



ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

Fakulta stavební

Katedra hydromeliorací a krajinného inženýrství

**Automatizace komplexního monitoringu zemědělských pozemků
pomocí dálkového průzkumu Země**

**Automation of complex monitoring of agricultural land using
remote sensing**

DISERTAČNÍ PRÁCE

Ing. Adam Tejkl

Doktorský studijní program: Stavební inženýrství

Studijní obor: Inženýrství životního prostředí

Školitel: Doc. Ing. Josef Krása, Ph.D.
Doc. Ing. Petr Kavka, Ph.D.

Praha, 2024

PROHLÁŠENÍ

Jméno doktoranda: Ing. Adam Tejkl

Název disertační práce: Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země

Prohlašuji, že jsem uvedenou disertační práci vypracoval/a samostatně pod vedením školitele Doc. Ing. Josef Krása, Ph.D..

Použitou literaturu a další materiály uvádím v seznamu použité literatury.

Disertační práce vznikla v souvislosti s řešením projektu: SS01020366 Využití dat dálkového průzkumu Země pro posouzení negativních dopadů přívalových srážek

V Praze dne 20.2.2024

.....
podpis

ABSTRAKT

Vodní eroze půdy je v současné době stále aktuální problém, který negativním způsobem ohrožuje jak zemědělské pozemky a jejich produkční schopnost, tak i široké okolí od vodních zdrojů až po intravilán. V dnešní době existuje mnoho způsobů určení erozní ohroženosti, nepřímého měření a monitoringu ztráty půdy, avšak stále je zde velký potenciál pro jejich automatizaci. Tato studie se zabývá problematikou sběru erozních dat pomocí nepřímých metod s cílem vyvinutí modelu či metody schopné s minimálním lidským úsilím najít a označit erozně poškozené plochy.

Pro tyto účely byly v rámci disertační práce provedeny různé typy experimentů, které testovaly a ověřovaly tyto metody v několika měřítcích experimentálních ploch od malých (4 m²) po celé katastrální území (km²). Tyto experimenty byly založeny na nalezení erozních projevů vzniklých přirozenou i umělou srážkou na datech vzdáleného průzkumu. Z hlediska přirozených srážek se jednalo o sledované pozemky v rámci jednotlivých projektů, monitorovaných pomocí družicových scén, či bezpilotními prostředky. V případě využití umělých srážek se jednalo o dva různé dešťové simulátory při standardních erozních experimentech doprovázených povrchovým odtokem. Vytvořená metoda a model byly dále otestovány na klasifikaci mapových děl, pro hlubší porozumění modelu.

V rámci jednotlivých experimentů byly získané výsledky analyzovány a zhodnoceny z různých perspektiv. Výsledný model prošel testy na celkem 12 různých kombinacích vstupních parametrů, což přineslo širokou škálu výsledků. Tato komplexní sada experimentů poskytuje robustní a komparativní pohled na výkon modelu. Z porovnání těchto výsledků vyplynulo závěrečné hodnocení modelu, které nyní představuje klíčový přínos této práce.

Klíčová slova: Eroze půdy, Zemědělské plochy, Dálkový průzkum, Sběr dat o erozi, Automatizované metody, Detekce eroze, Klasifikační model, Analýza dat, Mapování eroze, Ochrana životního prostředí

ABSTRACT

The issue of soil erosion remains a contemporary concern, posing a significant threat to agricultural lands, their productivity, and the broader environment, encompassing water sources and urban areas. Although various methods exist for assessing erosion vulnerability and indirectly measuring and monitoring soil loss, there is still significant potential for their automation. This study addresses the collection of erosion data using indirect methods with the aim of developing a model or method capable of identifying and marking eroded areas with minimal human effort.

To achieve this goal, various types of experiments were conducted within the dissertation, testing, and validating these methods across multiple scales of experimental plots, ranging from small (4 m²) to entire cadastral areas (km²). These experiments were based on detecting erosion manifestations resulting from both natural and artificial precipitation in remote sensing data. Regarding natural precipitation, monitored plots within individual projects were observed using satellite scenes or unmanned aerial vehicles. In the case of artificial precipitation, two different rainfall simulators were employed during standard erosion experiments accompanied by surface runoff. The developed method and model were further tested on the classification of map sheets to deepen the understanding of the model.

The results obtained from each experiment were thoroughly analyzed and evaluated from various perspectives. The final model underwent tests across a total of 12 different combinations of input parameters, yielding a wide range of outcomes. This comprehensive set of experiments provides a robust and comparative view of the model's performance. The final assessment of the model, derived from comparing these results, represents a key contribution of this work.

Keywords: Soil erosion, Agricultural lands, Remote sensing, Erosion data collection, Automated methods, Erosion detection, Classification model, Data analysis, Erosion mapping, Environmental conservation

PODĚKOVÁNÍ

Chtěl bych poděkovat svému školiteli doc. Ing. Josefu Krásovi, Ph.D. za poskytnuté odborné znalosti a vedení této disertační práce. Dále bych rád poděkoval také doc. Ing. Petru Kavkovi za odborné vedení a rady v rámci dílčích projektů souvisejících s touto disertační prací. Za jazykovou a stylistickou asistenci děkuji Ing. Jakobovi Staškovi. Také bych chtěl poděkovat i ostatním členům Katedry hydromeliorací a krajinného inženýrství za jejich spolupráci při experimentálním měření. Bez jejich pomoci by nebylo provedení experimentů možné. V neposlední řadě bych chtěl poděkovat také mým rodičům za dlouhodobou podporu při mých studiích a přítelkyni za její trpělivost a oporu.

Obsah

Obsah.....	1
1 Motivace.....	5
1.1 Cíle.....	6
1.2 Časová osa vývoje modelu a experimentů.....	7
1.3 Přehled provedených experimentů.....	10
2 Úvod do problematiky vodní eroze.....	11
2.1 Vodní eroze jako globální riziko.....	11
2.2 Měření a monitoring eroze půdy.....	13
2.2.1.1 Přímé měření - Dešťové simulátory.....	14
2.2.2 Nepřímé měření erozních procesů – monitoring erozních projevů.....	18
2.2.2.1 Satelitní data.....	20
2.2.2.2 Letecké ortofoto a ortofoto z dronu.....	22
2.2.2.3 Fotogrammetrická metoda SfM-MVS.....	22
3 Software.....	25
3.1 Strojové učení pomocí neuronových sítí.....	25
3.2 Programovací jazyk.....	25
3.3 Knihovny.....	26
3.3.1 Scikit-image.....	26
3.3.2 Numpy.....	26
3.3.3 TensorFlow.....	26
3.3.4 SQLite3.....	27
4 Testované modely.....	28
4.1 Pixel by pixel.....	28
4.2 GLCM analýza.....	28
4.3 Ridge filtr.....	28
4.4 Blobs filtr.....	29

4.5	Vyhodnocení úspěšnosti modelů	30
4.5.1	Model pixel by pixel.....	30
4.5.2	Metoda GLCM.....	30
4.5.3	Ridge filter	31
4.5.4	Blobs filter.....	32
5	Segmentační model klasifikace obrazu.....	33
5.1	Kaggle Cats vs. Dogs model	33
5.2	Postup pro segmentaci scény	34
5.3	Trénink modelu.....	39
5.4	Klasifikace dat	42
5.5	Kompletní model	44
5.6	Dostupnost modelu	47
6	Experimentální aplikace – detekce erozního poškození	48
6.1	Satelitní snímky PlanetScope.....	48
6.1.1	Postup.....	49
6.1.2	Výsledky.....	54
6.2	Data z bezpilotních prostředků.....	56
6.2.1	Postup.....	57
6.2.2	Výsledky.....	61
6.3	Experimentální plochy Jirkov	65
6.3.1	Postup.....	66
6.3.2	Výsledky.....	69
6.4	Laboratorní dešťový simulátor	72
6.4.1	Postup.....	73
6.4.2	Histogram úspěšnosti klasifikace dle třídy	78
6.4.3	Závislost úspěšnosti dle tříd na velikosti segmentu.....	80
6.4.4	Závislost úspěšnosti dle tříd na počtu tréninkových segmentů.....	81
6.5	Souhrn výsledků a diskuse.....	81

7	Experimentální aplikace na skenech map	82
7.1	Motivace pro vyhodnocení map metodami strojového učení	82
7.1.1	TIFF15	83
7.1.2	JPEG	83
7.2	Základní vodohospodářské mapy	84
7.2.1	Postup	84
7.2.2	Výsledky	89
7.3	Mapy Stablního katastru	91
7.3.1	Císařské otisky stabilního katastru	91
7.3.2	Postup	93
7.3.3	Výsledky	97
7.4	Základní mapy z 80. let	99
7.4.1	Postup	99
7.4.2	Výsledky	106
8	Diskuse	108
8.1	Výběr použitých metod	108
8.2	Výsledky experimentálních aplikací	108
8.3	Výhody a nevýhody modelu	111
8.4	Problémy modelu	112
8.5	Zjištěné poznatky	112
8.6	Další postup výzkumu	113
9	Závěr	114
10	Seznamy	116
10.1	Seznam použité literatury	116
10.2	Seznam publikací autora	121
10.3	Seznam výzkumných projektů	125
10.4	Seznam obrázků	125
10.5	Seznam tabulek	127

10.6	Seznam grafů	127
10.7	Seznam zkratek.....	128

1 Motivace

Nedostatek informací o oblasti postižené erozí půdy, o její lokalitě a rozloze, je omezující pro přesné určení erozního poškození zemědělských pozemků. Většina z těchto snah je omezena na tradiční metody predikce erozního poškození pomocí empirických erozních modelů, jako je například Universal Soil Loss Equation (USLE) (Wischmeier and Smith 1978) či Revised Universal Soil Loss Equation (RUSLE) (Renard et al. 1997). Využívání leteckých snímků a satelitních dat značně zvýšilo kapacitu a monitorování eroze půdy na místních, národních a regionálních měřítcích (Le Roux et al. 2008). Tradiční techniky sběru dat o skutečném erozním poškození zahrnují manuální detekci erozního poškození zleteckých snímků a z měření v terénu. Hlavním problémem těchto přístupů je, že jsou omezeny na odborné znalosti, kromě toho, že jsou časově náročné a nákladné (Dube et al. 2017). Dálkový průzkum Země (DPZ) ve spojení s geografickým informačním systémem (GIS) poskytuje klíčové informace o erozní dynamice a intenzitě v čase a prostoru, což je kritické pro stanovení základní úrovně pro hodnocení, kontrolu a predikci eroze půdy. Potvrzují to četné studie, které byly doposud provedeny pomocí vyhodnocení satelitních dat (Sepuru and Dube 2018).

Jak je citováno v několika souvisejících studiích (Casalí, Giménez, and Bennett 2009; de Vente et al. 2009), eroze půdy se vyskytuje v mnoha formách, například eroze plošná, rýhová či stržová. Některé typy eroze je obtížné zjistit pomocí dat dálkového průzkumu. Pro zabránění erozi půdy a pro formulování nezbytných strategií ochrany je proto nezbytné znát prostorovou distribuci a velikost fenoménu (Seutloali, Dube, and Mutanga 2017).

Řadu let pokračují snahy o modelování erozních procesů, tyto erozní modely vycházejí ze sebraných informací o poloze a stupni erozních projevů pro svoji validaci (Demir and Dursun 2023; Jetten, Govers, and Hessel 2003). Vznikají také klasifikační modely využívající strojového učení pro identifikaci těchto projevů (Chakraborty et al. 2020; Roy et al. 2020). Tyto modely využívají informace z řady vstupních vrstev k rozlišení mezi erozními projevy a nepoškozenou půdou, či různými erozními poškozeními. Práce na tyto modely navazuje.

Pro zrychlení výzkumu a zajištění opakovatelnosti měření lze erozní poškození vytvářet uměle pomocí dešťových simulátorů. Jedná se o zařízení napodobující přírodní srážku. Tyto simulátory se staly důležitou metodou pro stadium eroze půdy a sledování hydrologických procesů. Provedené experimenty na simulátorech lze převést do digitální podoby pomocí metody Structure from Motion (Eltner and Sofia 2020) a vzniklá data analyzovat. Analýza takových dat má velmi blízko k analýzám satelitních a leteckých scén.

