suchých oblastí, sledování stupně sucha v čase a hodnocení jeho dopadů na zemědělství, životní prostředí a ekonomiku. Pro klimatologické analýzy jsou však zásadní nejen pozemní data o teplotách a úhrnu srážek, ale i data získaná ze satelitů. Proto byly definovány různé vlhkostní indexy, které mají napomoci monitoringu půdní vlhkosti a přítomnosti vody v krajině vůbec.

Cílem této práce je za využití dat dálkového průzkumu Země (DPZ) získat informace o obsahu vody v půdě, plodinách a o hustotě vegetace, a prostřednictvím analýzy časových řad vlhkostních a vegetačních indexů v porovnání s úhrny srážek a teplotami potvrdit či vyvrátit vliv podryvání na jejich hodnoty. Studie je iniciována Výzkumným ústavem zemědělské techniky za účelem snazšího monitoringu situace na problémových polích, na nichž se dlouhodobě vyskytují holé plochy bez plodin.

Metoda podryvání byla zvolena s cílem prokypření zhutnělých polí, které by vedlo ke zlepšení jejich retenční schopnosti, zvýšení půdní vlhkosti a výnosů plodin. Podryv byl proveden na různých skupinách půdních bloků v období 2017–2020.

Práce je rozdělena do několika částí. V první - rešeršní - části jsou hodnoceny různé zdroje dat půdní vlhkosti, následuje seznámení s družicemi Sentinel-1 a Sentinel-2 a se spektrální odrazivostí vody a vegetace, jež je pro tuto práci zásadní, a nakonec srovnání a zhodnocení využitelnosti různých vlhkostních a vegetačních indexů. Následující dvě kapitoly se věnují charakteristice zájmového území a použitým datům. Metodická část pojednává o výpočtu vlhkostních a vegetačních indexů a zpracování dat za účelem analýzy jejich časových řad. Přínosy a nedostatky výsledků jsou v diskuzi porovnávány s dalšími studiemi a v závěru jsou shrnuty nejdůležitější poznatky a jejich potenciál do budoucna.

zhodnotit potenciál aktivních a pasivních metod dálkového průzkumu Země v zemědělství. Jsou zde popsány různé způsoby získávání informací důležitých pro hospodaření na orné půdě - tedy nejen o půdní vlhkosti, ale také o vlhkosti ve vegetaci, či hustotě vegetace.

1. Vstup do problematiky

1.1. Měření vlhkosti půdy

Údaje o půdní vlhkosti lze získat z měření in situ, klimatických modelů a modelů zemského povrchu, nebo pomocí dálkového snímání (Dobriyal a kol., 2012). Přímé (in situ) měření půdní vlhkosti je náchylné k nejistotám, může být finančně nákladné a prostorově a časově omezené. Proto se alternativně používají data družicová nebo data získaná z modelů vytvořených na základě měření (Tavakol a kol., 2021). Modelovaná a satelitní data půdní vlhkosti vykazují sice povětšinou lepší prostorové pokrytí než in situ data, ale mají také svá omezení. Pro data z modelů jsou zdrojem nejistot předpoklady modelu a parametrizace, zatímco senzory DPZ získávající data dálkově jsou sice schopné vlhkost půdy relativně přesně určit, ale ovlivňují je faktory, jako např. typ půdy či krajinný pokryv. Takovýto odhad půdní vlhkosti je také omezen pouze na pár horních centimetrů půdy. Santi a kol. (2013) ve svém výzkumu porovnává výsledky obsahu vlhkosti půdy získaných pomocí radaru SAR (z angl. *synthetic aperture radar*) za využití pásma C, hydrologického modelu a pozemního měření. Dosažené výsledky vypovídají o tom, že hydrologický model, jež simuloval situaci ve dvou hloubkách pod povrchem - ve 30 a 5 cm - ve 30 cm dosahoval vyšších hodnot než satelit. Zatímco při srovnání výsledků v 5 cm nabývaly všechny metody měření srovnatelných hodnot.

Výběr dat a metody pro určení půdní vlhkosti závisí na cíli studie, aplikaci, dostupnosti dat, prostorovém a časovém rozlišení, obtížnosti použití a neposledně na požadované přesnosti výsledků (Dobriyal a kol., 2012). Nelze tedy určit nejvhodnější data a metody pro univerzální aplikaci. Níže je však popsáno, k čemu se jednotlivé metody měření nejčastěji používají, a s jakou úspěšností.

1.1.1. In situ data

In situ nebo také bodová měření půdní vlhkosti zjišťují obsah půdní vlhkosti v určitém časovém bodě na daném místě. Vlhkost půdy in situ se měří pomocí gravimetrické metody, technologie neutronových sond, reflektometrie nebo tenzometrů (Dobriyal a kol., 2012; Srivastava, 2017).

Měřicí senzory mohou způsobit chyby zapříčiněné špatnou instalací, načasováním nebo kalibrací (Plauborg a kol., 2005; Mittelbach a kol., 2012). Další chyby v in situ měření půdní vlhkosti mohou být důsledkem rozdílných hloubek, ve kterých bylo měřeno, různých prostorových měřítek nebo principů měření (Brocca a kol., 2007). Vzhledem k časové a prostorové variabilitě půdní vlhkosti je její odhad pomocí pozemních měření značně náročný. Rozmístění měřicích senzorů však může poskytnout taková bodová měření, která nám pomohou pochopit vzorce půdní vlhkosti v rámci malých měřítek. Jejich rozšíření do většího měřítka, např. povodí, by ovšem bylo velmi nákladné a časově náročné, proto se pro monitoring rozsáhlejších území lépe hodí dálkové snímání (Santi a kol., 2013). Toto měření ke svému výzkumu půdní vlhkosti použil např. Litschmann (2015).

1.1.2. Modely založené na datech půdní vlhkosti

Jelikož družice jsou schopné odhadnout vlhkost půdy pouze do hloubky pár centimetrů, potenciálním řešením je pro simulaci půdní vlhkosti v hlubších vrstvách využít hydrologické modely. Modelované odhady půdní vlhkosti se počítají za využití kvantitativních metod. Modely popisují vzájemné interakce mezi atmosférou a zemí prostřednictvím simulovaných výměn hybnosti, tepla a vody (Tavakol a kol., 2021). Modelová data o vlhkosti půdy mohou být využita k hodnocení průtoků, záplav či sucha (Case, 2016), predikci výnosů plodin (Bandaru a kol., 2017), nebo k posouzení hydrologických změn v čase (Xue a kol., 2018).

Např. a Koster (2005) ve své studii zkoumali model simulující roční cyklus vlhkosti půdy v povrchové a kořenové zóně, zatímco Wagner a kol. (1999) pro detekci změn v čase vyvinul algoritmus na vyhledávání půdní vlhkosti.

1.1.3. Určování půdní vlhkosti pomocí DPZ

Metody dálkového průzkumu půdní vlhkosti se od 70. let 20. století neustále vyvíjí a zdokonalují. V posledních několika desetiletích bylo vypuštěno mnoho satelitů za účelem monitoringu prostorových a časových změn zemského povrchu (Babaeian a kol., 2019). Vypuštění družice Sentinel-1 v roce 2015 vedlo ke snížení chyb při odhadech půdní vlhkosti. Do té doby totiž mikrovlnný dálkový průzkum dosahoval prostorového rozlišení pouze od desítek do 50 metrů, zatímco odhady půdní vlhkosti pomocí optických dat Sentinel-1 se pohybují v prostorovém rozlišení 5x20 m s periodou opakování 6–12 dnů (Santi a kol., 2013). V minulém století byly také definovány indexy sucha, které mají pomoci při jeho hodnocení.

Nejen Notarnicola a kol. (2006), ale i mnoho dalších autorů ve svých studiích dokládají, že dálkové snímání je vhodným nástrojem pro sledování vlhkosti půdy v prostoru i čase. Dále se odrazivost povrchu využívá také např. pro rozlišení krajinného pokryvu, nesklizených polí od sklizených, nebo k detekci začátku a konce vegetačního období.

Obsah vody v půdě a vegetaci lze monitorovat díky vlivu vody na odrazivost povrchu. Podle odlišné spektrální odrazivosti je možné určit, kde je vody nadbytek nebo naopak nedostatek. K extrakci informací o vlhkosti půdy se využívají různé metody v závislosti na typech senzorů - aktivní, pasivní (Ahmed a kol., 2011). Pro monitoring vlhkosti půdy pomocí DPZ lze použít všechny části elektromagnetického spektra, ale jak uvádí Wigneron (2017), nejvhodnější je pásmo L. Důvodem je, že přijímané signály nejsou téměř ovlivněny atmosférou, drsností povrchu a vegetací.


Porovnáme-li zjišťování povrchové vlhkosti půdy pasivními a aktivními senzory, monitoring pasivními senzory byl vyhodnocen jako robustnější. Aktivní signál je silně ovlivňován vegetačním krytem a drsností povrchu, jež mají vliv na jeho rozptyl a útlum (Narvekar a kol., 2015).

Proto Narvekar a kol. (2015) ve své studii vytvořil algoritmus pro vlhkost půdy, jež je navržen pro práci s radarovými měřeními v pásmu L. Navržený algoritmus je aplikovatelný s konfigurací snímání mise *Soil Moisture Active Passive* (SMAP), avšak jeho využití je mimo podmínky zahrnuté v souborech dat použitých při jeho vývoji omezené.

1.2. Spektrální odrazivost vody

Pro kapalnou vodu je charakteristická nízká odrazivost na všech vlnových délkách. Závisí však na obsahu biologických a mechanických příměsí. Čím větší je jejich zastoupení, tím větší množství záření je od nich odraženo. Z Obrázku 1 lze vyčíst, že zakalená voda záření odráží, jeví se tedy světleji (od 950 nm pak černě), zatímco čistá ho absorbuje a zobrazuje se tak tmavší (Kolář, 1990).


Obrázek 1: Spektrální odrazivost čisté a zakalené vody.



Zdroj: převzato z Kolář 1990

Obecně platí, že přítomnost vody v půdě snižuje odrazivost. Množství vody, kterou půda zadrží, závisí na její struktuře, na velikosti částic. Jak ukazuje Obrázek 2, mnohem více záření odrazí prachová hlína, jelikož má větší částice a půda tak rychleji vyschne. Naopak čím jemnější je půdní struktura, tím vyšší obsah vlhkosti je půda schopna udržet. Půdní vlhkost tak pohltí větší množství energie a jen minimum odrazí. Proto se půda nasycená vodou jeví tmavě. Maximálních hodnot odrazivosti půda nabývá na vlnových délkách 1800 nm, naopak minimálních v absorpčních páslech na vlnových délkách 1400 a 1900 nm (Kolář, 1990).

Obrázek 2: Spektrální odrazivost půdy v závislosti na její vlhkosti.




Zdroj: převzato z Kolář 1990

1.3. Spektrální odrazivost vegetace

Spektrální odrazivost vegetace nám pomáhá určit její zdravotní stav. Jak ukazuje Obrázek 3, zdravá vegetace nejvíce dopadajícího záření absorbuje v modré a červené části spektra, tedy na vlnových délkách 450 a 670 nm. K odražení záření dochází v zelené části spektra na vlnové délce 550 nm - to je také důvod, proč vidíme listy zeleně - a v blízké infračervené

části spektra. Poškození vegetace mění její spektrální vlastnosti, což se projevuje sníženou schopností absorpce (Opreanu, Lăzărescu 2016). V zelené a střední infračervené části spektra tak můžeme pozorovat větší odrazivost než u zdravé vegetace. Naopak nižší hodnoty jsou zaznamenány v blízké infračervené části spektra.


Obrázek 3: : Spektrální odrazivost zdravé a poškozené vegetace.



Zdroj: převzato z Opreanu, Lăzărescu 2019

Odrazivost listnaté a jehličnaté vegetace je odlišná. Listnatá vegetace má odrazivost vyšší, tudíž se jeví světleji. Důvodem je rozdílná buněčná struktura a větší plocha listu nežli má jehlice, tudíž list odrazí větší množství záření. Na Obrázku 4 lze pozorovat, že na křivce odrazivosti vegetace se projevují tři minima na vlnových délkách 1400, 1900 a 2700 nm. Jedná se o vodní absorpční pásy, kde je odrazivost vegetace, ať už listnaté či jehličnaté, nízká (Kolář a kol., 2000).