Část experimentálních dat této disertační práce využívá data získaná pomocí laboratorního dešťového simulátoru, na kterém autor prováděl dlouhodobá měření již od bakalářského studia. Drtivá většina

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země provedených experimentů však až do roku 2018 nebyla systematicky vyhodnocována pomocí fotogrammetrické metody. Z tohoto důvodu nebylo možné tuto velkou část experimentů zahrnout do výsledné analýzy této práce. Část využitých dat z laboratorního dešťového simulátoru se týká až období po jeho modernizaci od roku 2018, na které se autor podílel a která je popsána v článku od (Kavka et al. 2019). Po této rekonstrukci tak začali systematicky vznikat fotogrammetrická data metodou Structure from motion (SfM).

Autor této disertační práce publikoval článek zabývající se vývojem a automatizací monitoringu výparu (Tejkl and Kavka 2021). V tomto článku byl řešen jak vývoj software, tak příslušné elektroniky i vlastní konstrukce zařízení.

Během zpracování práce se naskytlá příležitost vyzkoušet vyvíjené klasifikační modely na datech jiných typů. Tato příležitost byla využita a analýzy poskytly další důležité poznatky o chování vyvíjených modelů a jejich silných a slabých stránkách.

1.1 Cíle

Téma disertační práce si dává za cíl rozvinout metody automatické detekce erozních projevů v různých měřících na datech získaných z experimentálních měření, která byla prováděna mezi lety 2015-2023.

Hlavním cílem této disertační práce je pomocí velkého množství provedených a vyhodnocených erozních experimentů vytvořit a natrénovat klasifikační model využívající postupy strojového učení, schopný klasifikovat snímek experimentální plochy na oblast bez poškození erozí, oblast s poškozením plošnou erozí a oblast poškozenou rýhovou erozí. Model by měl být schopný pracovat s daty ze satelitů, z bezpilotních monitorovacích prostředků či letadel a s daty vytvořenými pomocí fotogrammetrické metody SfM.

Dalším cílem je vyhodnotit úspěšnost klasifikace tohoto modelu a najít jeho silné a slabé stránky. Toho bude dosaženo spuštěním modelu na jednotné datové sadě s různým nastavením parametrů modelu. Jedná se především o vliv velikosti segmentu na úspěšnost klasifikace, kdy pro praktické využití modelu je snaha velikost segmentu zmenšovat, ideálně pracovat pouze s jednotlivými pixely. Dále posoudit vliv množství trénovacích dat na přesnost modelu. Obecně se předpokládá, že se snižujícím se množstvím tréninkových dat bude klesat úspěšnost modelu. Toto bude ověřeno a dále bude nalezena hranice, od které se úspěšnost snižuje významně.

Doplňujícím cílem práce je ověřit použití klasifikačního modelu pro další typy analýz jako je digitalizace map pro získání informací o využití území, či identifikaci určitých prvků na mapách. Dále budou analyzovány výsledky různých modelů a hledány cesty a doporučení, jak s takovými výsledky dále pracovat.

Toto téma svým zaměřením navazuje na výsledky disertační práce Ing. Markéty Báčové s názvem „Monitoring projevů vodní eroze na zemědělských půdách“ (Báčová 2018) a výsledky disertační práce Ing. Tomáše Laburdy s názvem „Modelování eroze půdy s využitím dat podrobného monitoringu“ (Laburda et al. 2021). V práci Laburdy (2021) byl stanoven základní postup využití nepřímých bezkontaktních metod při monitoringu eroze půdy a zároveň byla v rámci této práce vytvořena řada scén povrchu dešťového simulátoru, včetně modelu terénu a nalezeny důležité poznatky. Všechny tyto poznatky byly cennými podklady a poskytly užitečné informace při tvorbě mé disertační práce z hlediska metodiky automatické detekce erozních projevů. Z tohoto důvodu je tato disertační práce oproti zmiňované práci Ing. Tomáše Laburdy zaměřena na hromadné vyhodnocení velkých setů naměřených dat. Negativní vliv možných chyb může být eliminován právě na základě dat vytvořených v rámci jeho práce.

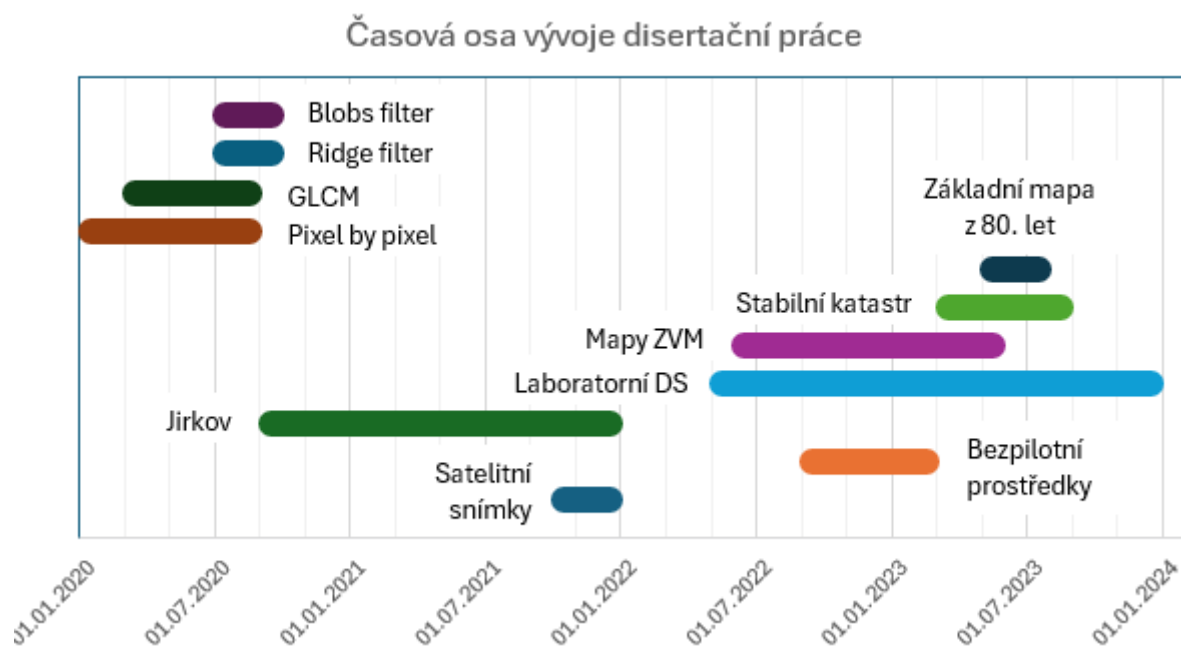
1.2 Časová osa vývoje modelu a experimentů

Vývoj modelu započal na začátku roku 2020 (viz Obr. 1). Během zahraničního studia v Německu jsem se zapojil do projektu analýzy satelitních snímků zájmové lokality v Indii. V tomto projektu bylo významně využíváno strojového učení k analýze snímků. Jednalo se především o analýzu a třídění jednotlivých pixelů pomocí trénovaných modelů. Byly zkoušeny modely založené na algoritmech Support Vector Machine (Chang and Lin 2011), Nearest Neighbors a Decision Trees (Goldberger et al. 2004). Použití těchto modelů však nevedlo k požadované přesnosti výsledků. Po diskusích s kolegy tak bylo přikročeno k otestování metod zahrnujících sousední pixely do analýzy. Po krátké rešerši byla nalezena metoda Gray Level Coocurrence Matrix (GLCM), k jejímu použití bylo nutné vyvinout segmentační skript. Ani využití metody GLCM k rozšíření základny pro modely pracující s jednotlivými pixely však nevedlo k uspokojivým výsledkům.

Po návratu ze zahraničního studia byly získané poznatky a zkušenosti využity k vývoji modelu pro Automatizaci komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země. V rychlém sledu byly vyzkoušeny metody Pixel by pixel, GLCM a předzpracování dat pomocí filtrů Blobs a Ridge. Modely byly zkoušeny na dostupných datech z erozního výzkumu Katedra hydromeliorací a krajinného inženýrství. Žádná z vyzkoušených metod však nepřinesla požadované výsledky.

Po další rešerši a s vyvinutou metodou segmentace snímku bylo přikročeno k testování modelů rozpoznávání obrazu pomocí trénovaných neuronových sítí. Metoda byla experimentálně využita na datech z erozního výzkumu na lokalitě Jirkov (projekt Navrhování technických opatření pro stabilizaci a ochranu svahů před erozí) toto testování ukázalo potenciál metody. Zároveň se ukázala potřeba vývoje robustní metody validace úspěšnosti modelu a zpracování výsledků modelu do stavu vhodného pro další využití v erozním výzkumu.

Následovalo testování metody na satelitních datech z projektu Monitoring erozního poškození půd a projevů eroze pomocí metod DPZ. Tento test potvrdil potenciál metody a potřebu spolehlivé metody validace výsledků modelu.



Obr. 1 Časová osa vývoje disertační práce

Posledním typem dat využívaným pro monitoring eroze jsou data z bezpilotních prostředků, které nebyly zatím vyzkoušeny na modelu. Bylo tedy přikročeno k analýze dat z bezpilotních prostředků, nasbíraných také v rámci projektu Monitoring erozního poškození půd a projevů eroze pomocí metod DPZ. V rámci tohoto experimentu byl vytvořen skript vytvářející validační matici. Pro úspěšné vytvoření validační matice je však nutná systematická tvorba tréninkových polygonů. Za tím účelem byla přepracována většina předchozích skriptů.

V rámci projektu Potenciál a rizika závlah na území ČR v měnícím se klimatu vyvstala potřeba vytvořit mapu realizovaných velkoplošných závlahových staveb. K tomuto účelu lze s úspěchem použít Základní vodohospodářské mapy, na kterých jsou závlahové soustavy velmi přesně zakresleny. Manuální digitalizace těchto staveb je však časově náročná a uživatelsky nepříjemná. Toto jsou stejné problémy, se kterými se střetává manuální digitalizace erozního poškození. Bylo tak rozhodnuto použít vyvíjený model pro tento účel. Během zpracování Map ZVM byla dopracována metoda filtrace výsledků modelu a dalšího zpracování do formy polygonů. Zároveň se ukázaly problémy modelu, jako pády klasifikačního skriptu a složitost změny klasifikačních tříd.

Úspěšnost modelu pro digitalizaci map ZVM byla dále využita pro digitalizaci map Stabilního katastru a Základních map z 80. let v rámci projektu The impact of depopulation on ecosystem services

in Europe. A pilot study in France, Czech Republic and Poland. Tato aplikace umožnila vyzkoušet model na více než třech klasifikačních třídách a třídách představujících různé jevy (body, linie, plochy, tvary a šrafy).

Všechny předešlé aplikace umožnily odladit model do finální podoby. Vznikl tak finální model, složený z řady na sebe navazujících skriptů, který začíná řadou RGB scén a tréninkových polygonů a končí validační maticí pro každou analyzovanou scénu. Finální otestování tohoto modelu proběhlo na řadě 12 scénářů s různým nastavením parametrů.

1.3 Přehled provedených experimentů

Následující tabulka (Tab. 1) shrnuje jednotlivé aplikace Segmentačního modelu klasifikace a jejich parametry.

Experiment	Satelitní snímky PlanetScope	Bezpilotní prostředky	Jirkov	Halový DS	Mapy ZVM	Stabilní katastr	Základní mapa z 80. let
Zdroj dat	Satelitní scény	Bezpilotní scény	SfM	SfM	Sken	Sken	Sken
Pásma	R, G, B, NIR	R, G, B	R, G, B	R, G, B, DMT	Colormap	R, G, B	R, G, B
Velikost pixelu (m)	3,0	0,23	0,001	0,001	3,18	0,459	0,459
Trénovací linie	X	X					
Trénovací polygony			X	X	X	X	X
Počet tříd	2	3	3	3	3	5	9
Vzájemný posun	VH	VH	VH	V, H, VH	V, H, VH	V, H, VH	V, H, VH
Otočení a zrcadlení	X	X	X	X			
Délka hrany segmentu (m)	48, 30	4,9, 7,3, 10,1, 15,2	0,05	0,05, 0,075, 0,1	98,58	25,908	22,958, 32,141, 41,324
Doplňkové vrstvy	Grayscale, Canny Edge	Grayscale	Grayscale, Canny Edge	Flow Direction, Grayscale		Grayscale	Grayscale
Typ řídicí databáze	CSV	CSV	CSV	SQLite	CSV	CSV	SQLite
Průměrování	X	X	X	X	X	X	X
Filtrace	X	X	X	X	X		
Posouzení		X		X	X		
Validace	Optická	Validační matice	Optická	Validační matice	Optická	Optická	Optická
Výstup	Rastr	Rastr	Rastr	Rastr	Polygony a body	Bezešvý rastr	Bezešvý rastr

Tab. 1 Přehled provedených experimentů

2 Úvod do problematiky vodní eroze

2.1 Vodní eroze jako globální riziko

Eroze půdy je jev, který byl, je a bude do jisté míry jevem přirozeným. V důsledku lidské činnosti či změnám klimatu však dochází v krajině ke změnám, které tento jev umocňují do takové míry, kdy probíhá eroze zrychlenou formou, která není dlouhodobě udržitelná. Vzhledem k tomu, že půda je jedním z nejcennějších přírodních bohatství a neobnovitelným přírodním zdrojem, mělo by být o ni s tímto ohledem pečováno. Eroze má mnoho podob lišících se způsobem, časem a také místem působení. V České republice je nejzávažnější formou tohoto jevu eroze vodní, ohrožující zemědělské pozemky ve svažitéch terénech, při které dochází k narušení schopnosti půdy plnit své základní produkční i mimoprodukční schopnosti. Zrychlená forma eroze půdy připravuje zemědělské pozemky o její nejúrodnější část – ornici, zhoršuje fyzikálně-chemické vlastnosti půd, snižuje mocnost půdního profilu, obsah nutrientů a humusu, zvyšuje šterkovitost, poškozují vegetaci případně způsobuje odnos osiva a v neposlední řadě ztěžuje pohyb agrotechniky (Novák, Vopravil, and Lagová 2010)

Zrychlená eroze půdy je výsledkem lidské činnosti a změn v krajině spojených s našimi aktivitami. Ačkoliv v některých rozvinutých zemích jsou prováděna opatření na ochranu půdy před erozí, v méně rozvinutých oblastech, jako je subsaharská Afrika, Jižní Amerika a jihovýchodní Asie, se očekává nárůst eroze půdy s postupným rozvojem zemědělství a rozšiřováním zemědělské půdy. Mezi lety 2001 a 2012 došlo především díky těmto regionům k celosvětovému zvýšení eroze půdy o 2,5 % (Borrelli et al. 2017). Z ekonomického hlediska bylo spočítáno, že celosvětová roční ztráta půdy, odhadovaná na 17 miliard tun, přináší náklady na ztrátu produkce a řešení škod ve výši 8×10^9 USD (Sartori et al. 2019).

Celosvětově je ohroženo erozí půdy celkem 20 % zemědělské půdy, přičemž 7 % půdy je vystaveno alespoň dvěma degradačním procesům (Právělie et al. 2021). Z hlediska ohrožení zemědělských půd na území ČR je erozí ohroženo přes 60 % orné půdy. Z toho vodní erozí je ohroženo přibližně 50 % orné půdy a dále přibližně 10 % orné půdy je ohroženo erozí větrnou. Na většině ohrožených pozemků přitom není prováděna systematická protierozní ochrana, která by snižovala ztrátu půdy pod limity přípustných hodnot (Janeček 2012).

V současné době existují metody, které nám umožňují měřit a modelovat účinky vodní eroze, což nám pomáhá do jisté míry předvídat tuto problematiku. Díky těmto postupům můžeme předejít nepříznivým důsledkům vodní eroze a chránit jak přírodní prostředí, tak i lidský majetek. Nicméně, je stále třeba pokračovat v rozvoji výzkumu v oblasti vodní eroze a zkoumat nové metody monitorování, hodnocení, predikce a prevence eroze (Nearing and Hairsine 2010).

Snaha zabránit zrychlené erozi půdy by měla být záležitostí každého majitele nebo nájemce zemědělské půdy. Toto je důležité nejen z hlediska ochrany životního prostředí a cenného přírodního zdroje, kterým půda bezesporu je, ale také z finančního hlediska v případě žádosti o státní podporu na implementaci protierozních opatření. Požadavky, které musí dodržovat zemědělci v České republice, kteří žádají o plnou podporu, jsou specifikovány v rámci standardů pro Dobrý zemědělský a environmentální stav půdy (DZES). Tyto standardy zabezpečují, že hospodaření je v souladu s ochranou životního prostředí a jsou rovněž součástí Kontroly podmíněnosti (Cross Compliance) (Novotný et al. 2017).

Při hodnocení erozních jevů a jejich důsledků v krajině je důležité klasifikovat erozi do jednotlivých forem, které jsou definovány tím, jak je povrchový odtok koncentrován na dané ploše a jaké následné projevy zanechává. Obecně lze proto vodní erozi rozdělit do dvou hlavních forem: plošná a rýhová. (Holz et al. 2015).

Plošná eroze je forma eroze charakteristická tím, že působí přibližně rovnoměrně v celé zasažené oblasti. Plošná eroze zahrnuje i prvotní fázi jakékoliv eroze, včetně kapkové eroze (Zhang 2019). Kapková eroze začíná dopadem dešťových kapek, které přenášejí svou kinetickou energii na půdní částice nebo půdní agregáty, které následně rozpadnou na menší části a jednotlivé půdní částice. Tímto způsobem dochází k zahájení erozního procesu, který probíhá téměř nepozorovatelně po celé postižené oblasti. S postupným nasycováním infiltrační kapacity půdy začíná vytvářet povrchový odtok, který zpočátku působí přibližně rovnoměrně a rozptýleně. Avšak v závislosti na geomorfologických charakteristikách území může docházet k postupnému koncentrování povrchového odtoku, což vede ke vzniku nepravidelného, koncentrovaného povrchového odtoku, a v tomto bodě už nelze hovořit o plošné erozi.

Výmolná eroze vzniká za určitých geomorfologických podmínek postupným soustřeďováním povrchového odtoku do preferenčních cest a následnou tvorbou erozních rýh, které zpočátku mohou být mělké, ale s časem se prohlubují. Hloubka, délka a rozsah těchto erozních útvarů dělí výmolnou erozi na další podkategorie:

- Rýžková eroze je charakterizována drobnými rýžkami o hloubce do 10 cm.
- Brázdová eroze zahrnuje nepravidelné mělké a širší zářezy.
- Rýhová eroze se projevuje širšími rýhami a může dosahovat hloubky až 30 cm.
- Výmolná eroze může zahrnovat výmoly hluboké až 100 cm, zejména na místech, kde se několik rýh soustřeďuje.
- Stržová eroze je nejvýraznější formou výmolné eroze a zahrnuje strže, které mohou být hluboké více než 1 metr a mít délku přes 1 kilometr (Novotný et al. 2017).

Výzkum eroze má své kořeny přibližně od první poloviny 20. století. Studie, která se zabývá vývojem erozního výzkumu od roku 1900 do roku 2013 (Zhuang et al. 2015), ukazuje, že erozní výzkum se zejména soustředil v USA a evropských zemích, které dominovaly v počtu publikovaných vědeckých studií až do roku 2001. Avšak od tohoto data lze pozorovat výrazný nárůst publikací v oblasti eroze půdy, zejména v Číně a částečně i v Austrálii. Důsledkem tohoto trendu jsou vysoké počty publikací od výzkumných institucí, především Chinese Academy of Sciences (Čína), následované United States Department of Agriculture - Agriculture Research Service (USDA-ARS) (USA) a Katholieke Universiteit Leuven (Belgie).

Čína má pravděpodobně nejvyšší počet publikací v oblasti eroze půdy díky odhadům o nejvyšší míře ztrát půdy způsobených vodní erozí, které dosahují mezi 150 až 200 tunami půdy na hektar za rok. USA také čelí ztrátám půdy způsobeným vodní erozí, s odhady v rozmezí 5 až 170 tun půdy na hektar za rok (Senanayake et al. 2020).

Pokud jde o kategorie erozního výzkumu, nejvíce publikací bylo věnováno zemědělství (46 %), životnímu prostředí a ekologii (30 %) a geologii (26 %), následované vodními zdroji (22 %) (Zhuang et al. 2015). Toto ukazuje, že eroze půdy je významným tématem, které souvisí s různými aspekty vědeckého výzkumu a měřítkem jeho globálního významu. Zjištění ze studie od (Zhuang et al. 2015) jsou zajímavá a ukazují vývoj v oblasti výzkumu eroze půdy. Význačným trendem je, že v posledních letech bylo více studií zaměřeno na životní prostředí a geologii než na zemědělství, což naznačuje rostoucí důraz na aspekty související s ochranou životního prostředí.

Klíčová slova používaná v těchto studiích jsou také zajímavá. Vedle nejběžnějších termínů jako "eroze půdy" a "odtok" byla často zdůrazňována klíčová slova související s použitými metodami. Nejčastěji zmiňované metody jsou "GIS", "remote sensing" (vzdálený průzkum) a „machine learning“ (strojové učení). Tato zjištění naznačují, že moderní technologie a analýzy provedené v GIS z dat vzdáleného průzkumu, vyhodnocených metodami strojového učení, mají stále větší roli ve studiích týkajících se eroze půdy.

2.2 Měření a monitoring eroze půdy

Pro zrychlení výzkumu a zajištění opakovatelnosti měření lze erozní poškození vytvářet uměle pomocí dešťových simulátorů. Jedná se o zařízení napodobující přírodní srážku. Tyto simulátory se staly důležitou metodou pro stadium eroze půdy a sledování hydrologických procesů (Cerdà 1999). Je mnoho způsobů, jak je tvořena srážka – například kapkovací, tryskové, rotující disk a další, které popisuje (Lal 1994). Pro určení prostorového rozložení srážky, a tedy správného nastavení simulátoru je nejčastěji užíván Christiansenův index uniformity (Christiansen 1942). Názory na velikost experimentální plochy se dle autorů různí. Například (Abudi, Carmi, and Berliner 2012) píše, že by plocha měla být větší než

1 m². Na druhou stranu (Calvo 1988) uvádí, že pro zkoumání jednotlivých jevů hydrologických procesů a eroze vedlo k vývoji malých zařízení na ploše do přibližně 1 m². Na světě jsou používány malé a velké simulátory. Není přesně dána hranice, co je nazýváno malým a co velkým simulátorem. Obecně se udává, že malé simulátory používají plochy menší než 1 m² až přibližně 5 m² (Kinnell 2016).

V případě malých dešťových simulátorů v Evropě provedl úpravy (Cerdà, Ibáñez, and Calvo 1997), a následně probíhalo vylepšování, (Iserloh et al. 2012) a další. Jedná se o zařízení důležité pro výzkum eroze v polních i laboratorních podmínkách. Velké dešťové simulátory mají výhodu, že je kromě plošného odtoku možné sledovat i soustředění odtoku do rýh. Velké simulátory se často užívají na plochách kratších než 10 m (Kinnell 2016). Porovnání několika velkých dešťových simulátorů užívaných ve střední Evropě provedl (Kavka et al. 2015).

Tyto metody měření erozních procesů lze rozdělit na dvě hlavní kategorie:

- Přímé měření erozních procesů: Tato metoda zahrnuje zaznamenávání a měření erozních procesů v reálném čase. Typickými příklady jsou experimentální měření množství povrchového odtoku a odběr vzorků pro analýzu množství sedimentu v něm. Tato měření často zahrnují použití experimentálních erozních ploch, které využívají přirozené srážky nebo umělé srážky generované dešťovými simulátory.
- Nepřímé měření erozních procesů: Tato metoda se zaměřuje na zaznamenání erozních projevů na základě porovnání stavu terénu před a po srážkové události. Zahrnuje monitorování a rekonstrukci morfologických změn na základě porovnání povrchu před a po srážkové události s následným vyhodnocením těchto změn. Toto měření může zahrnovat kontaktní nebo moderní bezkontaktní metody, jako je digitální fotogrammetrie. Sem lze také zařadit sledování koncentrace nerozpuštěných látek ve vodních tocích, což slouží jako indikátor erozních procesů, a měření erozních procesů na základě analýzy rozpadu radionuklidů v půdních vzorcích.

Tyto metody umožňují získávat data o erozních procesech a jejich dopadech na terén, což je důležité pro porozumění a monitorování eroze půdy a přijímání opatření k ochraně půdy a krajiny.