Obrázek 4: Spektrální odrazivost borovice vejmutovky.



Zdroj: převzato z ECOSTRESS Spectral Library 2013

1.4. Faktory ovlivňující radarové měření půdní vlhkosti

Elektromagnetické záření v mikrovlnném oboru spektra má několik vlastností, kterými je charakterizováno - polarizaci, amplitudu a vlnovou délku vyjadřovanou také jako frekvenci. Intenzita odraženého záření závisí na konfiguraci senzoru a emisivitě, jež se u různých povrchů liší. Emisivita povrchu je různá v závislosti na jeho drsnosti, elektrických vlastnostech a obsahu vody (Kolář, 2008). Podle Lakhankar a kol., (2009) je odezva půdní vlhkosti ze zemského povrchu na mikrovlnný systém dálkového průzkumu ovlivněna parametry jako je krajinný pokryv, hustota vegetace a textura půdy. Kvůli nim je získávání přesných informací o obsahu vody v půdě složitější. Brogioni a kol. (2010) ve své studii uvádí, že přesnost vyhledávání a získání co největšího množství informací o zemském povrchu je možné zlepšit použitím mikrovlnného záření na různých vlnových délkách, různě polarizované a s rozdílným úhlem dopadu.

Podle drsnosti povrchu rozlišujeme různé odražeče. Povrch hladký funguje jako zrcadlový odražeč a intenzita zpětně odraženého záření je pouze nízká, tudíž se na snímku z radaru jeví tmavě (např. klidná vodní hladina, silnice). Naopak nejvíce energie se odrazí od koutového odražeče, jakými jsou plochy, na které záření dopadá pod úhlem 45° (např. domy). Termín difuzní odražeč se používá v případě odrazu záření od drsného povrchu, který se na získaném snímku jeví různými odstíny šedé barvy. U drsných povrchů také platí, že pokud jsou vlhké, odrazí se od nich větší množství signálu, než kdyby byly suché (Kolář, 2008).

1.4.1. Vlnová délka nebo frekvence

Frekvence je nepřímo úměrná vlnové délce. Tedy s rostoucí vlnovou délkou frekvence mikrovlnného záření klesá. Hloubka, do jaké je dopadající záření schopné skrze povrch proniknout, závisí na jeho frekvenci (Kolář, 2008). Lakhankar a kol. (2009) uvádí, že pro odhad půdní vlhkosti jsou nejčastěji používána pásma L (15–30 cm, tzn. 1–2 GHz) a C (3,75–7,50, tzn. 4–8 GHz). Toto tvrzení podporuje také Kolář (2008). Pásmo L kvůli delším vlnovým délkám může do povrchu půdy nebo do vegetace proniknout hlouběji. V nepříliš husté vegetaci se však snižuje jeho citlivost na vegetaci a více interaguje s podložím. Paloscia a kol. (2013) však poukazuje na to, že většina radarů se syntetickou aperturou (SAR), jako např. RADARSAT 2, COSMO SkyMed či TerraSAR-X, pracuje s pásmy C a X, které pro monitoring půdní vlhkosti nejsou příliš vhodné kvůli své citlivosti na vegetaci. Jeho názor tak rozporuje s Lakhankar a kol. (2009), který naopak tvrdí, že pásmo C je pro odhad půdní vlhkosti použitelné, a to v případech, kdy půda není pokryta vegetací.

1.4.2. Úhel dopadu

Čím více se úhel dopadajícího záření zvětšuje, tím více klesá citlivost mikrovlnného senzoru na vlhkost půdy. Při větším úhlu je totiž větší část signálu zachycena a zeslabena vegetací. Příspěvek půdy na celkovém rozptylu je tak snížen o energii zpětně rozptýlenou vegetací (Mo a kol., 1984). Vlhkost půdy je možné odvodit pomocí nízkého úhlu dopadu. Je totiž optimalizována pro snímání vlastností půdy a minimalizuje vliv vegetace a drsnosti povrchu na zpětný rozptyl (Lakhankar a kol., 2009).

1.4.3. Polarizace

Jak aktivní, tak pasivní mikrovlnné systémy jsou schopny měřit zpětný rozptyl za využití různé polarizace. Polarizace je dána uspořádáním elektrické a magnetické složky elektromagnetické vlny v rovině, která je kolmá na směr šíření vlnění. Jinými slovy se jedná o kmitání vektoru intenzity elektrického pole E a na něj kolmého vektoru indukce magnetického pole B , přičemž oba tyto vektory se vyskytují v rovině, jež je kolmá na směr šíření vlny. Nepolarizované záření lze rozeznat podle náhodného směru roviny vektoru E (Kolář, 2008).

Polarizaci lze rozlišit na vertikální (V), kdy se vektor E pohybuje kolmo k zemskému povrchu, a horizontální (H), při které je vektor E s povrchem rovnoběžný. Radarové antény

tak mohou vysílat a přijímat různě polarizované vlny - např. HH, VV, HV, VH (Kolář, 2008). Díky různým konfiguracím polarizace lze získat větší množství informací z různých vrstev zemského povrchu. Odrazivost objektů je různá v závislosti na polarizaci (Lakhankar a kol., 2009).

Pro odhad obsahu vody v půdě je vhodná HH polarizace, která je částečně schopna proniknout skrze vegetaci do půdy. Vysvětlením je, že horizontálně polarizované vlny stonky rostlin do určité míry obcházejí, zatímco vertikálně polarizované by se od nich odrazily. Kombinace polarizací se využívají např. pro odlišení vegetace a půdy nebo určení hustoty vegetace (Kolář, 2008).

1.5. Vlhkostní indexy využívající optická data

Pasivní mikrovlnné senzory (radiometry) poskytují data s prostorovým rozlišením 20 až 50 km a časovým rozlišením 12 až 24 hodin. V globálním měřítku jsou takovéto informace o půdní vlhkosti a vegetačních anomáliích důležité pro monitorování a předpovídání výnosů plodin (Doraiswamy a kol., 2004), jímž se ve svém výzkumu zabývá např. Krása a kol. (2019).

Informace o obsahu vlhkosti v půdě nebo vegetaci nemusí být získávány pozemním měřením, ale lze je změřit s určitým prostorovým a časovým rozlišením pomocí DPZ např. ze snímků družic Sentinel 2 (Alonso a kol., 2019). V mnoha studiích k tomu autoři využívají různé vlhkostní indexy a modely. Níže jsou popsány některé z nich.

1.5.1. Normalized Soil Moisture Index (NSMI)

Výsledky studie od Musik a Pelletier (1986), kteří analyzovali měření vlhkosti půdy z optických dat DPZ, vedly ke stanovení korelace mezi poměrem pásem SWIR Landsat-5 a obsahem vlhkosti v půdě. Na základě toho Haubrock a kol. (2008) za využití pásem SWIR Sentinel-2A definoval normalizovaný index vlhkosti půdy jako ukazatel obsahu vody v půdě označovaný také jako NSMI (z angl. *Normalized Soil Moisture Index*) rovnicí:

$$NSMI = \frac{\rho_{11} - \rho_{12}}{\rho_{11} + \rho_{12}},$$

kde ρ_{11} vyjadřuje odrazivost v pásmu 11 (SWIR, 1613 nm) a ρ_{12} odrazivost v pásmu 12 (SWIR, 2202 nm). Nejen Haubrock a kol. (2008), ale i Hong a kol. (2017) ve svých studiích dokazují, že NSMI je vhodným ukazatelem obsahu vody v půdě.

Jedním z faktorů, na kterém hodnoty indexu závisí, je vegetační kryt pixelu, jež je mimo jiné ovlivněn přítomností vody. Alonso a kol. (2019) uvádí, že aby se dosáhlo přesnějších výsledků, je nutné pixely klasifikovat do tříd. Toto tvrzení podporuje také výsledek studie od Adegoke a Carleton (2002). Jak uvádí Tucker (1979), pro rozlišení vegetačního krytu jednotlivých pixelů pomocí dálkového průzkumu je vhodné využít NDVI.

Alonso a kol. (2019) zabývající se korelací mezi NSMI a NDVI za využití Sentinel-2 došli k nejlepším výsledkům při klasifikaci pixelů do tří tříd - pixely bez vegetace (s holou půdou), plně pokryté vegetací a pixely se směsí vegetace. Výsledek studie tak dokládá, že mezi NSMI a těmito třídami lze za využití statistických modelů opravdu prokázat korelaci.

1.5.2. Normalized Difference Moisture Index (NDMI)

Normalizovaný rozdílový index vlhkosti využívá k zobrazení vlhkosti pásmo NIR a SWIR. Používá se ke sledování změn obsahu vody v listech, tudíž lze využít pro určení úrovně vodního stresu plodiny a pro odhad zdravotního stavu vegetace. Počítá se jako poměr mezi rozdílem a součtem lomeného záření v blízké infračervené oblasti (NIR) a krátkovlnné oblasti infračerveného záření (SWIR; Taloor a kol., 2021):

$$NDMI = \frac{(NIR - SWIR)}{(NIR + SWIR)}.$$

Pásmo SWIR odráží změny obsahu vody ve vegetaci, zatímco odrazivost v pásmu NIR je ovlivněna buněčnou strukturou listů. Kombinace těchto pásem odstraňuje změny způsobené vnitřní strukturou listů a obsahem sušiny listů, díky čemuž je získávání obsahu vody ve vegetaci přesnější. Množství vody dostupné ve vnitřní struktuře listu z velké části řídí spektrální odrazivost v pásmu SWIR. Odrazivost SWIR tedy negativně souvisí s obsahem vody v listech.

Jeho hodnoty se pohybují mezi -1 a +1, přičemž každá hodnota odpovídá jiné agronomické situaci, nezávisle na plodině. Hodnoty NDMI tak umožňují rozpoznat pole s vodním stresem (Gao, 1996).

1.5.3. Normalized Difference Water Index (NDWI)

Nejvhodnější pro mapování vodních ploch a sledování jejich změn je normalizovaný rozdílový vodní index. Jelikož voda silně absorbuje světlo v rozsahu od viditelné po infračervenou část elektromagnetického spektra, NDWI ke zvýraznění vodních ploch využívá zelené a blízké infračervené pásmo:

$$NDWI = \frac{(GREEN - NIR)}{(GREEN + NIR)}.$$

Je citlivý na zastavěná území a často nadhodnocuje vodní plochy (Taloor a kol., 2021).

1.6. Vegetační indexy využívající optická data

Vegetační indexy jsou definovány jako aritmetické kombinace dvou nebo více pásem souvisejících se spektrálními charakteristikami vegetace (Heute a kol., 1999). Poskytují prostorové a temporální informace o vegetaci. Ty však nemusí být přesné kvůli vlivu topografie, atmosférických podmínek, půdě v pozadí porostu nebo příměsí v porostu. Tyto vlivy způsobují zvýšení nebo snížení odrazivosti ve viditelné a blízké infračervené části spektra, přičemž v obou částech spektra jsou vlivy srovnatelné (Lee, Kaufman, 1986).

Mnoho vegetačních indexů bylo vyvinuto za využití měření v červeném a blízkém infračerveném pásmu. Důvodem je, že ve srovnání s povrchem bez vegetace zelené listy absorbují více viditelného záření pro fotosyntézu a méně blízkého infračerveného (Chen, 1996). Nejpoužívanějším vegetačním indexem je normalizovaný rozdílový vegetační index (NDVI).

1.6.1. Normalized Difference Vegetation Index (NDVI)

Normalizovaný rozdílový vegetační index je poměrový vegetační index. Vypočítá se na základě počtu pixelů jako normalizovaný rozdíl mezi červeným pásmem a blízkým infračerveným pásmem pomocí vzorce:

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)}.$$

Podle jeho hodnot, které nabývají od -1 do +1, je možné rozeznat krajinný pokryv. Záporné hodnoty většinou představují vodní plochy, hodnotám blízko nule odpovídá povrch bez vegetace, např. zástavba, a vysoké hodnoty blíží se jedné vypovídají o hustší vegetaci, jako jsou např. lesy. Podle hodnot NDVI lze také monitorovat zdravotní stav vegetace. Vysoké hodnoty dokládají dobrý zdravotní stav vegetace, naopak vegetace ve stresu vykazuje hodnoty nižší (Hang a kol., 2021).