2.2.1.1 Přímé měření - Dešťové simulátory

Dešťové simulátory jsou významnými nástroji pro výzkum eroze půdy, protože umožňují generovat kontrolované srážkové události s přesně definovanými parametry a usnadňují studium různých erozních procesů. Tyto zařízení byly vyvinuty v podobném období, kdy začaly vznikat erozní modely, a to přibližně ve 30. a 40. letech 20. století (Cerdà 1999).

Dešťové simulátory jsou význačné tím, že umožňují experimentální měření erozních procesů s vysokou opakovatelností a kontrolou nad prostředím. Při těchto experimentech se sledují různé parametry a procesy, které souvisejí s erozí půdy. (Comino 2021):

Kromě těchto erozních parametrů je také důležité sledovat charakteristiky generovaných dešťových kapek, protože přesná definice těchto parametrů umožňuje výzkumníkům dosáhnout co nejděšnějšího modelování přirozených srážkových událostí. Dešťové simulátory jsou tedy klíčové pro vývoj a validaci erozních modelů a pro porozumění erozním procesům v různých krajinných kontextech.

Celkově je sledování intenzity deště a dalších charakteristik dešťových kapek důležité pro správné vyhodnocení srážko-odtokových experimentů a dešťových simulací, které mají za cíl studovat erozi půdy a její procesy. Kalibrace zařízení a kontrola rovnoměrnosti distribuce srážky jsou klíčové pro získání spolehlivých dat.

Je důležité, že mnoho studií se zaměřuje na vývoj a optimalizaci dešťových simulátorů s cílem dosáhnout co nejděšnější reprezentace přirozených dešťů. Výběr konkrétního typu dešťového simulátoru a jeho parametrů, které mohou být upraveny podle potřeb a cílů daného výzkumu. Kalibrace a kontrola dešťových simulátorů jsou klíčové pro dosažení přesných a spolehlivých výsledků.

Laboratorní (stabilní) dešťové simulátory představují velmi sofistikované řešení, které nabízí řadu výhod i nevýhod. Jako hlavní výhody lze zmínit především velmi vysokou míru kontroly charakteristik deště a počátečních podmínek a vlastností testovaného půdního vzorku. To vše lze provádět velmi často s vysokou mírou reprodukovatelnosti. Nevýhoda těchto zařízení spočívá především v omezené velikosti jak zadešťované plochy, tak především v mocnosti půdního vzorku, který nikdy nemůže obsáhnout celý půdní horizont jako je tomu v terénu na přirozeném půdním profilu. Velká většina laboratorních dešťových simulátorů pracuje s experimentální zadešťovanou plochou do 20 m² a s intenzitami do 200 mm.hod⁻¹ (Kalibová, Jačka, and Petru 2016) (Pan, Ma, and Shangguan 2010) (Zambon et al. 2021). Nicméně existují výjimky, jako například největší laboratorní dešťový simulátor, který je schopen experimentálně testovat velké vzorky s plochou až 3000 m² a při velmi vysokých intenzitách až 300 mm.hod⁻¹. Toto zařízení je velmi specifické a je mimo standardních erozních experimentů orientováno více na sesuvy půdy a jiné extrémní jevy. (NIED 2023).

V rámci této disertační práce byla využita data naměřená pomocí těchto zařízení:

- Laboratorní DS ČVUT v Praze
- Venkovní stabilní DS na lokalitě Jirkov

Laboratorní DS (Fakulta stavební, ČVUT v Praze)

Laboratorní dešťový simulátor Katedry hydromeliorací a krajinného inženýrství se nachází ve Vodohospodářském experimentálním centru Fakulty stavební, ČVUT v Praze. Tento simulátor byl zkonstruován mezi lety 1998 až 2000 z komponentů dodaných z USA podle předlohy podobného zařízení univerzity BOKU ve Vídni. Ve své době se jednalo o čistě tryskový dešťový simulátor konstrukce typu „Norton Ladder Rainfall Simulator“ (pojmenovaný podle autora Dr. Darrela Nortona z USDA-ARS). Laboratorní dešťový simulátor se využívá k experimentálnímu měření erozních procesů na porušených půdních vzorcích, kde se monitoruje a odebírá množství povrchového odtoku, perkolace, měří se rychlost povrchového odtoku a z odebraných vzorků odtoku se následně se vyhodnocuje půdní smyv (Koláčková 2005).

Po dlouholetém používání laboratorního dešťového simulátoru se objevila potřeba modernizace, aby bylo možné splnit nové požadavky dané novými metodami experimentálního měření a zvýšenými možnostmi nastavení parametrů. Původní konstrukce simulátoru měla omezení, jako byl omezený rozsah nastavení sklonu experimentální plochy, nedostatečná variabilita charakteristik deště a nízký stupeň automatizace měření různých parametrů. Proto byl v roce 2017 navržen nový koncept konstrukce, který měl tyto nedostatky odstranit. V roce 2018 proběhla rekonstrukce, která zahrnovala nezávisle pohyblivý podvozek s erozním kontejnerem, ke kterému bylo možné připojit zadešťovací systém.

Nová konstrukce umožnila zvětšení půdorysné rozlohy experimentální plochy na 4 × 1 m, a přesto zůstaly zachovány otvory ve dně kontejneru pro měření infiltrace. Největší inovací bylo začlenění hydraulického pístu mezi podvozek a erozní kontejner, což umožňuje nastavit sklon v rozsahu od 0° do 40°. Tento rozsah je plně využitelný i pro testování eroze a stability svahů silničních násypů a zářezů.

Kontejner byl také vybaven tepelnou izolací a na jeho dně byl nainstalován výkonný tepelný/chladicí systém propojený s klimatizační jednotkou, což umožňuje nastavit teplotu půdního vzorku v rozmezí od -15 °C do +40 °C. Další modifikace byla provedena u zadešťovacího zařízení, které bylo v nové verzi zdvojeno. Systém kyvných trysek VeeJet na dvou sekcích byl rekonstruován s použitím nového materiálu, ale s ponecháním původních rozměrů a parametrů. Navíc byl mezi oběma sekcemi přidán druhý zadešťovací systém sestavený z pevných pulzních trysek WSQ 40, které byly ovládány solenoidovými ventily. Toto uspořádání umožňuje simulovat silné srážky s maximální intenzitou až 160 mm/hod. Obě zadešťovací systémy jsou umístěny na pohyblivém roštu, což umožňuje nastavit výšku nad povrchem půdy v rozmezí od 2,0 do 2,8 m s krokem 0,1 m. Všechny tyto konstrukční vylepšení jsou

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země doplněny senzory a čidly pro kontinuální monitorování tlaku vody, teploty, intenzity deště, infiltrace a vlhkosti půdy (Kavka et al., 2019).

Po dokončení rekonstrukce samotného zařízení DS následovala celková modernizace Vodohospodářského experimentálního centra, kde je toto zařízení umístěno. Modernizace měla za následek nepřístupnost zařízení po celý rok 2019. Na začátku roku 2020 byla modernizace DS dokončena v podobě kompletního přemístění na jiné místo ve Vodohospodářském experimentálním centru, což bylo vhodnější pro prováděné experimenty. Bylo nově umístěno v úrovni podlaží, což zajišťuje snadnější přístupnost a usnadňuje měření srážko-odtokových parametrů a získávání fotogrammetrických dat.

Venkovní stabilní DS (stavební společnosti Strix s.r.o. v Jirkově)

Venkovní dešťový simulátor je provozován společností Strix s.r.o. a nachází se v Jirkově, Ústecký kraj. Tento simulátor, který lze zařadit mezi laboratorní typy dešťových simulátorů, je jednoduchého tryskového typu. Konstrukce simulátoru zahrnuje lešenářské trubky, které jsou pevně spojeny s experimentální plochou vytvořenou ocelovým kontejnerem. Experimentální plocha má půdorysné rozměry 4 x 2,2 metru a výšku 1,6 metru. Celkově jsou připraveny tři jedinečné experimentální plochy s různými sklony, které odpovídají běžným sklonům vytvářeným při budování silničních násypů a zářezů (1:1,5, 1:1,75 a 1:2,5). Zadešťovací zařízení na každé z experimentálních ploch se skládá z dvou trysek, které jsou umístěny na horní konstrukci simulátoru. Tyto trysky umožňují simulovat různé charakteristiky deště na základě tvaru samotných trysk a nastaveného tlaku vody. Běžně používaná intenzita deště se pohybuje v rozmezí 120 až 160 mm/hod.

Příprava experimentálních ploch

Experimenty samotné probíhaly na upravených plochách, které imitovaly podmínky na zemědělské půdě v případě mělkého úhoru. Každý experiment zahrnoval dvě srážkové epizody a měření 1 a 2. První epizoda začínala simulací deště na suchém povrchu, trvala 30 minut a byla následována 15minutovou pauzou. Po této pauze následovala druhá srážková epizoda na již mokřím povrchu, trvající také 30 minut. Během každé simulace byl povrchový odtok odebírán ve 2,5minutových intervalech (celkem 12 vzorků) pro následnou analýzu množství erodovaných půdních částic. V některých případech, konkrétně v lokalitě Jirkov, byl tento experimentální režim opakován přibližně po 10 dnech na ploše, která nebyla po první a druhé simulaci upravena. Tyto opakování tvořily další dvojici experimentů označenou jako 3 a 4.

Příprava fotogrammetrických dat

Nahrány byly snímky podle lokality, úpravy povrchu a čísla simulace. Prvním krokem bylo jejich prvotní orientační spojení v softwaru Agisoft Metashape. Poté byly na snímcích automaticky detekovány referenční terče a přiřazeny jim odpovídající souřadnice z připraveného souboru pro jednotlivé plochy podle zaměření pomocí totální stanice (v případě Jirkova) nebo definovaného souřadného systému (v případě laboratorního DS).

Rozlišení dat z lokality Jirkov bylo průměrně 0,34 mm/pixel s průměrnou výškou snímání 1,4 m nad povrchem půdy. Naopak, rozlišení dat z lokality ČVUT bylo průměrně 0,24 mm/pixel s průměrnou výškou snímání 98 cm nad povrchem půdy.

Pro určení přesnosti byly vypočteny vertikální a horizontální střední hodnoty chyb pro referenční kontrolní body (RMSEz a RMSExy). V lokalitě Jirkov bylo dosaženo RMSEz 6,28 mm se směrodatnou odchylkou 1,61 mm a RMSExy 5,94 mm se směrodatnou odchylkou 2,18 mm. Na měřicím stanovišti laboratorního DS ČVUT bylo dosaženo hodnoty RMSEz 2,77 mm se směrodatnou odchylkou 1,61 mm a hodnoty RMSExy 1,72 mm se směrodatnou odchylkou 0,70 mm. Byla také vypočítána hodnota LoD (Level of Detection) dle Williams (2012), která pro data z lokality Jirkov činila 8,78 mm a pro data z lokality ČVUT 3,92 mm. LoD udává minimální změnu, kterou je možné s danou metodou detekovat.

Ne vždy se podařilo získat kompletní DEM experimentální plochy. Nekompletní DEM mohou vzniknout z různých důvodů, jako je špatné snímání, nedostatečný počet snímků, malý překryv mezi snímky, nepříznivé světelné podmínky (silné slunce a hluboké stíny), a tak dále. Důležité také bylo vyloučení oblastí s možnými rušivými vlivy, jako jsou vlhkostní čidla na povrchu půdy, která způsobují nežádoucí efekty.

Oříznutí výpočtových polygonů se provedlo na základě ortofoto snímků a chybějících částí DEM. Zásadním kritériem pro úpravu polygonu bylo, aby zahrnoval plochy, které jsou dostupné ve všech třech DEM (před simulací, po suché simulaci a po mokré simulaci). V případě laboratorního dešťového simulátoru, kde jsou umístěna vlhkostní čidla na povrchu půdy, se polygon upravuje tak, aby nezahrnoval místa s čidly a jejich kabely, tak aby nedocházelo k ovlivnění dat.