NDVI ve své studii použil např. Santi a kol. (2013) pro zohlednění vegetačního vlivu při odhadu půdní vlhkosti pomocí SAR a hydrologického modelu, nebo Alonso a kol. (2019) při zkoumání korelace vegetačního indexu s vlhkostí v půdě. Ačkoliv někteří autoři zpochybňují korelaci mezi NDVI a obsahem půdní vlhkosti měřeným pomocí NSMI, Alonso a kol. (2019) ve své studii prokázal, že NSMI a NDVI spolu korelují, a to i přes to, že podle Rundquist a Harrington (2000) je mezi deficitem srážek a reakcí NDVI časová prodleva. Pro zjištění korelace Alonso a kol. (2019) navrhuje klasifikovat pixely jednotlivých snímků na základě hodnot NDVI do třech tříd: holá půda ($NDVI < 0,2$), směs půdy a vegetace ($0,2 \leq NDVI \leq 0,5$) a plný vegetační zápoj ($NDVI > 0,5$).

Tento index patří k nejběžněji používaným vegetačním indexům a to díky schopnosti redukovat některé formy šumu způsobené topografií, oblačností či stínem (Heute a kol., 1999). Nicméně jeho nevýhodou je citlivost na různorodé pozadí porostu, což může být zdrojem chyb (Liu, Heute, 1995; Gao, 1996). Na základě toho byl navržen níže popsáný vegetační index EVI, který do NDVI zahrnuje jak pozadí, tak vliv atmosféry (Liu, Heute, 1995).

1.6.2. Enhanced Vegetation Index (EVI)

EVI je vegetační index, který vznikl modifikací NDVI. Oproti NDVI redukuje nepříznivé vlivy atmosféry a půdy, a to díky využití odrazivosti modrého pásma. Jeho nevýhodou je senzitivita na topografické podmínky, což se může projevit zejména v kopcovitých nebo hornatých oblastech. Tato citlivost je dána faktorem úpravy půdy L . Proto je nutné před výpočtem odstranit v datech odrazivosti vliv topografie. Výpočet EVI je dán rovnicí:

$$EVI = G * \frac{(NIR - RED)}{(NIR + C1 * RED - C2 * BLUE + L)},$$

jejíž součástí je faktor G , jehož hodnota se zpravidla rovná 2,5, dále koeficienty odolnosti vůči aerosolům $C1 = 6$, $C2 = 7,5$ a faktor pro úpravu půdního krytu $L = 1$ (Huete a kol., 1997).

1.6.3. Difference Vegetation Index (DVI)

Vegetační index DVI lze vypočítat rozdílem pásem NIR a RED:

$$DVI = NIR - RED .$$

Jeho výhodou je schopnost rozlišit půdu a vegetaci, jelikož je citlivý na změny půdního pokryvu. Proto se využívá k monitoringu vegetačního prostředí. Nezohledňuje však rozdíl mezi atmosférickými efekty či stíny (Driese, 2012).

1.7. Radarové vegetační indexy

Mikrovlnné systémy dálkového průzkumu mají velký potenciál v prostorovém odhadu vlhkosti půdy (např. pro odhad kolísání výnosů plodin, ať už v regionálním nebo globálním měřítku). Radary se syntetickou aperturou (SAR) poskytují vysoké prostorové rozlišení až 10 m. Také jsou oproti pasivním mikrovlnným senzorům citlivější na charakteristiky povrchu. Jak uvádí Doraiswamy a kol. (2004), data s vysokým prostorovým rozlišením se hojně uplatňují např. v precizním zemědělství. Využitím v tomto sektoru se ve své bakalářské práci podrobně věnuje např. Strnadová (2019).

1.7.1. Radar Vegetation Index (RVI)

Radarový vegetační index RVI je jeden z indexů polarizovaných dat radaru se syntetickou aperturou SAR. Jeho matematické vyjádření udává rovnice:

$$RVI = \frac{8\gamma_{HV}^0}{\gamma_{HH}^0 + \gamma_{VV}^0 + 2\gamma_{HV}^0} ,$$

kde γ^0 představuje radiometricky a geometricky opravený koeficient zpětného rozptylu SAR pro každou kombinaci polarizací v jednotkách (m^2/m^2). Hodnoty blízko nule odpovídají hladkému holému povrchu a narůstají spolu s růstem vegetace (Flores a kol., 2019).

Vyšší hodnoty odpovídají vegetaci, což je způsobeno její vysokou odrazivostí v pásmu blízkého infračerveného záření, zatímco nižší vodním plochám, ledu, či půdě. Na rozdíl od NDVI a DVI redukuje vliv atmosféry a topografie. Pokud jsou však oblasti pokryté vegetací

pouze řídce (50 % a méně), index se stává citlivějším na atmosférické vlivy. Jelikož je tento index citlivý na vegetaci a podle studií bylo také prokázáno, že dobře koreluje s rostlinnou biomasou (Kim, 2012; Mandal, 2020) a s indexem NDVI optických snímků (Kim, 2014), používá se pro její odhady a sledování při pokrytí půdy hustou vegetací (Flores a kol., 2019).

2. Charakteristika zájmového území

Celkem bylo vybráno 37 půdních bloků nacházejících se v okrese Písek v okolí obcí Putim, Heřmaň či Skály. Jejich rozmístění si lze prohlédnout na Obrázku 5. Všechna pole se rozprostírají v kulturní krajině Českobudějovické pánve, v níž se hojně vyskytují rybníky, tudíž je zde vysoká hladina podzemních vod. Jedná se o zemědělsky obhospodařovaná pole o různé rozloze s všesměrnou expozicí. Přehledové mapy skupin půdních bloků, do nichž byla pole za účelem sledování vlivu podřívání rozdělena, spolu s údaji o jejich rozloze a podřívání je možné si prohlédnout v Příloze 1–10. Leží v nadmořské výšce od 360 do 435 m n. m. a jejich sklonitost nepřekračuje 4°, tudíž se nachází v rovině.


Podle katalogu BPEJ se pole rozprostírají v mírně teplém a mírně vlhkém klimatickém regionu. Převládajícím půdním typem na zájmových polích jsou fluvizemě, dále se zde ale také vyskytují regozemě, pseudogleje a kambizemě. Všechny tyto půdní typy jsou málo či dokonce velmi málo produkční, středně hluboké až hluboké, tedy od 30 do 60 cm, a nejsou vhodné k zatravnění ani zástavbě.

V rámci jednotlivých polí byl uskutečněn terénní výzkum, při němž byla sledována např. heterogenita mezi poli či topografické charakteristiky. Byl zjištěn výskyt problémových holých ploch, kde se plodinám nedaří. Příklad takové plochy je možné vidět na Obrázku 6 a 7. Na pohled bylo zřejmé, že příčinou je dlouhodobá nežádoucí přítomnost stojaté povrchové vody. Mezi lety 2016–2020 bylo proto Českým ústavem zemědělské techniky (ČÚZT) uskutečněno podřívání vybraných polí do hloubky 30–50 cm za cílem prokypření, obnovení schopnosti retence vody a minimalizování holých problémových ploch.

Jelikož se zkoumaná pole nachází v blízkosti rybníků, struh a mokřadů, ostatně Českobudějovická pánev je rybníkářskou oblastí, je v této oblasti vysoká hladina podzemních vod. Proto není nic neobvyklého, že deprese na polích bývají přemokřené, technika zde zapadá a plodinám se na takových místech nedaří. Do takto vlhkých depresí se pak koncentruje také voda ze zbytku pole, které je obhospodařované těžkou technikou, a půda je zde v porovnání s problémovými plochami více zhutnělá. Voda se na takových místech hůře vsakuje,

a proto většina odteče, koncentruje se do zmíněných depresí, nebo se podílí na evapotranspiraci. Tento efekt se projevuje i přes to, že podle kódů BPEJ je většina zkoumaných půdních bloků utužením ohrožena pouze mírně.

Obrázek 5: Poloha jednotlivých polí (modře - pole podrytá v roce 2016, žlutě - pole podrytá v roce 2017, fialově - pole podrytá v roce 2018, zeleně - pole podrytá v roce 2019, červeně - pole podrytá v roce 2020).



Zdroj: VÚZT, ČÚZK 2022

Obrázek 6: Problematická plocha na zájmovém půdním bloku.



Zdroj: vlastní zpracování 2022

Obrázek 7: Problematická holá plocha na zájmovém půdním bloku.



Zdroj: vlastní zpracování 2022


3. Data

Pro výpočet hodnot indexů z družicových dat byla využita data družic Sentinel, jenž jsou součástí programu Copernicus. Mise Sentinel-1 se skládá ze dvou polárních družic - Sentinel-1A, která byla na oběžnou dráhu vypuštěna v roce 2014, a Sentinel-1B, jež je

v provozu od roku 2016. Měřicím přístrojem družic Sentinel-1 je radar. Jedná se o aktivní mikrovlnný senzor pracující v pásmu C (Hang et al., 2021). Vysílá vlastní zdroj mikrovlnného záření a díky tomu není závislý na Slunci a může snímat zemský povrch i v noci. Další výhodou radaru je, že mikrovlnné záření je schopné proniknout skrze oblaky, déšť či mlhu, což optický senzor družic Sentinel-2 nedokáže (Hang et al., 2021).

Mise Copernicus Sentinel-2 se skládá z konstelace dvou polárních družic - Sentinel-2A, jež byla vypuštěna v roce 2015, a Sentinel-2B z roku 2017. Jejich oběžná dráha je synchronní se Sluncem a doba oběhu Země v bezoblačných podmínkách odpovídá pěti dnům. Na rozdíl od družic Sentinel-1 snímání zajišťuje pasivní multispektrální optický senzor. Není tedy zdrojem záření, ale přijímá sluneční záření odražené od zemského povrchu. Družice Sentinel-2 snímají zemský povrch ve 13 optických pásmech od viditelné části elektromagnetického spektra (VIS, 493 nm) po krátkovlnnou infračervenou oblast spektra (SWIR, 2202 nm). Prostorové rozlišení snímků pořízených v jednotlivých spektrálních pásmech je různé. Na Obrázku 8 si můžeme prohlédnout čtyři pásma s prostorovým rozlišením 10 m. Jedná se o pásmo B2 (blue, 490 nm), B3 (green, 560 nm), B4 (red, 665 nm) a B8 (NIR, 842 nm).


Obrázek 8: Pásma s prostorovým rozlišením 10 m.



Zdroj: převzato ze Sentinel Online 2020

Snímky pořízené v šesti pásmech znázorněných na Obrázku 9 mají rozlišení 20 m. Patří sem pásmo B5 (705 nm), B6 (740 nm), B7 (783 nm), B8a (865 nm), B11 (SWIR, 1610 nm) a B12 (SWIR, 2190 nm).


Obrázek 9: Pásma s prostorovým rozlišením 20 m.



Zdroj: převzato ze Sentinel Online 2020

Pouze ve třech pásmech, jež je možné vidět na Obrázku 10, jsou pořizovány snímky s prostorovým rozlišením 60 m a to v pásmu B1 (443 nm), B9 (940 nm) a B10 (SWIR, 1375 nm; Agapiou et al. 2014; Sentinel Online, 2020).

Obrázek 10: Pásma s prostorovým rozlišením 60 m.



Zdroj: převzato ze Sentinel Online 2020

Pro výpočet hodnot indexů z optických dat nad zájmovými oblastmi byly použity snímky družice Sentinel-2, pro radarový index RVI pak snímky z družice Sentinel-1 z období 2017–2020. Časové řady hodnot indexů byly vygenerovány pomocí aplikace Google Earth Engine.

Vektorové vrstvy zájmových polí s doprovodnými atributy o rozloze či hloubce podrvání byly poskytnuty Výzkumným ústavem zemědělské techniky, s nímž byla v rámci tohoto výzkumu navázána spolupráce.