2.2.2 Nepřímé měření erozních procesů – monitoring erozních projevů

V porovnání s přímým měřením erozních procesů v reálném čase se zde jedná o následné nepřímé měření následků eroze po ukončení samotného erozního procesu. Tato metoda vyžaduje schopnost zaznamenat změny, které nastaly na zkoumaném území, ať už se jedná o celé povodí nebo pouze menší erozní plochu. Pro tuto analýzu je nezbytné mít k dispozici dvě sady dat, a to data o stavu území před

erozní událostí a data o jeho stavu po ní. Díky těmto dvěma sadám dat je pak možné provést analýzu a zhodnotit změny, jež na dané experimentální ploše proběhly.

Tyto metody lze rozdělit podle několika různých kritérií podle způsobu získání dat na kontaktní (profilometry, reliéf metry, pin metry, roller chain) a bezkontaktní (DPZ).

Kontaktní metody pro zaznamenávání tvaru povrchu půdy a sledování erozních jevů byly jedny z prvních metod využívaných v tomto kontextu, a jejich historie sahá až do 50. let 20. století (Hudson, 1993). Existují však některé nevýhody spojené s těmito kontaktními metodami. Mezi ně patří možnost deformace, poškození nebo ovlivnění povrchu půdy samotnými měřicími zařízeními a nutností fyzického přístupu na místo měření. Tato omezení jsou zejména problematická při sledování syplých a suchých půd nebo při měření velkých erozních ploch. Další nevýhodou těchto metod je časová a logistická náročnost a omezené rozlišení výsledných dat (Jester and Klik 2005).

Dále lze aplikovat rozdělení, které se týká již pouze modernějších bezkontaktních metod DPZ (Žížala and Krása, 2016) dle následujících kritérií rozdělení podle:

- Technologie pořízení obrazu na konvenční (fotografické) a nekonvenční (skenery, radary, termokamery, lasery)
- Zdroje energie na aktivní (lasery) a pasivní (odraz slunečního záření)
- Druhu nosiče (satelitní, letecké, UAV, pozemní)
- Spektra využívaného elektromagnetického záření (RGB, multispektrální data, termosnímký)
- Metody zpracování dat na 2D (jednotlivé ploché snímky) a 3D (fotogrammetrie, laser skenery)

Z uvedeného rozdělení metod je obecně nejčastěji používanou bezkontaktní metodou fotogrammetrie, která zahrnuje snímání objektů a povrchů z různých úhlů s využitím fotografických technik. Tato metoda může být provedena pozemně (terestrická fotogrammetrie), z letadla (letecká fotogrammetrie) nebo pomocí bezpilotních prostředků (UAV). Druhou nejběžnější metodou pro bezkontaktní rekonstrukci objektů a povrchů je metoda založená na aktivním zdroji energie, obvykle laserovém paprsku, což je princip, který využívají laserové skenery, známé také jako LiDAR (Hänsel et al. 2016). Tyto metody, podobně jako fotogrammetrie, mohou být prováděny pozemně (terestrický laserový skenování - TLS), z letadla (letecké laserové skenování - ALS) a stále více se využívají ve spojení s bezpilotními prostředky (UAV) (Amon et al. 2015) (Mandlbürger et al. 2020).

Fotogrammetrická metoda má tu výhodu, že je schopna dosáhnout dostatečné přesnosti s použitím standardních fotografických technik a zpravidla nabízí vynikající poměr mezi přesností a náklady. Avšak není vždy vhodná pro snímání složitých tvarů s lesklými povrchy, jako je například vegetace nebo povrchy pokryté vodní hladinou (Cook 2017).

Naopak metoda založená na laserovém skenování obvykle vyžaduje vyšší finanční náklady a manipulaci s většími laserovými skenery, což ji činí méně dostupnou než běžné fotografické techniky. Tato metoda také může vyžadovat více času k dosažení srovnatelného rozlišení (Eltner, Maas, and Faust 2018). Výhodou však je, že LiDAR metoda nemá omezení spojená s odrazivostí povrchů a umožňuje detekovat i skryté povrchy (Nouwakpo, Weltz, and McGwire 2016).

V České republice jsou běžně dostupná data z leteckého laserového skenování, která pokrývají celou zemi a jsou označena jako digitální model reliéfu ČR 5. generace (DMR 5G) pro popis přirozeného terénu a digitální model povrchu ČR 1. generace (DMP 1G) pro popis terénu včetně budov a vegetace. Tato data byla získána během leteckých prací v letech 2009 až 2013 a zveřejněna od roku 2016. DMR 5G dosahuje výškové přesnosti střední chyby 0,18 m v odkrytém terénu a 0,3 m v zalesněném terénu. DMP 1G dosahuje výškové přesnosti chyby 0,4 m pro budovy a 0,7 m pro vegetaci, jako jsou lesy a další prvky rostlinného pokryvu (Geoportál 2023). Pokud je potřeba získat přesnější a aktuálnější data, je třeba provést samostatné nebo komerční měření s využitím pozemního nebo leteckého laserového skenování.

Monitoring na základě dvou sad dat, které zachycují stav bez erozního projevu a s erozním projevem, případně rozvoj erozního poškození, má své výhody i nevýhody. Mezi výhody tohoto přístupu patří možnost porovnávání aktuálních dat s archivními leteckými nebo satelitními snímky z minulých let. I přes omezenou přesnost a kvalitu dat umožňuje tento způsob sledovat změny využití krajiny a odhadovat množství eroze půdy během vývoje krajiny (Báčová and Krása 2016) (Žížala et al. 2019). Nevýhoda spočívá v nutnosti mít zaznamenaný stav před erozní událostí a týká se spíše kvality a rozlišení dat než samotné proveditelnosti tohoto postupu. Díky archivním datům ortofotosnímků lze porovnání různých časových stavů využít a sledovat změny v krajině a erozní procesy. Nicméně je nutné erozní poškození nalézt na velkém množství detailních archivních snímků.

2.2.2.1 Satelitní data

Omezením pro měření erozního poškození je nedostatek přesných informací o oblasti postižené erozí půdy a její velikosti. Většina z těchto snah je omezena na tradiční metody, jako je například Universal Soil Loss Equation (USLE) (Wischmeier and Smith 1978) či Revised Universal Soil Loss Equation (RUSLE) (Renard et al. 1997). Využívání satelitních dat značně zvýšilo kapacitu a možnosti monitorování eroze půdy na místních, národních a regionálních stupnicích (Le Roux et al. 2008). Je to proto, že tradiční techniky erozního modelování zahrnují manuální detekci erozního poškození z leteckých snímků a z měření v terénu. Hlavním problémem těchto přístupů je, že jsou omezeny na odborné znalosti, kromě toho, že jsou časově náročné a nákladné (Dube et al. 2017). Dálkový průzkum ve spojení s GIS poskytuje klíčové informace o erozní dynamice a intenzitě v čase a prostoru, což je kritické pro

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země stanovení základní úrovně pro hodnocení, kontrolu a predikci eroze půdy. Potvrzují to četné studie, které byly doposud provedeny pomocí satelitních technologií. (Sepuru and Dube 2018)

Jak je citováno v několika souvisejících studiích (Le Roux et al. 2008)(Dube et al. 2017), eroze půdy se vyskytuje ve formě eroze plošné, nebo rýhové, z nichž některé z nich je obtížné zjistit pomocí dat dálkového průzkumu. Pro zabránění erozi půdy a pro formulování nezbytných strategií ochrany je proto nezbytné znát prostorovou distribuci a velikost fenoménu (Seutloali et al. 2017)(Dube et al. 2017).

Družice Sentinel 2 je multifunkční průzkumná družice s velmi širokým záběrem a vysokým rozlišením, v rámci programu Copernicus Land Monitoring. Scény mohou být využity pro monitorování vegetace, půdy a vodních zdrojů, jakož i pozorování vnitrozemských vodních cest a pobřežních oblastí. Družice Sentinel 2 je vybavena multispektrálním senzorem (MSI), který vzorkuje 13 spektrálních pásem: čtyři pásma s 10m rozlišením, šest pásem s 20m rozlišením a tři pásma s rozlišením 60 m. (Anon 2019c)

Družice Landsat 8 je vybavena senzorem Operational Land Imager (OLI), vyrobený společností Ball Aerospace & Technologies Corporation, měří ve viditelných, blízkých infračervených a krátkovlnných infračervených částech spektra. Jeho snímky mají 15m panchromatické a 30m multi-spektrální prostorové rozlišení při 185 km širokém záběru. Toto řešení umožňuje při jednom přeletu pokrýt širokou oblast zemské krajiny při dostatečném rozlišení pro identifikaci urbanizace, lesů a jiného využití půdy. Celá Země je zachycena jednou za 16 dní díky blízké polární orbitě. (Anon 2019b)

Data z družic by nebyla použitelná, pokud by k nim nebyl zajištěn přístup. U družic Evropské a Americké vesmírné agentury je přístup součástí mise družice a je tak zcela veřejný. Kromě veřejných serverů pro přístup k datům dále existuje řada soukromých společností, které přístup k datům nabízejí za poplatek, nicméně s některými výhodami oproti zdarma dostupným veřejným serverům. (Anon 2019d)

Moderní satelitní technologie dokážou zachytit snímky s nižším než metrovým rozlišením. Satelity z konstelace PlanetScope mohou zachytit rozsáhlé pásy zemského povrchu s častou frekvencí opakování. (Curnick et al. 2022) (Roy et al. 2021). Tyto typy satelitních snímků mají potenciální využití pro detekci a sledování krajinného pokryvu a eroze. (Lake 2022)

Snímky PlanetScope jsou krokem vpřed z hlediska prostorového i časového rozlišení. PlanetScope je konstelace více než 200 satelitů, které poskytují denní globální pokrytí obrazu v prostorovém rozlišení 3–5 m. Normální velikost scény je přibližně 24 km × 7 km, ale to se může lišit s nadmořskou výškou. Snímky v tomto rozlišení a frekvenci opakovaných návštěv umožňují mapování větších oblastí v lesích a významně zvyšují možnosti sledovat drobné změny v pokryvu povrchu, jako je selektivní těžba dřeva nebo eroze půdy. Potenciální aplikace snímků PlanetScope, ale nejsou omezeny na monitorování pokryvu povrchu. Snímky PlanetScope také rozšiřují možnosti zachytit celou fenologii růstu plodin

a variaci stavu rostlin uvnitř polních bloků, které lze obtížně zachytit při nižším časovém a prostorovém rozlišení. (Pickering et al. 2021)

2.2.2.2 *Letecké ortofoto a ortofoto z dronu*

Dle (Krása 2021) ČÚZK poskytuje od roku 2016 letecké ortofotosnímky v rozlišení 20 cm/pixel (dříve s nižším rozlišením) s náletem poloviny republiky každé dva roky. K těmto snímkům lze poptat série ortofotosnímků od společnosti TopGIS z libovolné části ČR. Tyto snímky mají rozlišení 12,5 cm/pixel.

2.2.2.3 *Fotogrammetrická metoda SfM-MVS*

Jedním ze zpracovávaných dat této disertační práce byla také data vytvořená metodou Structure from Motion - Multi-View Stereo (SfM-MVS) fotogrammetrie. Fotogrammetrie je obor zabývající se rekonstrukcí tvarů objektů na základě fotografických snímků. Využití fotogrammetrických principů v souvislosti s výzkumem půdy začalo nabývat na významu od 80. let, kdy se prováděly první pokusy o měření drsnosti povrchu půdy pomocí stereofotogrammetrie (Peter Heng et al., 2010). Postupně docházelo k rozvoji fotogrammetrických metod pro parametrizaci půdního povrchu a kvantifikaci povrchových změn.

Ačkoliv byly do konce 90. let převážně používány analogové fotografické přístroje (Warner, 1995), digitální fotoaparáty začaly být široce využívány od roku 2000 díky jejich rostoucí dostupnosti a vývoji technologie (Abd Elbasit et al., 2009; Báčová et al., 2019a; Jester and Klik, 2005). Následně i fotoaparáty zabudované do mobilních telefonů se staly důležitým nástrojem pro tvorbu digitálních modelů terénu (Prosdocimi et al., 2017; Vinci et al., 2017; Wrózyński et al., 2017).

Použitá technologie a fotografická technika ovlivňují přesnost a rozlišení výsledných produktů. Důležité faktory zahrnují rozlišení snímače, ohniskovou vzdálenost a optickou kvalitu objektivu, vzdálenost přístroje od snímaného povrchu a také vlastnosti povrchu, jako je morfologická složitost, textura a odrazivost povrchu. Klimatické podmínky a osvětlení během snímání také hrají klíčovou roli.