Obecná charakteristika vybrané oblasti byla získána za využití volně dostupných dat Českého úřadu zeměměřického a katastrálního (ČÚZK), Státního pozemkového úřadu (SPÚ)

a geodatabáze ArcČR 500. Konkrétně z geodatabáze ArcČR 500 byly pro tvorbu DEM (*Digital Elevation Model*) použity vrstevnice, z ČÚZK vrstva WMS - ZM 50 a od SPÚ vektorová vrstva s hranicemi BPEJ.

Záznamy o průměrných denních teplotách vzduchu a denním úhrnu srážek ve sledovaném období byly čerpány z volně dostupných dat ČHMÚ. Použitá data byla naměřena meteorologickou stanicí ve Strakonici, jež byla nejbližší stanicí ke zkoumané oblasti, pro kterou byla dostupná data za požadované období 2017–2020.

Pro lepší interpretaci výsledků byly použity poznatky z terénního průzkumu, konkrétně topografické charakteristiky či heterogenita mezi poli.

4. Metody

4.1. Výběr a výpočet indexů

Pro stanovení hodnocení soil moisture byly vybrány relevantní indexy. V první řadě byl vybrán index NDMI, jež je hojně používán (Rahman, Mesev, 2019; Malakhov, Tsyhuyeva, 2020; Taloor a kol., 2021). Dále byl vybrán index NSMI reflektující vlhkost v půdě (Haubrock, 2008; Hong a kol., 2017; Alonso a kol., 2019).

Jako představitel vegetačních indexů využívajících optická data byl pro monitorování stavu vegetace vybrán NDVI a to nejen proto, že patří k nejčastěji používaným vegetačním indexům (Matsushita a kol., 2007; Alonso a kol., 2019; Hang a kol., 2021), z radarových spektrálních indexů pak RVI. Využitím radarových dat byl redukován vliv oblačnosti.

Výpočet vybraných indexů byl proveden pomocí algoritmu aplikace Google Earth Engine nad družicovými snímky Sentinel-1 a Sentinel-2, viz. <https://code.earthengine.google.com/98d9d34dcbafe31aca1db8a4cfec5619>. Do výpočtů indexů optických dat byly zahrnuty pouze takové snímky Sentinel-2, které byly pokryty oblačností do 50 %. Následovně byl pro její odmaskování použit algoritmus S2cloudless, jež je detailně popsán ve studii López-Puigdollers a kol. (2021).

Hodnoty indexů byly postupně vypočteny pro všechny skupiny půdních bloků, které byly podryté v roce 2016, až po pole podrytá v roce 2020. Pole podryté roku 2016 byly do výzkumu zařazeny i přes zkoumané období 2017–2020 za účelem zjištění nástupu efektu podryvání také.

4.2. Zpracování dat a analýza časových řad

Pro zpracování dat byla využita především aplikace Google Earth Engine, dále SW Microsoft Excel a ArcGIS Pro.

Za účelem zjištění vlivu podřívání zájmových půdních bloků na jejich schopnost retence vody a růst plodin bylo třeba získat časové řady hodnot vlhkostních a vegetačních indexů. Toho bylo dosaženo pomocí aplikace Google Earth Engine, ve které bylo nejdříve zapotřebí vytvořit algoritmus pro jejich vygenerování. Zápis algoritmu byl proveden v programovacím jazyku JavaScript. Výsledné hodnoty indexů byly spočteny jako průměr z hodnot pixelů v rámci skupiny polí. Pro každou skupinu polí byly časové řady hodnot za období 2017–2020 vygenerovány pomocí Google Earth Engine zvlášť, jelikož byly podřívány v rozdílných letech.

Následně byly časové řady hodnot indexů NSMI, NDMI, NDVI a RVI extrahovány do formátu CSV a vloženy do softwaru Microsoft Excel, kde z nich spolu s daty o teplotách a srážkách byly vytvořeny grafy a vypočteny statistické charakteristiky. Pro každou skupinu půdních bloků podřítou v daném roce byly zjištěny roční průměry indexů v období 2017–2020, Pearsonův korelační koeficient a měsíční maxima a minima. Pearsonův korelační koeficient byl vypočten za účelem zjištění případné korelace mezi hodnotami indexů navzájem či jejich korelace s úhrny srážek a teplotami. Poté byly vytvořeny časové řady zvlášť pro každý index, aby bylo možné porovnat průběh indexů mezi skupinami polí. Pro přehlednost a snazší porovnání byly také zkonstruovány tabulky s průměrnými ročními hodnotami. Zájem byl soustředěn hlavně na to, zda se podřívání polí na hodnotách indexů nějakým způsobem projevilo či nikoliv, tedy zda hodnoty NSMI, NDMI, NDVI a RVI naměřené na podřítých polích dosahovaly lepších výsledků než na nepodřítých. Při zkoumání vlivu podřívání na vlhkost a vegetaci, byly v úvahu brány také průměrné teploty a úhrny srážek, jež mají vliv na přítomnost vody v krajině a růst plodin.

ArcGis Pro byl využit pro získání informací o nadmořské výšce, sklonitosti či identifikaci půdních typů na zájmových plochách. Ke zjištění nadmořské výšky byl za využití vektorové vrstvy vrstevnic po 50 metrech a funkce *Topo to Raster* vytvořen DEM, díky kterému byl také zhotoven model sklonitosti. Pro identifikaci půdních typů byly přes sebe překryty vektorové vrstvy s hranicemi BPEJ a hranicemi půdních bloků.

5. Výsledky

Jelikož období 2017–2020 bylo z hlediska meteorologických podmínek poměrně variabilní, hodnoty indexů byly porovnány s úhrny srážek a průměrnými teplotami. Z Tabulky 1 je možné vyčíst, že nejsušším rokem byl rok 2019 s celkovým úhrnem srážek 530 mm. Také průměrná roční teplota vyšplhala poměrně vysoko, konkrétně na 10,3 °C. Naopak nejvyšší úhrn srážek naměřený za rok 2020 činil 637 mm a průměrná roční teplota vzduchu byla o 1,1 °C nižší než v roce 2019.

Tabulka 1: Roční úhrny srážek a průměrné roční teploty spočtené z denních měření ve Strakonících v období 2017–2020.


	Roční úhrn srážek [mm]	Průměrná roční teplota [°C]
2017	586.8	9.5
2018	546.6	10.34
2019	529.9	10.30
2020	637.4	9.2

Zdroj: ČHMÚ 2022; výpočty autora

Výsledky Pearsonova korelačního koeficientu (r), jež si můžeme prohlédnout v Tabulce 2, vypovídají o určité korelaci mezi jednotlivými indexy. Největší korelace je patrná mezi půdní vlhkostí (NSMI) a hustotou vegetace (NDVI), kde $r = 0,934$. Potvrzuje se zde tedy, že hustota vegetace má vliv na obsah vody v půdě, stejně jako půdní vlhkost ovlivňuje hustotu vegetace. Podíváme-li se na Obrázek 11, odpovídají tomu také průběhy hodnot indexů. Konkrétně při červencovém poklesu hodnot NDVI v roce 2017 o 64 %, klesly i hodnoty NSMI o 65 %. Pokud jsou tedy plodiny sklizeny a pole jsou holá, v půdě se zadrží méně vody. V případě, že obsah půdní vlhkosti je vysoký, bude tomu odpovídat větší hustota vegetace, což je dobře patrné v červnu roku 2019, kdy hodnoty NSMI stouply o 160 % a NDVI o 117 %. Také mezi NDVI a NDMI je podle jejich průběhu hodnot a Pearsonova korelačního koeficientu, který se rovná 0,775, značná korelace. Např. při dubnovém nárůstu hodnot NDVI roku 2020 o 8 %, vzrostly hodnoty NDMI o 44 %. Tento výsledek dokládá, že čím hustěji jsou pole pokryta vegetací, tím vyšších hodnot dosahuje obsah vody v ní.

Pearsonův korelační koeficient mezi srážkami a hodnotami indexů však korelaci nenaznačuje. Konkrétně mezi srážkami a NSMI se rovná $r=0,092$, či teplotami a NDVI $r=0,006$. Jak můžeme vidět na Obrázku 13, příčinou je zpožděná reakce vegetace (NDVI) a vlhkosti v půdě (NSMI) i vegetaci (NDMI) na tyto meteorologické charakteristiky.

Obrázek 11: Průběh hodnot indexů NSMI, NDMI, RVI a NDVI na Polích 20 za období 2017–2020.



Tabulka 2: Hodnoty Pearsonova korelačního koeficientu pro jednotlivé indexy, teploty a srážky pro Pole 20.

	NDMI	NSMI	NDVI	RVI	Srážky	Teplota
NDMI	1.000	0.769	0.775	0.686	0.042	-0.203
NSMI	0.769	1.000	0.934	0.715	0.092	0.018
NDVI	0.775	0.934	1.000	0.728	0.068	0.006
RVI	0.686	0.715	0.728	1.000	0.138	0.401
Srážky	0.042	0.092	0.068	0.138	1.000	0.102
Teplota	-0.203	0.018	0.006	0.401	0.102	1.000


Zdroj: Google Earth Engine, ČHMÚ 2022

Při porovnání hodnot NSMI (Obrázek 12) a NDMI (Obrázek 14) s úhrny srážek, jejichž průměrné měsíční hodnoty nalezneme v Příloze 11–14, nejnižších hodnot nabývají v červenci a srpnu, kdy NSMI dosahuje až 0,04 a NDMI až -0,2, a to i přes to, že v této části roku spadne nejvíce srážek. NDVI (Obrázek 15) a RVI (Obrázek 16) nejnižších hodnot až 0,1 dosahují hlavně v srpnu a září. Vysvětlením je nejen to, že vliv srážek se projeví až později, ale také skutečnost, že většina plodin je v tomto období sklizena a pole nejsou pokryta vegetací. Naopak nejvyšší obsah vody (NSMI, NDMI) a hustota vegetace (NDVI, RVI) byla během sledovaného období nejčastěji zaznamenána v květnu, kdy byla pole porostlá plodinami. Maximální hodnoty vlhkostního indexu NSMI sahaly až k 0,4, a NDMI k 0,6, zatímco hodnoty vegetačního indexu NDVI k 0,9 a RVI k 1,4.

Jak lze vypořádat z Obrázku 11, podle poklesu a nárůstu hodnot indexů, je dobře patrné, kdy se na polích sklízí, nebo začínají růst plodiny. Je zřejmé, že sklizeno bylo


po dosažení maximálních hodnot NDVI a RVI v daném roce, vypovídající o vysokém zápoji plodin a tedy i jejich dozrání. Jako příklad jsou uvedeny časové řady hodnot indexů pro Pole 20. Konkrétně roku 2017, 2018 a 2020 probíhala sklizeň od června do srpna, což dokládá pokles hodnot indexu NDVI v tomto období o 70–80 %, zatímco v roce 2019 byly plodiny sklizeny v průběhu září a října, kdy hodnoty NDVI klesly o 80 %. Naopak vzrůstající hodnoty indexů až o 130 % se projeví následně po výsevu jarních plodin, jež probíhá v březnu a dubnu, nebo setí ozimu na podzim v srpnu a září.

Obrázek 12: Srovnání průběhu hodnot NSMI pro jednotlivá pole v období 2017–2020.



Zdroj: Google Earth Engine 2022

Obrázek 13: Teploty a srážky naměřené ve Strakonících (levá osa) v porovnání s NSMI, NDMI a NDVI (pravá osa) Polí 20 v období 2017–2020 .




Zdroj: Google Earth Engine, ČHMÚ 2022

Co se týče podřívání, jeho efekt lze pozorovat v roce 2017, kdy se hodnoty půdní vlhkosti (Obrázek 12), obsahu vody ve vegetaci (Obrázek 14) a hustoty vegetace (Obrázek 15 a 16) na polích podřitých v roce 2016 drží v období od září do prosince v porovnání s nepodřitými skupinami polí značně vysoko. Hodnoty NSMI a NDVI vypočtené na Polích 16 v roce 2017 vypovídají o vůbec nejlepší situaci za sledované období na těchto půdních blocích a předčily tak i rok 2020, který byl srážkově nejvydatnější. Jak můžeme vidět v Tabulce 3, v roce 2017 se index NSMI rovnal 0,242 a vypovídal tak o vyšším obsahu vody v půdě než v roce 2020, kdy byl roven pouze 0,229. Také NDVI se svou průměrnou hodnotou 0,550 v roce 2017 dosáhl vyšší hodnoty než za rok 2020, za nějž nabýval pouze 0,534. Zatímco na ostatních skupinách půdních bloků situace v roce 2017 nebyla vzhledem k jejich průměrným ročním hodnotám až tak příznivá a na rozdíl od Polí 20 jejich hodnoty naměřené pro rok 2017 vypovídaly o horší situaci než roku 2020.