Metoda SfM-MVS je založena na průsekové fotogrammetrii a slouží k rekonstrukci objektů a povrchu na základě snímání z různých úhlů a pozic. Metoda SfM-MVS přináší výhody, jako je snadnější získání 3D modelů bez potřeby předem známých souřadnic referenčních bodů na snímcích. Dále umožňuje georeferencování s minimálním počtem referencovacích bodů. Přesnost a kvalita výsledků jsou ovlivněny kvalitou snímků, technickými parametry fotoaparátu a vlastnostmi snímaného povrchu (Furukawa and Hernández, 2015; Furukawa and Ponce, 2010).

Rozlišení snímače a obrazového materiálu je klíčovým faktorem pro přesnost a detail digitálních modelů terénu (DEM) a ortofoto snímků vytvořených metodou SfM-MVS. Toto rozlišení udává, kolik zemského povrchu pokrývá jeden pixel na výsledném obrazu a ovlivňuje podrobnost a kvalitu výsledného

produktu. Standardní hodnota rozlišení u ortofoto snímků se pohybuje v rozmezí desítek centimetrů na pixel (například 20 cm/pixel pro ortofoto ČR poskytované Českým úřadem pro zeměměřictví a katastr nemovitostí).

Pomocí moderních metod, jako je snímání pomocí bezpilotních prostředků (UAV), může být dosaženo vysokého rozlišení, zejména pokud lze ovlivnit výšku letu (Johnson et al., 2003, Mancini et al., 2013). Běžné hodnoty prostorového rozlišení se díky tomu zvýšily z desítek centimetrů na jednotky centimetrů. Při nízkých výškách letu se dokonce dosahuje rozlišení pod centimetr. To umožňuje vytvářet velmi detailní DEM a ortofoto snímky. Například ortofoto ČR poskytované ČÚZK dosahuje rozlišení 20 cm/pixel (ČÚZK: Geoportál, 2016), což je běžná hodnota při využití leteckého snímání, ale i satelitních dat (Turner et al., 2012).

Při pozemní fotogrammetrii, což zahrnuje blízké snímání z pozemního stanoviště, lze dosáhnout sub-milimetrového rozlišení. Standardně se používá rozlišení 1 mm/pixel, a to jak při využití fotogrammetrie, tak při použití laserových skenerů. Tato technika umožňuje vytvářet extrémně detailní a přesné modely terénu nebo povrchu (Rieke-Zapp et al., 2001).

Softwary

V dnešní době je k dispozici široká škála softwarů pro zpracování fotogrammetrických dat metodou SfM-MVS, a to od komerčních až po open-source řešení, včetně webových služeb, které provádí veškeré zpracování v cloudovém prostředí. Mezi nejběžněji používanými komerčními softwary pro zpracování snímků patří Agisoft Metashape (dříve známý jako Agisoft Photoscan) (Agisoft LLC, 2018). Tento software nabízí uživatelsky přívětivé prostředí, vysoký výkon a široké možnosti nastavení. Proto se stává jedním z nejčastěji využívaných programů v rámci studií zaměřených na erozi a další podobné oblasti (Cândido, 2019; Eltner et al., 2015; Ngadiman et al., 2018; Prosdocimi et al., 2017; Smith et al., 2016).

Vztah fotogrammetrických dat k erozi půdy

Bezkontaktní fotogrammetrická metoda SfM-MVS se v dnešní době používá k vyhodnocení stejných dat jako v minulosti pomocí kontaktních metod. Hlavním rozdílem je způsob získání těchto dat, přesnost, časová efektivita a kvalita dat. Jedním z nejběžněji studovaných aspektů na sledovaných územích nebo plochách je plocha zasažená erozním poškozením. Tato plocha je spojena s poškozením půdy erozí či depozicí materiálu. Případně lze vymezenou plochu použít k výpočtu objemu erodovaného materiálu pomocí rozdílů DEM. Výpočet změny objemu půdního vzorku se nejčastěji provádí odečtením digitálních modelů terénu před událostí (DEM1) od digitálních modelů terénu po události (DEM2). V případě erozních experimentů bývá sledovanou událostí obvykle srážková situace. Odečtením těchto

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země

dvou digitálních modelů terénu vzniká digitální model rozdílu (Digital Elevation Model of Difference - DoD), který zachycuje změny ve výšce terénu ve stejném měřítku jako vstupní data (Williams, 2012).

Aplikace v erozním výzkumu

Pro fotogrammetrické zpracování byly na experimentálních plochách v lokalitě Jirkov a v halovém dešťovém simulátoru ČVUT v Praze instalovány referenční vlíčovací terče (GCP). Tyto terče byly umístěny po obvodu experimentálních ploch a sloužily k vytvoření přesného souřadného systému pro následné referencování získaných dat.

Na lokalitě Jirkov bylo celkem 11 terčů - 9 terčů umístěných po obvodu a 2 terče umístěny na dělicím prkně uprostřed plochy. Všechny terče byly zaměřeny pomocí totální stanice, a jejich souřadnice byly poté použity pro referencování dat.

V halovém dešťovém simulátoru ČVUT bylo instalováno celkem 24 terčů, které byly rovnoměrně rozloženy po obvodu plochy. Tyto terče byly vyrobeny tiskem na 1 metr dlouhých páskách z měkčeného PVC a měly předem definovaný souřadný systém. Terče byly připevněny na okraji erozní plochy v souladu s předem definovanými vzdálenostmi mezi jednotlivými terči.

Pro fotogrammetrické snímání experimentálních ploch byly použity bezzrcadlové fotoaparáty Sony s čipem typu APS-C. Na lokalitě Jirkov byl použit fotoaparát Sony NEX-5N s rozlišením snímače 16,1 Mpx, spolu s objektivem Samyang o ohniskové vzdálenosti 12 mm (ekvivalent 18 mm na kinofilmu). Na laboratorním dešťovém simulátoru ČVUT byl použit fotoaparát Sony A6000 s rozlišením snímače 24,1 Mpx a objektivem Sony 16-50 mm nastaveným na 16 mm (ekvivalent 24 mm na kinofilmu).

Každé měření zahrnovalo pořízení řady fotografií. Na lokalitě Jirkov bylo potřeba přibližně 80-100 fotografií, zatímco na laboratorním dešťovém simulátoru stačilo kolem 50-70 fotografií. Snímky byly pořízeny kolmým snímáním ve dvou řadách na okraji erozní plochy s co největším překryvem sousedních snímků v podélném i příčném směru (přibližně 80% překryv).

Při snímání byl zvolen režim priority clony s hodnotou okolo F8 a citlivostí okolo hodnoty ISO 800 (max. 1600). Toto nastavení mělo za cíl dosáhnout co největší hloubky ostrosti snímků, ale zároveň zajišťovalo, že expoziční čas nebyl kratší než přibližně 1/80 sekundy, což pomáhalo udržet dostatečnou ostrost snímků.

3 Software

Automatizace monitoringu široce využívá výpočetní techniku k provádění jednotlivých operací. Jedná se většinou o počítače s vyšším výkonem procesorů a grafických karet. Na těchto počítačích je nainstalován speciální software umožňující provádět příslušné úkony, případně je software vytvořen pro konkrétní úkol ve zvoleném programovacím jazyce.

3.1 Strojové učení pomocí neuronových sítí

Algoritmy hlubokého učení poskytují řešení pro širokou škálu inženýrských a vědeckých problémů prostřednictvím různých typů neuronových sítí. Stále pokračuje vývoj lepších architektur strojového učení, aby byly efektivnější a výkonnější. Pro trénink a provoz sítí lze využít standardní počítače s běžnými CPU, upravené grafické karty GPU nebo přímo speciální TPU. TPU jsou speciální procesory navržené přímo pro provoz strojového učení. Neuronové sítě se skládají z jednotlivých vrstev a jejich vztahů. S těmito vrstvami lze provádět řadu operací jako je konvoluce nebo sdružování hustých vrstev. Vrstvy lze navrhovat pomocí vlastních definic vrstev, či využívat ověřené postupy. Pro další urychlení práce lze použít výhod hardwarové akcelerace. (Akgun 2022)

3.2 Programovací jazyk

Pro geografické analýzy, zpracování dat z dronů a satelitů je široce využíván software ArcGIS. Tento software je zdarma dostupný pro studenty ČVUT FSv, a je využíván i v rámci katedry. V rámci softwaru ArcGIS je možné spouštět programy psané v programovacím jazyce **Python**, samotný program pak využívá programovací jazyk ve svých nástrojích. Bylo tak zvoleno vytvořit model také v tomto programovacím jazyce.

Python je přehledný a výkonný objektově orientovaný programovací jazyk, srovnatelný s Perl, Ruby, Scheme nebo Java. Python může bezproblémově fungovat na různých platformách, jako je Windows, Linux a Mac. Mezi jeho přední stránky patří použití elegantní syntaxe, což usnadňuje čtení programů. Díky tomu je Python ideální pro vývoj prototypů a další ad-hoc programovací úlohy, aniž by byla ohrožena údržba takovýchto úloh. Je také dodáván s velkou standardní knihovnou prvků, která podporuje mnoho běžných programových úloh, jako je připojení k webovým serverům, vyhledávání v textu, čtení a úprava souborů. Interaktivní režim Pythonu umožňuje snadno otestovat krátké úryvky kódu. Python má jednoduchou syntaxi podobnou anglickému jazyku. Python je interpretovaný jazyk, což znamená, že se provádí kód řádek po řádku. Pokud dojde k nějaké chybě, dojde k zastavení dalšího postupu, dokud programátoři nenajdou chyby a opraví je. Python přichází s mnoha standardními knihovnami pro mnoho uživatelům a s velkým výběrem potřebných funkcí pro jejich úkoly. (Huang 2023)

K dispozici je také vývojové prostředí s názvem IDLE. Je snadno rozšiřitelný přidáním nových modulů implementovaných v kompilovaném jazyce jako C nebo C ++. Může být také vložen do aplikace, která poskytuje programovatelné rozhraní. Stahování nebo používání Pythonu, nebo jeho zahrnutí do aplikace je zcela zdarma. Python může být také volně modifikován a re-distribuíván, protože i přes to, že jazyk je chráněn autorskými právy, je distribuován pod open source licenci. (Anon 2019a)

3.3 Knihovny

V oblasti dálkového průzkumu mají zvláštní význam dostupnost a funkčnost softwaru pro provádění požadovaného zpracování datových sad. Jedním z klíčových požadavků pro zpracování dat dálkového průzkumu je možnost zahrnout geoprostorové informace, a to jak při čtení dat, tak při tvorbě finálních výstupů. (Krása, Tejkl, and Stašek 2019)

3.3.1 Scikit-image

Scikit-image je knihovna pro zpracování obrazu, která implementuje algoritmy a nástroje pro použití ve výzkumu, vzdělávání a průmyslových aplikacích. Poskytuje řadu návodů a jednoduché uživatelské rozhraní v jazyce Python. Knihovna je vyvinuta aktivním mezinárodním týmem spolupracovníků (van der Walt et al. 2014). Knihovna nabízí algoritmy pro hledání charakteristických prvků obrazu (Gouillart 2017). Pro analýzu snímků erozního poškození půdy se jeví výhodné použití nástroje Ridge filter z knihovny pro hledání hranových prvků, těmito prvky mohou být horské hřebeny, řeky, cévy. Dalším perspektivním nástrojem se jeví použití nástroje Blob filter pro vyhledávání plošných kruhovitých prvků, těmito prvky mohou být písečná zrna nebo bakteriální kolonie (Merritt and Kuehn 2016). Toto je přímo spojené s erozními projevy, jež vytváří charakteristickou stromovou strukturu či dochází k odhalení písčitého nebo štěrkového podkladu.

3.3.2 Numpy

Analýza dat často zahrnuje provádění operací na velkých objemech dat. Numpy je výkonná sada nástrojů, která umožňuje rychle a snadno pracovat s velkými daty. Může se jednat o listy, matice i jednotlivé proměnné. Zároveň je možné pracovat s celými čísly i s desetinnými čísly. Knihovna Numpy umožňuje v případě matic pracovat po prvcích, nebo provádět bitové operace. (Artasanchez and Joshi 2020) V rámci segmentace snímků byl rastrový obraz převeden na matici a tato matice byla postupně procházena analyzačním oknem. K tomuto je knihovna Numpy přímo určena. Dále bylo prováděno otáčení a zrcadlení matic, výpočet maxima, minima a dalších statistických veličin. Knihovna Numpy tak byla zásadní pro tvorbu modelu.

3.3.3 TensorFlow

TensorFlow je rozsáhlá knihovna pro strojové učení, kterou lze použít v mnoha různých situacích. Je výkonná s užitečnými nástroji pro vývoj a testování architektur strojového učení. TensorFlow

poskytuje rozhraní pro různé jazyky, jako je Python, Java a C#. Umožňuje distribuovat proudy toku dat mezi více počítačů v clusteru, stejně jako různé procesorové jednotky v rámci jednoho systému, jako jsou vícejádrové CPU a specializované výpočetní procesory. Nízko úroňové uživatelské rozhraní umožňuje TensorFlow běžet na specializovaných výpočetních procesorech a urychluje trénink a používání modelů strojového učení. Vývojáři mohou definovat své vlastní vrstvy pomocí specifických definic tříd v TensorFlow, vlastní vrstvy usnadňují integraci nové vrstvy do architektury cílového modelu. (Akgun 2022). Knihovna TensorFlow nabízí nástroje pro široký rozsah aplikací, které se zaměřují na odvození a trénink hlubokých neuronových sítí. Tyto nástroje využívá například několik služeb Google. Knihovna je vydána jako open-source projekt, který je široce používán ve výzkumu strojového učení (Ramchandani et al. 2022). Pro stavbu modelu byly použity nástroje z knihovny TensorFlow. Tyto nástroje umožnily postavit samotný model, zkonstruovat jednotlivé uzly sítě, definovat spoje mezi uzly sítě a natrénovat model.

3.3.4 SQLite3

SQLite knihovna, obsahuje samostatný zapisovací databázový nástroj. Na rozdíl od většiny ostatních databází SQL nemá SQLite samostatný serverový proces. SQLite čte a zapisuje přímo do běžných diskových souborů. Kompletní databáze SQL s více tabulkami, indexy, spouštěči a pohledy je obsažena v jediném souboru na disku. Formát databázového souboru je multiplatformní – databázi lze libovolně kopírovat mezi 32bitovými a 64bitovými systémy. Díky těmto funkcím je SQLite populární volbou jako formát souboru aplikace.

SQLite obecně pracuje rychleji, čím větší objem paměti je dostupný. Nicméně výkon je dobrý i v prostředí s nízkým objemem paměti. V závislosti na tom, jak se používá, může být SQLite rychlejší než přímý souborový zápis systému. Tato vlastnost je výhodná vzhledem k obrovskému množství vznikajících segmentů, kdy každý segment má v databázi vlastní zápis.

SQLite elegantně reaguje na selhání alokace paměti a chyb přímého zápisu souboru do systému. Zápisy jsou platné, i když jsou přerušeny pády systému nebo výpadky napájení (Anon 2023) . Toto se během testování ukázalo jako problém při používání CSV souborů k ukládání dat a SQL databáze toto vyřešila. Použití SQL databází pak dále nabídlo rychlý výběr záznamů k analýze, jejich filtraci či úpravu.

4 Testované modely

Testování modelů proběhlo na datech z Laboratorního dešťového simulátoru. Data a simulátor jsou detailně popsány v kapitole 2.2.1.1 a 2.2.2.3.


4.1 Pixel by pixel

První vyzkoušenou metodou klasifikace byla klasifikace pomocí trénovaného modelu, který klasifikoval každý pixel zvlášť. Vstupní matice je převedena na databázi pixelů, kde je v příslušném sloupci informace, zda pixel obsahuje rýhu či nikoli. Z knihovny Scikit Learn je importován klasifikační model Random forest classification, vstupní databáze je rozdělena na trénovací a testovací část a model je spuštěn. Je tak vytvořen jednoduchý Random forest model, který následně zatřídí pixely předem neklasifikovaných snímků.

4.2 GLCM analýza

GLCM je zkratkou Gray Level Co-occurrence Matrix. Podstatou této metody je výpočet a odvození „texturní míry“ z barevného obrazu převedeného na černobílý. Jedná se o sérii komplexních deskriptivních charakteristik matice zvolené velikosti, tato matice je běžně vytvořena jako segment původní scény. Vzniká tak série nových scén pro každou texturní míru. (Haralick, Dinstein, and Shanmugam 1973)

GLCM analýza byla provedena pro 7 texturních měř. Jednalo se o Contrast, Dissimilarity, Homogeneity, Symmetry, Entropy, Mean a Variance. Tyto míry byly vytvořeny jak pro vertikální, tak pro horizontální směr a pro velikosti segmentu 3, 5, 8 a 10 pixelů.



Obr. 2 Ukázka GLCM analýzy pro míru Contrast, s velikostí segmentu 5 pixelů a vertikální směr

4.3 Ridge filtr

Ridge filtry používají Hessovu matici. Hessova matice je čtvercová matice druhých parciálních derivací skalární funkce. Při detekci hřebenových struktur, se využívá jevu, kdy se intenzita mění více kolmo na strukturu, ale ne podél struktury. Matice se musí nalézat uvnitř zpracovávaného rastru. Nelze ji tak použít v těsném sousedství okraje rastru. Dochází tak k tzv. okrajovým efektům. Výsledky pro filtry Meijering a Frangi jsou tak oříznuty o několik pixelů na každém okraji, aby bylo dosaženo správného

vykreslení. S větší hodnotou parametru rozsah roste oříznutí u okrajů. Toto není vážný problém, okraj plochy je zpravidla tvořen rámem žlabu dešťového simulátoru.

4.4 Blobs filtr

Byly testovány tři varianty filtru vyhledávajícího shluky (blobs). Tento filtr má potenciál identifikovat minerální zrna odkrytá dopadajícími kapkami deště a stékající vodou. Tato odkrytá zrna jsou charakteristická pro plošnou erozi.



Obr. 3 Detail plochy s plošnou erozí

První varianta je Laplacian of Gaussian (LoG). Toto je nejpřesnější a nejpomalejší varianta. Proveďte Laplaciánskou nebo Gaussovu transformaci obrazu s postupně rostoucí směrodatnou odchylkou a skládá se do krychle. Bloby jsou místní maxima v takto vytvořené krychli. Detekce větších blobů je obzvláště pomalejší kvůli větší velikosti jádra během konvoluce. Jsou detekovány pouze světlé skvrny na tmavém pozadí. Superparametry algoritmu jsou minimální sigma, maximální sigma a rozdělení sigma mezi minimem a maximem.

Další varianta je Difference of Gaussian (DoG). Jedná se o rychlejší variantu přístupu LoG. V tomto případě se obraz rozostřuje s rostoucí směrodatnou odchylkou a rozdíl mezi dvěma postupně rozostřenými obrazy je naskládán do krychle. Tato metoda má stejnou nevýhodu jako přístup LoG pro detekci větších blobů. Opět se předpokládá, že bloby jsou světlé na tmavém pozadí. Superparametry algoritmu jsou minimální sigma, maximální sigma a poměr sigma mezi minimem a maximem.

Další metodou je Determinant of Hessian (DoH). Toto je nejrychlejší přístup. Detekuje bloby tím, že najde maxima v matici determinantu hessiánské transformace obrazu. Rychlost detekce je nezávislá na velikosti blobů, protože metoda interně používá box filtr místo konvolucí. Jsou tak detekovány světlé bloby na tmavých pozadích i tmavé bloby na světlých pozadích. Nevýhodou je, že malé bloby (<3px)

nejdou přesně detekovány. Parametry algoritmu jsou minimální sigma, maximální sigma a rozdělení sigma mezi minimem a maximem.

4.5 Vyhodnocení úspěšnosti modelů

Modely byly hodnoceny na základě několika parametrů. Primární bylo optické hodnocení úspěšnosti zvýraznit rýhové erozní poškození ve výstupní vrstvě, pokud je výsledkem rastr. Pokud byl výsledek formou tabulky bylo provedeno statistické vyhodnocení validačních dat. Dalšími hodnotícími kritérii byla časová náročnost výpočtu a procesní náročnost aplikace modelů na velké množství snímků.

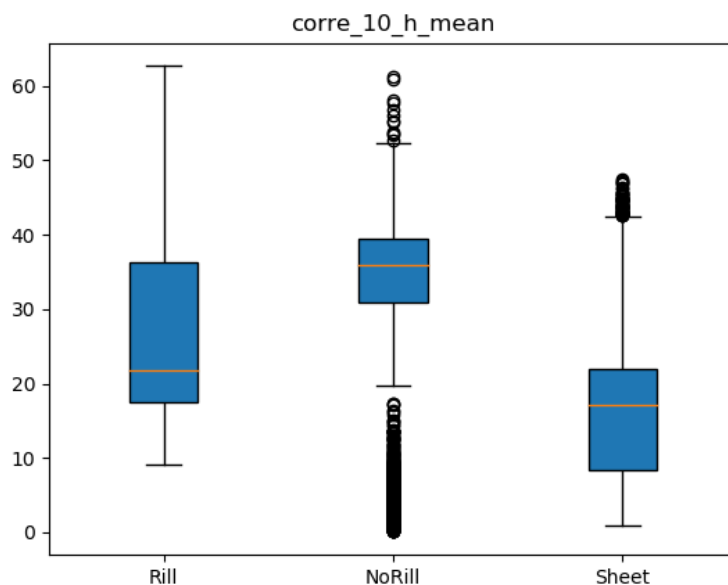
4.5.1 Model pixel by pixel

Současné výsledky ukazují celkovou úspěšnost modelů pracujících metodou pixel by pixel 98 %. Nicméně úspěšnost nalezení rýhy se pohybuje okolo 70 %, úspěšnost nalezení prosté půdy se pohybuje přes 90 %. Tento rozptyl je zřejmě způsoben značně nerovnoměrným rozložením třídy rýha a třídy prostá půda ve vstupních datech, kdy množství pixelů prosté půdy značně převyšuje množství pixelů rýhy.

4.5.2 Metoda GLCM

Analýza GLCM nabízí určitý potenciál, nicméně výpočet jednotlivých texturních měř je velmi časově náročný a vzniká velké množství dat. Až 18 nových scén z jedné černobílé scény pro jednu velikost segmentu. Vyhodnocení této metody je tak značně náročné.

Bylo vyzkoušeno statisticky vyhodnotit jaké hodnoty texturních měř odpovídají jednotlivým posuzovaným kategoriím. Z analýz box plotů jednotlivých měř je vidět určitý potenciál pro přímé využití hodnoty míry k zařídění segmentu do klasifikovaných tříd. Nicméně jednotlivé kategorie vykazují značný překryv.




Obr. 4 Ukázka box plotu hodnot GLCM analýzy validačních polygonů pro míru Correlation, s velikostí segmentu 10 pixelů a horizontální směr

4.5.3 Ridge filter

Nejprve byla otestována varianta Frangi. Tato varianta poskytla nevýrazný výsledek, na kterém bylo velmi obtížné identifikovat rýhy. Výhodou varianty byl normalizovaný výsledek s hodnotami mezi 0 a 1.

Další byla testována varianta Sato. Varianta Sato je založena na kombinaci hodnot Hessovy matice pro několik filtrů (Sah et al. 2019). Tato varianta se opět neukázala jako perspektivní a dále neposkytuje normalizovaný výstup.

Další variantou je Hessian. Tato varianta produkuje výrazné rozdíly mezi plochou a rýhou, při hodnotě rozsahu 30. Vyzkoušen byl také průměr rozsahu 30, 40 a 50 a následné zhlazení dat nástrojem *Focal statistics* se čtvercem o hraně délky 10 pixelů. Došlo k částečnému zvýraznění ploch s rýhou. Také došlo k rozšíření neanalyzovaných okrajů.




Obr. 5 Výsledek Ridge filtru metody Hessian

Poslední zkoušená varianta filtru byla varianta Meijering. Tato metoda poskytuje normalizovaný výstup, dle vizuálního hodnocení skýtá určitý potenciál.

4.5.4 Blobs filter

Všechny Blobs filtry jsou charakteristické vysokou časovou náročností na výpočet výsledku. Zároveň je výsledkem bodová vrstva a použití této vrstvy k identifikaci erozního poškození se ukázalo jako velmi problematické.