Naopak při srovnání průběhů hodnot Polí 17, jež byly podřity v roce 2017, s ostatními skupinami půdních bloků na Obrázku 12, 14, 15 a 16, nevidíme v roce 2018 mezi průběhem hodnot podřitých a nepodřitých skupin polí žádný zásadní rozdíl. Podřítí v roce 2017 se tedy následující rok neprojevilo. Vysvětlením mohou být nízké úhrny srážek v kombinaci s vysokými teplotami, jak lze sledovat na Obrázku 13.


Stav sucha a horka přetrvával i v průběhu roku 2019, avšak zde se podřítí z předešlého roku projevilo pozitivně. Z tabulky 3 lze vyčíst, že pro Pole 18 v roce 2019 byla spočtena průměrná hodnota NDMI 0,167 a vypovídala tak o nejvyšším obsahu vody v plodinách ze všech skupin polí. Také průměrná hodnota RVI za tento rok dosáhla v porovnání s ostatními zájmovými plochami maximální hodnoty 0,678. Nejvyšší obsah vody v půdě v roce 2019 byl na Polích 16, kdy průměrná roční hodnota indexu NSMI byla 0,204, zatímco u všech ostatních skupin polí nepřesáhl hodnotu 0,194. NDVI s průměrem za rok 2019 0,480 na Polích 16 také o nejhustší vegetaci. Vysvětlením hodnot vypovídajících o lepší vlhkostní a vegetační situaci v roce 2019 na Polích 16 a 18 je, že několik půdních bloků ze skupiny Pole 16 a Pole 18 bylo podřito jak v roce 2016, tak roku 2018, tudíž byly podřity již podruhé. Proto také i přes nepříznivé podmínky byly plodiny a půda schopny vodu z nízkých úhrnů srážek lépe zadržet a využít.

Obrázek 14: Srovnání průběhu hodnot NDMI pro jednotlivá pole v období 2017–2020.




Zdroj: Google Earth Engine 2022

Obrázek 15: Srovnání průběhu hodnot NDVI pro jednotlivá pole v období 2017–2020.



Zdroj: Google Earth Engine 2022

Obrázek 16: Srovnání průběhu hodnot NDMI pro jednotlivá pole v období 2017–2020.



Zdroj: Google Earth Engine 2022

Při vzájemném porovnání všech skupin polí, lze z přehledové Tabulky 3 a časových řad výše (Obrázek 12, 14, 15 a 16) vyčíst, že sucho a teplo v roce 2019 se na všech skupinách půdních bloků projevilo nejnižšími hodnotami z celého sledovaného období. Nejnižší průměrný obsah vody v půdě i hustota vegetace za tento rok byl zaznamenán na Polích 20, pro které index NSMI=0,187, NDVI=0,426 a RVI=0,496.

Naopak nejvyšší hodnoty vypovídající o vysokém obsahu vody v půdě i v rostlinách a husté vegetaci byly zjištěny v roce 2020, kdy byl celkový úhrn srážek 637.4 mm v porovnání s následujícími roky nejvydatnější (Tabulka 1). Také průměrná teplota 9,2 °C byla nižší, proto na polích bylo dostatek vlhkosti a hustý pokryv plodinami. Vůbec maximální hodnoty vypovídající o nejlepší vlhkostní a vegetační situaci však byly zjištěny na Polích 19, kde max. NDMI=0,215, NDVI=0,595 a RVI=0,756. Zde se potvrzuje, že podrytí těchto polí, jež se uskutečnilo v roce 2019, se v následujícím roce projevilo.

Tabulka 3: Průměrné roční hodnoty NSMI, NDMI, NDVI a RVI jednotlivých skupin půdních bloků za období 2017–2020 seřazené sestupně.

	Pole 16		Pole 17		Pole 18		Pole 19		Pole 20	
NSMI	2017	0.2423	2020	0.2384	2020	0.2293	2018	0.2440	2018	0.2559
	2020	0.2290	2018	0.2347	2017	0.2203	2020	0.2427	2020	0.2481
	2018	0.2067	2017	0.2222	2018	0.2109	2017	0.2413	2017	0.2475
	2019	0.2041	2019	0.1939	2019	0.1873	2019	0.1935	2019	0.1866
NDMI	2020	0.1885	2020	0.2108	2018	0.1725	2020	0.2147	2017	0.2410
	2017	0.1670	2018	0.1642	2019	0.1672	2017	0.1912	2020	0.1985
	2019	0.1622	2017	0.1490	2020	0.1401	2018	0.1784	2018	0.1882
	2018	0.1553	2019	0.1454	2017	0.0935	2019	0.1523	2019	0.1316
NDVI	2017	0.5503	2020	0.5906	2020	0.5008	2018	0.6028	2018	0.5830
	2020	0.5347	2018	0.5855	2018	0.4918	2020	0.5952	2017	0.5700
	2018	0.5023	2017	0.5283	2017	0.4736	2017	0.5661	2020	0.5574
	2019	0.4804	2019	0.4741	2019	0.4411	2019	0.4788	2019	0.4263
RVI	2018	0.7236	2017	0.8344	2020	0.7453	2017	0.8351	2017	0.7351
	2017	0.7081	2018	0.8158	2017	0.7134	2018	0.7935	2018	0.7278
	2020	0.6829	2020	0.7556	2018	0.7062	2020	0.7559	2020	0.6305
	2019	0.6759	2019	0.6725	2019	0.6775	2019	0.6353	2019	0.4959

Zdroj: Google Earth Engine 2022; výpočty autora

5.1. Pole podrytá v roce 2017 (Pole 17)


Na Polích 17 bylo v srpnu a září roku 2017 uskutečněno podrývání. Rozložení půdních bloků je možné vidět v Příloze 3 a konkrétní datum a hloubku podrytí v Příloze 4. Podrytí v roce 2017 se však následující rok neprojevovalo, jelikož porovnáme-li průběh hodnot Polí 17 s ostatními skupinami půdních bloků na Obrázku 12, 14, 15 a 16, nevidíme v roce 2018 mezi průběhem hodnot podrytých a nepodrytých skupin polí žádný zásadní rozdíl.

Z Obrázku 17 je patrné, že nízké úhrny srážek a vysoké teploty, jež lze sledovat na Obrázku 18, se v roce 2019 stejně jako na ostatních polích projevilo i na Polích 17 nejnižšími hodnotami. Nejhorší situace nastala v březnu a dubnu roku 2019, kdy hodnoty NSMI, NDMI i NDVI dosahovaly minima za celé sledované období. Také průměrná hodnota RVI byla značně nízká. Vysvětlením je, že v březnu a začátkem dubna probíhá výsev plodin a pole jsou zatím holá, tudíž není voda zadržována vegetací a snadněji odteče, nebo se vypaří. Jak lze vyčíst z Přílohy 13, za březen byly navíc zaznamenány oproti ostatním rokům poměrně vysoké teploty, kdy průměrná měsíční teplota dosahovala 6,7 °C, a v dubnu abnormálně nízké úhrny srážek (13,6 mm).

Jelikož byl rok 2020 nejchladnější a s největším úhrnem srážek, vlhkost v půdě i vegetaci dosáhla na těchto polích v porovnání s předchozími roky nejvyšších hodnot, což se projevilo také na zápoji plodin (Tabulka 3).

Sklizeň na těchto polích v roce 2017 probíhala po vydatných jarních srážkách, jež způsobily nárůst vlhkosti v půdě i vegetaci a vegetačního zápoje, v červenci. Roku 2018 bylo sklizeno již dříve, a to v červnu.

Obrázek 17: NSMI, NDMI, NDVI a RVI polí podrytých v roce 2017 za období 2017–2020.




Zdroj: Google Earth Engine 2022

5.2. Pole podrytá v roce 2018 (Pole 18)

Na Obrázku 19 můžeme vidět, že obsah vody v půdě i vegetaci byl nejnižší v letních měsících roku 2018, jež byl oproti ostatním rokům nejteplejší a druhý nejsušší (Tabulka 1). Průběh úhrnu srážek a teplot si lze prohlédnout na Obrázku 20. Nízké hodnoty v tomto období jsou však také zapříčiněny sklizní.

Obrázek 18: Teploty a srážky naměřené ve Strakoniciích (levá osa), NSMI a NDMI (pravá osa) polí podrytých v roce 2017 v období 2017–2020. Černá přerušovaná příčka znázorňuje termín, kdy bylo provedeno podrytí.




Zdroj: Google Earth Engine, ČHMÚ 2022

Na třech půdních blocích Polí 18 bylo provedeno podrytí nejen v srpnu roku 2018, ale také v září a říjnu roku 2016. Hloubku a datum podryvání v roce 2016 a 2018 je možné vyčíst z Přílohy 2 a 6. Podíváme-li se na mapu v Příloze 5, jedná se o půdní bloky s čísly 20, 21 a 22. Na Obrázku 12, 14, 15 a 16 vidíme, že hodnoty Polí 16 i 18 se od dubna do začátku července drží výše než u nepodrytých. Také v Tabulce 3 lze sledovat, jak se podrytí v následujícím roce 2019 pozitivně projevilo na obsahu vody v půdě i na hustotě vegetace, jelikož u Polí 16 převyšují hodnoty nepodrytých polí se svými hodnotami indexy NSMI a NDVI, a u Polí 17 pak indexy NDMI a RVI. Vysvětlením může být, že voda díky prokypření neodtekla, nebo se v důsledku vysokých teplot hned nevypařila, ale měla možnost se vsáknout a být využita rostlinami.

Vzhledem k vysokým hodnotám indexů, nižším teplotám a vydatným srážkám a v roce 2020 je zřejmé, že je půda a plodiny byly schopny efektivně zadržet a využít.


Podle vysokých hodnot indexů a jejich následného poklesu v letních měsících, jež vidíme na Obrázku 19, lze odvodit, že v roce 2017, 2019 a 2020 sklizeň probíhala od konce června do začátku srpna, zatímco roku 2018 již v červnu.

Obrázek 19: NSMI, NDMI, NDVI a RVI polí podrytých v roce 2018 za období 2017–2020.



Zdroj: Google Earth Engine 2022

Obrázek 20: Teploty a srážky (levá osa) naměřené ve Strakonících, NSMI a NDMI (pravá osa) polí podrytých v roce 2018 v období 2017–2020. Černá přerušovaná příčka znázorňuje termín, kdy bylo provedeno podrytí.



Zdroj: Google Earth Engine, ČHMÚ 2022

5.3. Pole podrytá v roce 2019 (Pole 19)


Situaci na Polích 19, jejichž polohu můžeme vidět v Příloze 7, je možné vyčíst z Obrázku 21. I když roční úhrn srážek, jež si lze spolu s teplotami prohlédnout na Obrázku 22, byl v roce 2017 poměrně vysoký, obsah vody v půdě a zápoj plodin byl menší než v roce 2018, kdy bylo teplo a sucho. Vysvětlením může být zasetí jiných plodin, které hůře zadržují vláhu.

Suchý rok 2019 nebyl ani zde výjimkou a hodnoty NSMI, NDMI i NDVI dosáhly z celého období minima. Vůbec nejnižší hodnoty lze pozorovat v říjnu, kdy byl zaznamenán abnormálně nízký úhrn srážek (23,7 mm). V Příloze 11, 12 a 14 je možné si prohlédnout průměrné říjnové úhrny srážek v ostatních letech. Zde se také potvrzuje, že podryvání, jež bylo v srpnu tohoto roku provedeno, na hodnotách není znát týž rok.

Podryvání uskutečněné v srpnu, jehož podrobnosti si lze prohlédnout v Příloze 8, se v následujícím roce, tedy 2020, projevilo pozitivně. Tabulka 3 dokládá, že průměrné hodnoty za rok 2020 spočtené pro Pole 19 dosahují v porovnání s ostatními skupinami půdních bloků nejvyšších hodnot. V časových řadách hodnot indexů na Obrázku 12, 14, 15 a 16 jsou vyšší hodnoty na Polích 19 patrné hlavně od dubna do června. Příčinou vysokých hodnot v těchto měsících je také efekt abnormálně vydatných únorových srážek (68,9 mm), který se v kombinaci s vlivem podryvání projevil. Únorové úhrny srážek v jednotlivých letech si lze prohlédnout v Příloze 10–14. Je však zajímavé, že obsah vlhkosti v půdě a vegetační zápoj i přes vydatné srážky a nízké teploty v roce 2020 nepřesáhly hodnoty z roku 2018. Vysvětlením je nejspíš výsev jiných plodin v roce 2018, které více držely vlhkost.

Podle značných poklesů hodnot vlhkosti a vegetačního zápoje lze odvodit, že sklizeň v roce 2017, 2018 a 2020 probíhala v červnu a červenci a roku 2019 v srpnu a září.

Obrázek 21: NSMI, NDMI, NDVI a RVI polí podrytých v roce 2019 za období 2017–2020.



Zdroj: Google Earth Engine 2022


5.4. Pole podrytá v roce 2020 (Pole 20)

Průměrné roční hodnoty indexů vypočtené pro Pole 20 za rok 2017, jež lze pozorovat v Tabulce 3, ale také průběh hodnot na Obrázku 12, 14, 15 a 16, vypovídají o tom, že hustota vegetace a obsah vody v půdě i plodinách byl v porovnání s ostatními skupinami půdních bloků v tomto roce největší právě na Polích 20, jejichž polohu můžeme vidět v Příloze 9. Z toho lze usoudit, že na půdních blocích se vyskytovalo nejméně holých ploch bez vegetace a půda efektivně dokázala hospodařit s vodou.

Zajímavé jsou hodnoty indexů pro rok 2018, které navzdory vyšším teplotám a suchu, jež lze pozorovat na Obrázku 24, vypovídají o větším obsahu vody v půdě (NSMI) než v předešlém roce. Hodnoty NDMI však informují o nízkém obsahu vody ve vegetaci. Důvodem je nejspíš dostatek vlhkosti v půdě, ale zhoršená možnost jejího využití rostlinami v důsledku zhutnění těchto půdních bloků.

Sucho v roce 2019 mělo na Pole 19 takový vliv, že v porovnání s ostatními zájmovými plochami dosáhly všechny indexy nejnižších hodnot.

Obrázek 22: Teploty a srážky (levá osa) naměřené ve Strakonících, NSMI a NDMI (pravá osa) polí podrytých v roce 2019 v období 2017–2020.




Zdroj: Google Earth Engine, ČHMÚ 2022

Podle průběhu hodnot indexů na Obrázku 23 lze usoudit, že situace v roce 2020 byla na Polích 20 příznivá. Hodnoty všech indexů začaly růst od března po vydatných srážkách, jako začaly růst plodiny. Detaily podrývání, jež bylo provedeno v září a říjnu, lze vyčíst z Přílohy 10. V tomto roce se však na hodnotách vypovídajících o vegetaci a obsahu vody neprojevovalo. Výsledek byl patrný pravděpodobně až následující rok 2021, který již nebyl předmětem zkoumání.


Pokles hodnot indexů vypovídá o tom, že v roce 2017, 2018 a 2020 sklizeň probíhala v červenci, zatímco v roce 2019 až v září.

Obrázek 23: NSMI, NDMI, NDVI a RVI polí podrutých v roce 2020 za období 2017–2020.



Zdroj: Google Earth Engine 2022

Obrázek 24: Teploty a srážky naměřené ve Strakonících (levá osa), NSMI a NDMI (pravá osa) polí podrytých v roce 2020 v období 2017–2020.



Zdroj: Google Earth Engine, ČHMÚ 2022

6. Diskuze

Výpočty indexů proběhly v období 2017–2020, kdy se vystřídaly jak vlhké, tak suché roky. Analýza časových řad tohoto heterogenního období se ukazuje jako přínosná. Dokládají to výsledné hodnoty indexů na podrytých polích, jež v suchém roce dosáhly vyšších hodnot než v roce s vydatnějšími srážkami. Konkrétně hodnoty NSMI=0,24 a NDVI=0,55 spočtené pro pole podryté v roce 2016 vypovídají v roce 2017 o vůbec nejlepší situaci na těchto půdních blocích za celé sledované období a předčily tak i srážkově vydatnější rok 2020, kdy NSMI=0,22 a NDVI=0,53. Za rok 2017 je zaznamenán celkový úhrn srážek 587 mm, zatímco v roce 2020 činil dokonce 637 mm. Naproti tomu hodnoty indexů vypočtené roku 2017 pro skupiny nepodrytých půdních bloků vypovídaly o horší situaci než v roce 2020. Na polích, které byly podryty až v roce 2017, se vlhkostní index NSMI v roce 2017 rovnal 0,22, zatímco v roce 2020 dosahoval vyšší hodnoty 0,24. Také vegetační index nabýval v roce 2017 nižší hodnoty NDVI=0,53, zatímco roku 2020 NDVI=0,59. Tyto výsledky potvrzují také skutečnost, že podrývání se neprojeví ve stejný rok, jako bylo provedeno, jinak by hodnoty indexů polí podrytých v roce 2017 vykazovaly lepší hodnoty roku 2017 nežli v roce 2020, stejně jako tomu bylo u polí podrytých v roce 2016. Jelikož hodnoty NSMI, NDMI, NDVI a RVI zaznamenávají následující rok po podrytí na většině půdních bloků vyšší obsah vody v půdě i vegetaci a také větší hustotu plodin, podařilo se zde prokázat pozitivní vliv podrývání. Využití těchto indexů se tak ukazuje jako vhodné pro monitoring vlhkosti a vegetace v zemědělství.

Výsledky Pearsonova korelačního koeficientu (r) prokazují korelaci mezi NSMI a NDVI. Konkrétně výpočet korelačního koeficientu z hodnot indexů naměřených na Polích 20 se rovnal 0,93. Korelaci mezi stejnými indexy ve své studii prokázal také Alonso a kol. (2019). Výsledky této práce však navíc potvrzují také korelaci mezi NDMI a NDVI, kde $r=0,78$.

Je však nutné zdůraznit, že pro výpočet indexů z optických dat vypovídajících o těchto skutečnostech bylo každý měsíc, a tedy i rok, použito jiné množství snímků v závislosti na oblačnosti, která optickým senzorům znemožňuje měření. Za některé měsíce tak nebyly zaznamenány žádné hodnoty. Průběh hodnot radarového indexu RVI, jež spočítal hodnoty i z oblačných snímků, je proto lépe vypovídající. Nicméně časové řady indexů vypočtených na základě optických dat nám i tak umožňují sledovat zásadní trendy ve vývoji obsahu vody v půdě i vegetaci a hustoty vegetace. Díky vypočteným průměrným ročním hodnotám indexů lze také snadno porovnat vlhkostní a vegetační situace v jednotlivých letech.

Pro monitoring vegetace, k němuž byly použity vegetační indexy NDVI a RVI, je lépe vypovídající radarový index RVI, jež je schopný hodnoty získat i z oblačných snímků,

tudíž jeho časové řady podrobněji vypovídají o hustotě vegetace v průběhu roku nežli NDVI. Hodnoty těchto vegetačních indexů však nevypovídají o druhu vegetace. Do dalšího výzkumu by proto bylo pro lepší pochopení výsledných hodnot indexů vhodné získat informace o pěstovaných plodinách, tak jako je ve své studii erozního ohrožení půd nechráněných vegetací použil Krása a kol. (2019).

Průměrné denní teploty vzduchu a úhrny srážek použité pro hledání spojitostí a příčin vlhkostní a vegetační situace na zájmových plochách byly naměřeny ve Strakonících. Meteorologické stanice blíže zkoumaného území neposkytovaly pro analyzované období kompletní data. Vzhledem k vysoké prostorové proměnlivosti srážek a teplot by bylo pro příští potenciální výzkum vhodné instalovat vlastní měřicí přístroje, jako ve svém výzkumu použil Litschmann (2015).

Vlhkost byla nejdříve zkoumána jen prostřednictvím indexu NDMI, jež sleduje obsah vody ve vegetaci a detekuje holou půdu, ale nevypovídá o její vlhkosti. Proto byla studie doplněna o index NSMI vypovídající o vlhkosti v půdě. Je-li totiž obsah vody v plodinách nízký, nemusí to nutně znamenat vodní stres. Vzhledem k výskytu holých ploch by pro zemědělství bylo přínosné rozšířit studii o monitoring těchto nechráněných půd s cílem posouzení erozního rizika, jako se ve svém výzkumu věnoval Krása a kol. (2019).

Výsledky indexu NSMI sice do určité míry vypovídají o obsahu vody v půdě, avšak Notica a kol. (2013) ve své studii uvádí, že výsledné hodnoty jsou ovlivněné řadou faktorů, jako je např. vegetační kryt, typ půdy nebo drsnost povrchu, jež mají rozdílné účinky na intenzitu odrazivosti záření, ze které je index vypočten. Vliv drsnosti povrchu lze však podle Jackson a kol. (1996) snížit využitím delších vlnových délek na úrovni mikrovln. Kolář (2008) doplňuje, že na určitých vlnových délkách je mikrovlnné záření schopno prostoupit skrze vegetaci. Toho je také částečně schopna HH polarizace, kterou, jak uvádí, je vhodné použít pro monitoring obsahu vody v půdě. Jak dokládá Lakhankar a kol. (2009), přesnějších výsledků je možné dosáhnout konkrétně pomocí pásma L (1–2 GHz) nebo C (4–8 GHz). V příštím výzkumu by proto bylo vhodné si tyto předpoklady ověřit a porovnat hodnoty získané z optických a radarových dat.

Využití dálkového průzkumu pro monitoring vlhkosti je v tomto případě lepší nežli pozemní měření, které ve svém výzkumu prováděl Litschmann (2015). Bodová měření při rozmístění dostatečného množství sond sice mohou poskytnout značné množství informací o prostorové a temporální variabilitě půdní vlhkosti, avšak DPZ umožňuje získat širší škálu informací snáze a rychleji a to pro libovolné území. Jeho potenciál stále roste a větší využití metod dálkového průzkumu v zemědělství by do budoucna mohlo být velkým přínosem.

Např. Lakhankar a kol. (2009) ve své studii rozebírá využitelnost vegetačních indexů a údajů o půdní vlhkosti v plánování distribuce závlah či k predikci výnosů plodin. Data z dálkového průzkumu tak již nyní přispívají k úspornějšímu a zároveň efektivnějšímu hospodaření.

7. Závěr

Cílem této práce bylo zhodnotit metody vhodné pro monitoring půdní vlhkosti na zemědělských plochách a prostřednictvím podrobné analýzy časových řad indexů NSMI, NDMI, NDVI a RVI jednotlivých skupin polí potvrdit či vyvrátit vliv podryvání na obsah vody v půdě a vegetaci a na hustotu vegetace. Podryvání bylo provedeno za účelem zlepšení výnosů a retence vody půdou.

Analýza časových řad hodnot indexů, jež byly získány pomocí Google Earth Engine, kdy byla brána v úvahu také teplota a úhrn srážek, prokázala pozitivní vliv podryvání půdních bloků, a to v následujícím roce po podryvání. Obsah vody v půdě či plodinách a hustota plodin rok po podrytí celkově vypovídali o lepších výsledcích. Příkladem mohou být hodnoty spočtené pro pole podrytá v roce 2017, které následující rok 2018 informovaly o vyšším obsahu vody v půdě i plodinách a větší hustotě vegetace než v roce 2017. Konkrétně průměrná hodnota NDVI v roce 2017 byla 0,53, zatímco v roce 2018 vystoupala na 0,59, a to i přes to, že rok 2018 byl sušší a teplejší. Druhý rok po podrytí se již podryv na hodnotách neprojevil. Jeho efektivita je tedy pouze krátkodobá. Pokud by podryvání mělo mít pro pole větší význam, muselo by se provádět opakovaně. Otázkou však zůstává, zda by časem opravdu vedlo k obnovení půdní schopnosti retence vody v případě, že budou dále pod vlivem těžké zemědělské techniky.

V rámci této práce se také na základě Pearsonova korelačního koeficientu podařilo prokázat korelaci mezi obsahem vody v půdě (NSMI) a vegetaci (NDMI) a hustotou vegetace (NDVI a RVI).

Monitoring vlhkosti a vegetace spolu s údaji o teplotě a úhrnu srážek pomocí časových řad prokázal pozitivní efekt podryvání, avšak pro získání přesnějších informací by bylo v příštím výzkumu vhodné využít data o zemědělských plodinách.

8. Seznam literatury a zdrojů

- ADEGOKE, J. O., CARLETON, A. M. (2002): Relations between Soil Moisture and Satellite Vegetation Indices in the U.S. Corn Belt. *Journal of Hydrometeorology*, 3, 4, 395–405.
- AGAPIOU, A., ALEXAKIS, D., D., SARRIS, A., HADJIMITSIS, D., G (2014): Evaluating the Potentials of Sentinel-2 for Archaeological Perspective. *Remote Sensing*, 6, 3, 2176–2194.
- AHMED, A., ZHANG, Y., NICHOLS, S. (2011): Review and evaluation of remote sensing methods for soil-moisture estimation. *SPIE Reviews* 2, 1, 1–17.
- ALONSO, C., LÓPEZ, P., BENITO, R. M., TARQUIS, A. M. (2019): Correlation between vegetation index and soil moisture index using Sentinel-2. *Estudios en la Zona No Saturada Del Suelo*, 14, 19, 75–80.
- ARCDATA PRAHA, ZÚ, ČSÚ (2014): ArcČR 500. <https://www.arcdata.cz/> (cit. 16. 3. 2020).
- Babaeian, E., Sadeghi, M., Jones, S. B., Montzka, C., Vereecken, H., Tuller, M., 2019. Ground, proximal, and satellite remote sensing of soil moisture. *Reviews of Geophysics*, 57, 2, 530–616.
- BANDARU, V., PEI, Y., HART, Q., JENKINS, B. M. (2017): Impact of biases in gridded weather datasets on biomass estimates of short rotation woody cropping systems. *Agricultural and Forest Meteorology*, 233, 71–79.
- BROCCA, L., MORBIDELLI, R., MELONE, F., MORAMARCO, T. (2007): Soil moisture spatial variability in experimental areas of central Italy. *Journal of Hydrology*, 333, 2–4, 356–373.
- BROGIONI, M., PETTINATO, S., MACELLONI, G., PALOSCIA, S., PAMPALONI, P., PIERDICCA, N., TICCONI, F. (2010): Sensitivity of bistatic scattering to soil moisture and surface roughness of bare soils. *International Journal of Remote Sensing*, 31, 15, 4227–4255.
- CASE, J. L. (2016): From drought to flooding in less than a week over South Carolina. *Results in Physics*, 6, 2016, 1183–1184.
- ČHMÚ (2021a): Denní úhrn srážek v Jihočeském kraji. <https://www.chmi.cz/> (cit. 9. 3. 2022).

- ČHMÚ (2021b): Průměrná denní teplota vzduchu v Jihočeském kraji. <https://www.chmi.cz/> (cit. 9. 3. 2022).
- ČÚŽK (2020): WMS - ZM 50. <https://www.cuzk.cz/> (cit. 1. 4. 2022).
- DOBRIYAL, P., QURESHI, A., BADOLA, R., HUSSAIN, S. A. (2012): A review of the methods available for estimating soil moisture and its implications for water resource management. *Journal of Hydrology*, 458, 110–117.
- DORAISWAMY, P. C., HATFIELD, J. L., JACKSON, T. J., AKHMEDOV, B., PRUEGER, J., STERN, A. (2004): Crop condition and yield simulations using Landsat and MODIS, *Remote Sensing of Environment*, 92, 4, 548–559.
- DRIESE, K. (2012): Vegetation Indices: Enhancing green vegetation using mathematical equations and transformations, http://web.pdx.edu/~nauna/resources/8-2012_lecture1-vegetationindices.pdf?fbclid=IwAR0SrISobmAED369xTcSwn_GrWg7yOvQ9xTvTz3xRtDgGb8ANcTs1WACgag (cit. 30. 12. 2021).
- ECOSTRESS (2013): Spectral Library, <https://speclib.jpl.nasa.gov/library> (cit. 1. 11. 2020).
- FLORES, A. I., HERNDON, K. E., THAPA, R. B., CHERRINGTON, E. (2019): The Synthetic Aperture Radar (SAR) Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation. NASA, Huntsville.
- GAO, B. C. (1996): NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58, 3, 257–266.
- Google Earth Engine (2022): Algoritmus. <https://code.earthengine.google.com/98d9d34dcbafe31aca1db8a4cfec5619> (cit. 21. 3. 2022).
- HANG, L. M., DUONG, N. D., TUAN, T. A. (2021): A Combination of Normalized Difference Vegetation Index and Multi-temporal Radar Vegetation Index of Sentinel Data for Landuse/Landcover Classification, https://www.researchgate.net/profile/Lm-Hang/publication/356536769_A_COMBINATION_OF_NORMALIZED_DIFFERENCE_VEGETATION_INDEX_AND_MULTI-TEMPORAL_RADAR_VEGETATION_INDEX_OF_SENTINEL_DATA_FOR_LANDUSELANDCOVER_CLASSIFICATION/links/61b6fb404b318a6970da06fa/A-COMBINATION-OF-NORMALIZED-DIFFERENCE-VEGETATION-INDEX-AND-MULTI-TEMPORAL-RADAR-VEGETATION-INDEX-OF-SENTINEL-DATA-FOR-LANDUSE-LANDCOVER-CLASSIFICATION.pdf (cit. 20. 12. 2021).

- HAUBROCK, S. N., CHABRILLAT, S., LEMNITRZ, C., KAUFMANN, H. (2008): Surface soil moisture quantification models from reflectance data under field conditions. *International journal of remote sensing*, 29, 1, 3–29.
- HEUTE, A. R., DIDAN, K., LEEUWEN, W. V., JACOBSON, A., SOLANOS, R., LAING, T. (1999): MODIS vegetation index (MOD13). Algorithm theoretical basis document, 3, 213, 295–309.
- HONG, Y., YU, L., CHEN, Y., LIU, Y., LIU, Y., LIU, Y., CHENG, H. (2017): Prediction of soil organic matter by VIS–NIR spectroscopy using normalized soil moisture index as a proxy of soil moisture. *Remote sensing*, 10, 1, 1–17.
- HUETE, A. R., LIU, H. Q., BATCHILY, K., YANLEEUEWEN, W (1997): A comparison of vegetation indices global set of TM images for EOS-MODIS. *Remote Sensing of Environment*, 59, 3, 440–451.
- HUNT, E. D., HUBBARD, K. G., WILHITE, D. A., ARKEBAUER, T. J., DUTCHER, A. L. (2009). The development and evaluation of a soil moisture index. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 29, 5, 747–759.
- CHEN, J. M., CIHLAR, J. (1996): Retrieving leaf area index of boreal conifer forests using Landsat TM images. *Remote Sensing of Environment*, 55, 2, 153–162.
- JACKSON, T.J., SCHMUGGE, J., ENGMAN, E.T. (1996): Remote sensing applications to hydrology: soil moisture. *Hydrological Sciences Journal*, 41, 4, 517–530.
- KIM, Y., JACKSON, T., LEE, H., HONG, S. (2012): Radar Vegetation Index for Estimating the Vegetation Water Content of Rice and Soybean. *IEEE Geoscience and Remote Sensing Letters*, 9, 4, 564–568.
- KOLÁŘ, J. (1990): Dálkový průzkum Země. Nakladatelství technické literatury, Praha.
- KOLÁŘ, J. (2008): Radarová obrazová data a jejich využití. Studie, Czech space office, Praha.
- KOLÁŘ, J., HALOUNOVÁ, L., PAVELKA, K. (2000): Dálkový průzkum Země 10. ČVUT, Praha.
- KRÁSA, J., TEJKL, A., STAŠEK, J. (2019): Určení rozsahu půdy nechráněné vegetací v období přívalemých srážek za účelem posouzení erozního rizika. *Vodohospodářské technicko-ekonomické informace*, 61, 2, 39–45.

- LAKHANKAR, T., KRAKAUER, N., KHANBILVARDI, R. (2009): Applications of microwave remote sensing of soil moisture for agricultural applications. *International Journal of Terraspace Science and Engineering*, 2, 1, 81–91.
- Lee, T. Y., Kaufman, Y. J. (1986): Non-lambertian effects on remote sensing of surface reflectance and vegetation index. *IEEE Transactions on Geoscience and Remote Sensing*, 24, 5, 699–707.
- LITSCHMANN, T (2015): Vyhodnocení 10-ti letých měření půdních vlhkostí ve vztahu k vybraným indikátorům sucha s měsíčním krokem, <http://www.cbks.cz/sbornikMikulov15/Litschmann2015.pdf> (cit. 14. 4. 2022).
- LIU, H. Q., HUETE, A. R. (1995): A feedback based modification of the NDVI to minimize canopy background and atmospheric noise. *IEEE Transactions on Geoscience and Remote Sensing*, 33, 2, 457–465.
- LÓPEZ-PUIGDOLLERS, D., MATEO-GARCÍA, G., & GÓMEZ-CHOVA, L. (2021): Benchmarking deep learning models for cloud detection in Landsat-8 and Sentinel-2 images. *Remote Sensing*, 13, 5, 992.
- MALAKHOV, D. V., TSYCHUYEVA, N. Y. (2020): Calculation of the biophysical parameters of vegetation in an arid area of south-eastern Kazakhstan using the normalized difference moisture index (NDMI). *Central Asian Journal of Environmental Science and Technology Innovation*, 1, 4, 189-198.
- MANDAL, D., RATHA, D., BHATTACHARYA, A., KUMAR, V., MCNAIRN, H., RAO, Y. S., FRERY, A. C. (2020): A Radar Vegetation Index for Crop Monitoring Using Compact Polarimetric SAR Data. *IEEE Transactions on Geoscience and Remote Sensing*, 58, 9, 6321–6335.
- MATSUSHITA, B., YANG, W., CHEN, J., ONDA, Y., QUI, G. (2007): Sensitivity of the Enhanced Vegetation Index (EVI) and Normalized Difference Vegetation Index (NDVI) to Topographic Effects: A Case Study in High-Density Cypress Forest. *Sensors*, 7, 11, 2636–2651.
- MITTELBACH, H., LEHNER, I., SENEVIRATNE, S. I. (2012): Comparison of four soil moisture sensor types under field conditions in Switzerland. *Journal of Hydrology*, 430, 39–49.
- MO, T., SCHMUGGE, T. J., JACKSON, T. J. (1984): Calculations of radar backscattering coefficient of vegetation covered soils, *Remote Sensing of Environment*, 15, 2, 119–133.

- MUSIK, H. B., PELLETIER, R. E. (1986): Response of Some Thematic Mapper Band Ratios to Variation in Soil Water Content. *Photogrammetric Engineering and Remote Sensing*, 52, 10, 1661–1668.
- NARVEKAR, P. S., ENTEKHABI, D., KIM, S. B., NJOKU, E. G. (2015): Soil Moisture Retrieval Using L-Band Radar Observations. *Transactions on Geoscience and Remote Sensing*, 53, 6, 3492–3506.
- NOTARNICOLA, C., ANGIULLI, M., POSA, F. (2006): Use of radar and optical remotely sensed data for soil moisture retrieval on vegetated areas. *IEEE Transactions on Geoscience and Remote Sensing*, 44, 4, 925–935.
- NOTICA, M., STEVENS, A., NOON, C., WESEMAEL, B. (2013): Prediction of soil organic carbon for different levels of soil moisture using Vis-NIR spectroscopy. *Geoderma*, 199, 37–42.
- OPREANU, C. H., LĂZĂRESCU, V., A. (2016): Multispectral satellite imagery and airborne laser scanning techniques for the detection of archaeological vegetation marks. Mega Publishing House, Cluj-Napoca.
- PALOSCIA, S., PETTINATO, S., SANTI, E., NOTARNICOLA, C., PASOLLI, L., REPPUCCI, A. (2013): Soil moisture mapping using Sentinel-1 images: Algorithm and preliminary validation. *Remote Sensing of Environment*, 134, 234–248.
- PLAUBORG, F., IVERSEN, B. V., LÆRKE, P. E. (2005): In situ comparison of three dielectric soil moisture sensors in drip irrigated sandy soils. *Vadose Zone Journal*, 4, 4, 1037–1047.
- RAHMAN, S., MESEV, V. (2019): Change vector analysis, tasseled cap, and NDVI-NDMI for measuring land use/cover changes caused by a sudden short-term severe drought: 2011 Texas event. *Remote Sensing*, 11, 19, 2217.
- REICHLE, R. H., KOSTER, R. D. (2005): Global assimilation of satellite surface soil moisture retrievals into the NASA Catchment land surface model. *Geophysical Research Letters*, 32, 2, 1–4.
- RUNDQUIST, B. C., HARRINGTON, J. A. (2000): The effects of climatic factors on vegetation dynamics of tallgrass and shortgrass cover. *GeoCarto International*, 15, 3, 33-38.
- SANTI, E., PALOSCIA, S., PETTINATO, S., NOTARNICOLA, C., PASOLLI, L., PISTOCCHI, A. (2013): Comparison between SAR soil moisture estimates and


hydrological model simulations over the Scrivia test site. *Remote Sensing*, 5, 10, 4961–4976.

- SENTINEL ONLINE (2020): Resolutions, <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/resolutions/spatial> (cit. 9. 4. 2022).
- SPÚ (2022): Celostátní databáze BPEJ. <https://www.spucr.cz/bpej/celostatni-databaze-bpej> (cit. 14. 4. 2022).
- SRIVASTAVA, P. K. (2017): Satellite soil moisture: review of theory and applications in water resources. *Water Resources Management*, 31, 10, 3161–3176.
- STRNADOVÁ, P. (2019): Měření půdní vlhkosti a teploty. Bakalářská práce. Katedra elektromechaniky a výkonové elektroniky Západočeské univerzity v Plzni, Plzeň.
- TALOOR, A. K., MANHAS, D. S., KOTHYARI, G. CH. (2021): Retrieval of land surface temperature, normalized difference moisture index, normalized difference water index of the Ravi basin using Landsat data. *Applied Computing and Geosciences*, 9, 1–11.
- TAVAKOL, A., MCDONOUGH, K. R., RAHMANI, V., HUTCHINSON, S. L., HUTCHINSON, J. M. S. (2021): The soil moisture data bank: The ground-based, model-based, and satellite-based soil moisture data. *Remote Sensing Applications: Society and Environment*, 24, 1–24.
- TUCKER, C. J. (1979): Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8, 2, 127–150.
- WAGNER, W., NOLL, J., BORGEAUD, M., & ROTT, H. (1999): Monitoring soil moisture over the Canadian prairies with the ERS scatterometer. *IEEE Transactions on Geoscience and Remote Sensing*, 37, 1, 206–216.
- WIGNERON, J., JACKSON, T.J., O'NEILL, P., DE LANNOY, G., DE ROSNAY, P., WALKER, J.P., FERRAZZOLI, P., MIRONOV, V., BIRCHER, S., GRANT, J. P., KURUM, M., SCHWANK, M., MUNOZ-SABATER, J., DAS, N., ROYER, A., AL-YAARI, A., BITAL, A. A., FERNANDEZ-MORAN, R, KERR, Y. (2017): Modelling the passive microwave signature from land surfaces: A review of recent results and application to the L-band SMOS & SMAP soil moisture retrieval algorithms. *Remote Sensing of Environment*, 192, 238–262.

- XUE, Z., GOCHIS, D., YU, W., KEIM, B., ROHLI, R., ZANG, Z., SAMPSON, K., DUGGER, A., SATHIARAJ, D., GE, Q., (2018): Modeling hydroclimatic change in southwest Louisiana rivers. *Water* 10, 5, 596.

9. Přílohy

Příloha 15: Přehledová mapa Polí 16.




Zdroj: VÚZT, ČÚZK 2022

Příloha 16: Údaje o Polích 16.

Číslo bloku/dílu	Kód bloku/dílu	Místní název	Katastrální území	Datum Podrývání	Hloubka [cm]	Spodní voda a utužení	Výměra [ha]
1	9501/1	U Vavřince	Štětice	8.10.	30	S,U	27.57
2	4510	U můstku	Skály u Protivína	9.9.	35	S,U	4.50
3	4505/2	Pod zastávkou	Skály u Protivína	9.9.	35	S,U	4.17
4	4416	Trávný u potoka	Skály u Protivína	26.9.	40	S,U	0.57
5	4406/1	Trávný	Skály u Protivína	26.9.	40	S,U	3.48
6	4404/1	Za Mášků	Skály u Protivína	26.9.	35	S,U	8.65
7	4403	Trávný u tratě	Skály u Protivína	26.9.	40	S,U	1.67
8	3508/1	Velká	Skály u Protivína	9.9.	35	S,U	7.04
CELKEM							57.65

Zdroj: VÚZT 2022

Příloha 17: Přehledová mapa Polí 17.




Zdroj: VÚZT, ČÚZK 2022

Příloha 18: Údaje o Polích 17.

Číslo bloku/dílu	Kód bloku/dílu	Místní název	Katastrální území	Datum Podrývání	Hloubka [cm]	Spodní voda a utužení	Výměra [ha]
9	8214/1	Za strouhou	Ražice	6.9.	35	S,U	16.81
10	8211	Hluš	Ražice	24.9.	40	S,U	5.79
11	8210	Za cementárnou	Ražice	24.9.	40	S,U	6.34
12	7209/1	Točinka	Ražice	25.9.	35	S,U	9.85
13	7207	Rekultivace	Ražice	6.9.	35	S,U	7.22
14	7206/1	Dolina	Ražice	11.8.	40	S,U	5.4
15	7206/9	Dolina	Ražice	11.8.	40	S,U	0.49
16	7205	Ražický	Ražice	11.8.	40	S,U	9.47
17	7204/2	Za signálkou	Heřmaň	9.8.	35	S,U	2.62
18	7203	Za signálkou	Heřmaň	9.8.	35	S,U	3.67
19	7202	Za signálkou	Ražice	9.8.	35	S,U	2.39
CELKEM							70.05

Zdroj: VÚZT 2022

Příloha 19: Přehledová mapa Polí 18.




Zdroj: VÚZT, ČÚZK 2022

Příloha 20: Údaje o Polích 18.

Číslo bloku/dílu	Kód bloku/dílu	Místní název	Katastrální území	Datum Podrývání	Hloubka [cm]	Spodní voda a utužení	Výměra [ha]
20	4416	Trávný u potoka	Skály u Protivína	2.8.	35	S,U	0.57
21	4406/1	Trávný	Skály u Protivína	2.8.	35	S,U	3.48
22	4403	Trávný u tratě	Skály u Protivína	2.8.	35	S,U	1.63
23	3504	Křemelka	Skály u Protivína	1.8.	35	S,U	2.27
24	3503/1	Cejčeň	Skály u Protivína	1.8.	35	S,U	26.54
25	3502/2	Selibovské	Skály u Protivína	1.8.	35	S,U	7.05
26	3411	Zadní řeka	Skály u Protivína	1.8.	35	S,U	16.69
27	3410/9	Přední řeka	Skály u Protivína	1.8.	35	S,U	17.33
CELKEM							75.56

Zdroj: VÚZT 2022

Příloha 21: Přehledová mapa Polí 19.



Zdroj: VÚZT, ČÚZK 2022

Příloha 22: Údaje o Polích 19.

Číslo bloku/dílu	Kód bloku/dílu	Místní název	Katastrální území	Datum podryvání	Hloubka [cm]	Spodní voda a utužení	Výměra [ha]
28	6304/4	Oulehle	Heřman	11.8.	35	S,U	39.56
29	6303	U Slanika	Heřman	9.8.	35	S,U	8.76
30	5304/6	V lukách	Heřman	9.8.	35	S,U	28.35
CELKEM							76.67

Zdroj: VÚZT 2022

Příloha 23: Přehledová mapa Polí 20.



Zdroj: VÚZT, ČÚZK 2022

Příloha 24: Údaje o Polích 20.

Číslo bloku/dílu	Kód bloku/dílu	Místní název	Katastrální území	Datum podryvání	Hloubka [cm]	Spodní voda a utužení	Výměra [ha]
31	8001/1	Směna	Putim	21.9.	35	S,U	1.24
32	8001/5	Směna	Putim	21.9.	35	S,U	8.38
33	7209/1	Točinka	Ražice	5.10.	50	S,U	8.83
34	7007/3	Směna	Putim	21.9.	35	S,U	1.18
35	5408/8	Směna u Heřmaně 2	Skály u Protivína	21.9.	50	S,U	1.69
36	5408/6	Směna prostředí	Skály u Protivína	16.9.	50	S,U	4.85
37	5408/5	Směna u Heřmaně	Skály u Protivína	21.9.	50	S,U	10.29
CELKEM							36.46

Zdroj: VÚZT 2022

Příloha 25: Měsíční úhrny srážek a průměrné měsíční teploty vzduchu v roce 2017 naměřené ve Strakonicih.

	2017											
Datum	leden 17	únor 17	březen 17	duben 17	květen 17	červen 17	červenec 17	srpen 17	září 17	říjen 17	listopad 17	prosinec 17
Měsíční úhrn srážek	20.3	18.6	41.9	95.3	40.4	59.8	70.8	96.8	25.8	51.8	40.7	24.6
Průměrná měsíční teplota vzduchu	-5.4	1.9	7.0	7.8	14.6	19.7	19.6	19.7	12.4	10.4	4.2	1.5

Zdroj: ČHMÚ 2022

Příloha 26: Měsíční úhrny srážek a průměrné měsíční teploty vzduchu v roce 2018 naměřené ve Strakonicih.

	2018											
Datum	leden 18	únor 18	březen 18	duben 18	květen 18	červen 18	červenec 18	srpen 18	září 18	říjen 18	listopad 18	prosinec 18
Měsíční suma srážek	29.1	24.8	27.9	12.0	54.6	113.6	31.3	54.6	71.9	38.7	26.5	61.6
Průměrná měsíční teplota vzduchu	3.2	-2.9	1.9	13.6	16.5	18.1	20.3	20.9	14.9	10.0	4.3	2.4

Zdroj: ČHMÚ 2022

Příloha 27: Měsíční úhrny srážek a průměrné měsíční teploty vzduchu v roce 2019 naměřené ve Strakonících.

	2019											
Datum	leden 19	únor 19	březen 19	duben 19	květen 19	červen 19	červenec 19	srpen 19	září 19	říjen 19	listopad 19	prosinec 19
Měsíční úhrn srážek	37.9	45.2	39.5	13.6	64.4	86.0	69.2	52.3	47.7	23.7	30.3	20.1
Průměrná měsíční teplota vzduchu	0.0	2.4	6.7	9.8	11.5	21.5	20.4	19.5	14.1	9.8	5.0	2.3

Zdroj: ČHMÚ 2022

Příloha 28: Měsíční úhrny srážek a průměrné měsíční teploty vzduchu v roce 2020 naměřené ve Strakonících.

	2020											
Datum	leden 20	únor 20	březen 20	duben 20	květen 20	červen 20	červenec 20	srpen 20	září 20	říjen 20	listopad 20	prosinec 20
Měsíční úhrn srážek	9.6	68.9	33.7	39.5	73.9	130.6	45.6	97.8	48.6	55.6	15.8	17.8
Průměrná měsíční teplota vzduchu	0.8	5.2	4.8	10.6	11.20	16.6	17.6	18.4	13.5	8.5	3.1	1.7

Zdroj: ČHMÚ 2022