Obr. 6: Výsledek Blobs filtru DoG10_50_16

5 Segmentační model klasifikace obrazu

Další analyzovanou metodou byla klasifikace segmentovaného obrazu. Tato metoda spočívala v rozložení obrazu na jednotlivé segmenty, stejně jako u metody GLCM, a jejich následné individuální klasifikaci pomocí trénované neuronové sítě.

5.1 Kaggle Cats vs. Dogs model

Jako základ pro konstrukci modelu byl využit model Kaggle Cats vs. Dogs. Jedná se o vítězný model soutěže strojového učení Kaggle (Jajodia and Garg 2019) konané v roce 2013, běžně známé jako Kaggle Cats vs. Dogs (Cukierski 2013). Tento model je pojmenován podle soutěžního datasetu, který se skládá z fotografií psů a koček. Datový soubor byl původně vytvořen jako zcela automatizovaný veřejný Turingův test, který má určit, zda se jedná o počítač či člověka (Computers and Humans Apart tzv. CAPTCHA). Konkrétně byl tento úkol znám jako rozpoznávání obrázků živočišných druhů pro omezení přístupu (Asirra) (Elson et al. 2007).

Model byl speciálně navržen tak, aby zvládl zatřídit 25 000 označených fotografií (Sermanet et al. 2013). Pro svou jednoduchost a skutečnost, že jej lze snadno uložit do paměti, se tento model stal oblíbeným mezi začátečníky v oblasti počítačového rozpoznávání obrazu a jako výchozí bod pro studium konvolučních neuronových sítí.

Model Kaggle Cats vs. Dogs je navržen tak, aby zvládl obrázky různých tvarů a velikostí, díky segmentačnímu přístupu a předdefinované velikosti mozaiky tato část modelu nebyla nutná. Tato skutečnost také redukovala problémy týkající se problémů s využitím paměti původního modelu.

Architektura modelu je Visual Geometry Group (VGG) a skládá se z bloků, kde každý blok je složen z vrstev 2D Convolution a Max Pooling. Architektura VGG je modulární, snadno pochopitelná a implementovatelná. S rostoucím počtem vrstev v konvoluční neuronové síti (CNN) se také zvyšuje schopnost modelu přizpůsobit se složitějším funkcím.

Architektura zahrnuje vrstvení konvolučních vrstev s malými 3×3 filtry následovanými maximální sdužovací vrstvou. Tyto vrstvy dohromady tvoří blok a tyto bloky lze opakovat, přičemž počet filtrů v každém bloku se zvyšuje s hloubkou sítě, jako je 32, 64, 128, 256 pro první čtyři bloky modelu. Na konvolučních vrstvách se používá odsazení, aby se zajistilo, že tvary výšky a šířky výstupních map prvků odpovídají vstupům.

Každá vrstva bude používat funkci Rectified Linear Activation Function (ReLU) a inicializaci váhy He, toto jsou obecně osvědčené postupy. ReLU je po částech lineární funkce, která bude vydávat vstup přímo, pokud je kladný, jinak bude na výstupu nula. ReLU se stala výchozí aktivační funkcí pro mnoho typů neuronových sítí, protože model, který ji používá, se snáze trénuje a často dosahuje lepšího výkonu.

V neuronové síti je aktivační funkce zodpovědná za transformaci sečteného váženého vstupu z uzlu na aktivaci uzlu nebo výstupu pro tento vstup.

5.2 Postup pro segmentaci scény

Na Obr. 7 je zobrazeno schéma modelu pro experimentální aplikaci na erozních plochách na vnitřním dešťovém simulátoru. Schéma se může v určitých částech měnit vzhledem k určení a vývojovému stadiu modelu. Nejčastěji se mění počet klasifikačních tříd, případně kroky, které se realizují po opětovném načtení dat do prostředí ArcGIS.

Celý proces analýzy začíná načtením scény do pracovního prostředí ArcGIS. Scény jsou standardně dostupné jako georeferencovaný TIFF, tato vlastnost značně ulehčuje jejich zpracování.

Manuální tvorba trénovacích polygonů

Je-li rozhodnuto o použití scény k tréninku a validaci modelu je prvním krokem analýzy manuální tvorba trénovacích polygonů. Polygony jsou tvořeny tak, že obkružují vyšetřované jevy, zpravidla s mírným odstupem.

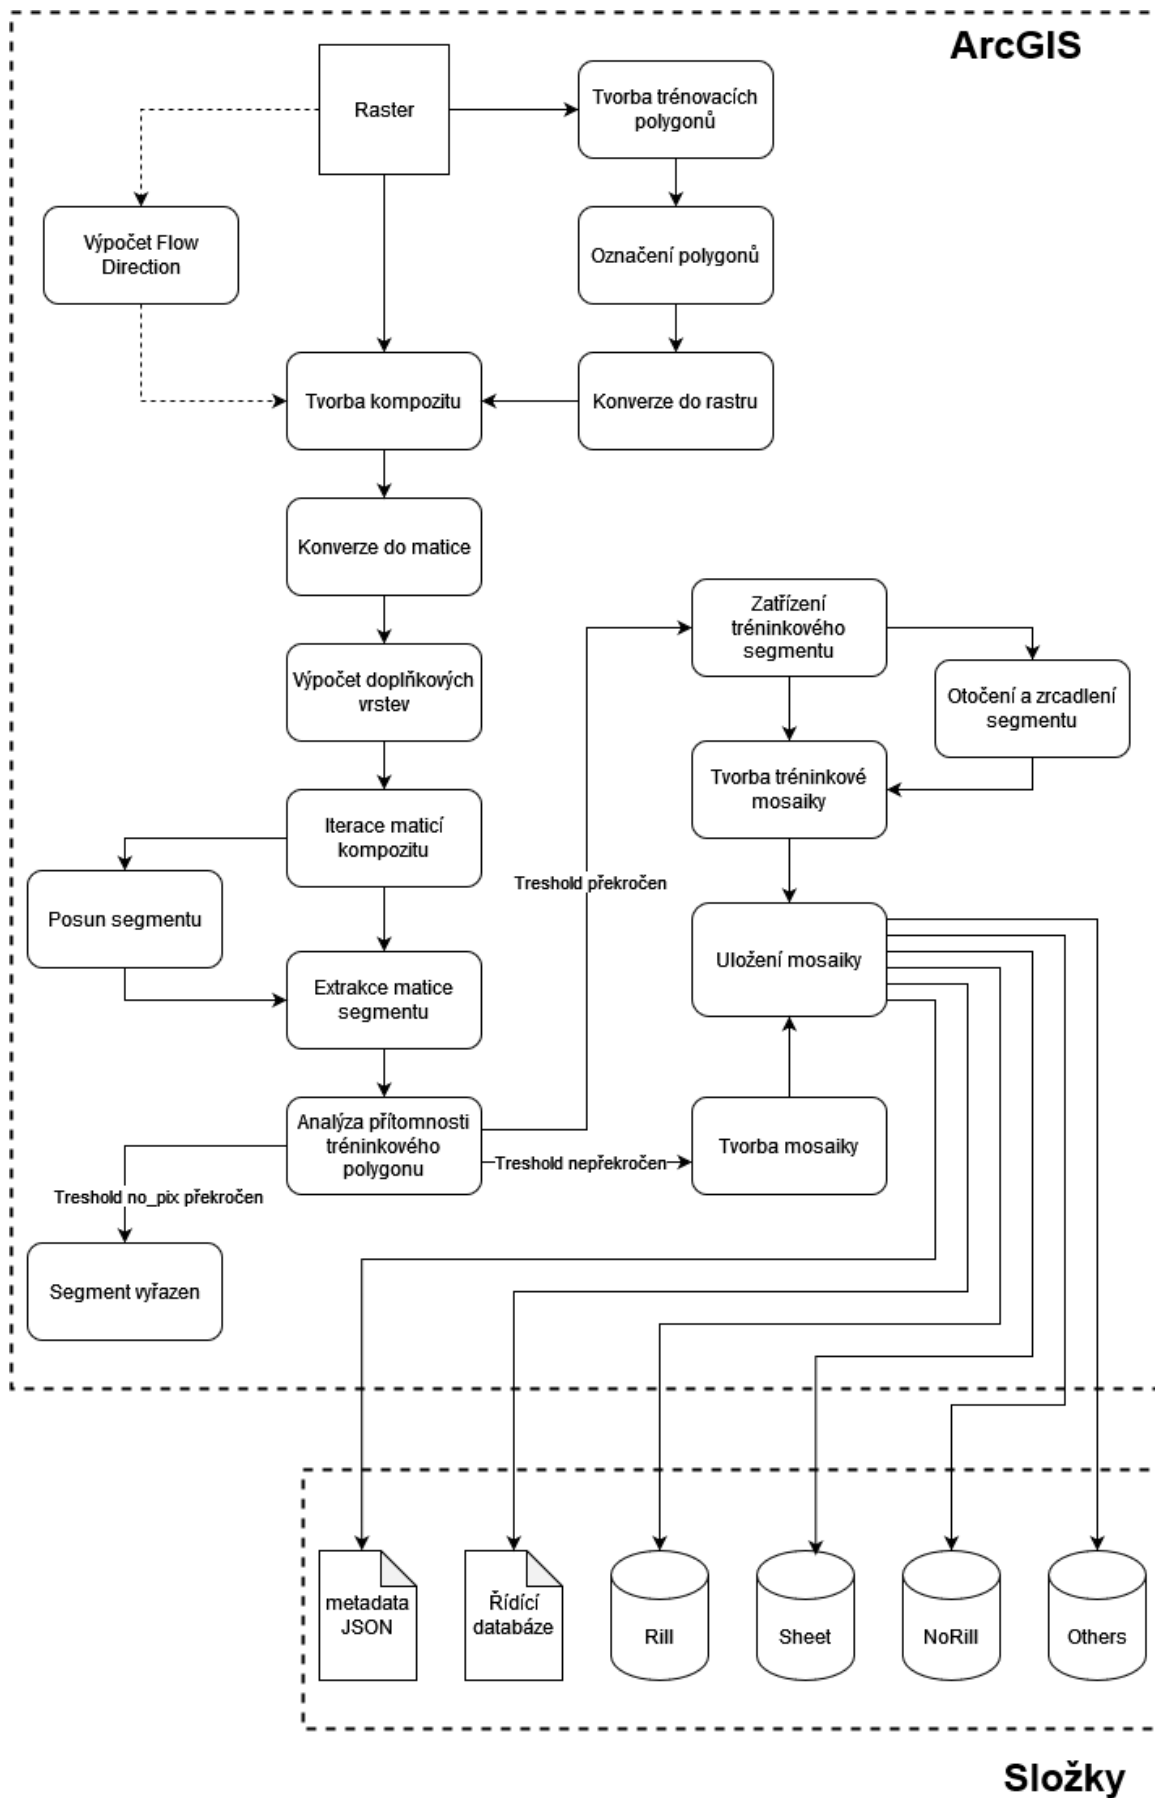
Tvorba polygonů je provedena pomocí nástroje *Create Feature*, do nové polygonové vrstvy. Pro urychlení práce byla vytvořena prázdná vrstva se zadanou symbologií s názvem *blank*, která byla kopírována a přejmenována pro každou analyzovanou scénu. To urychlilo práci tím, že bylo možné tvořit přímo jednotlivé kategorie, namísto tvoření polygonů a jejich následného pojmenovávání v atributové tabulce.

V případě satelitních dat byly tvořeny kalibrační linie v osách rýhového poškození, případně šrafa přes nepoškozenou či plošně poškozenou půdu. Tyto linie byly opatřeny informací o šířce a převedeny na polygony nástrojem *Buffer*, blíže je tento postup popsán v příslušných kapitolách.

Trénovací polygony byly vždy označovány tak, aby obsahovaly informaci, zda jsou určeny pro trénink nebo validaci. Tato informace byla obsažena v příslušném sloupci atributové tabulky.

Konverze do rastru

Vytvořené polygony jsou pomocí nástroje *Polygon to Raster* převedeny do rastrového formátu. Hodnoty rastru odpovídají hodnotám označení polygonů v atributové tabulce. Plocha bez trénovacích a validačních polygonů je v rastru prezentována hodnotou *no_data*.



Obr. 7 Schéma segmentace snímku

Tvorba kompozitu

Kompozit použitý pro segmentaci je složen zpravidla ze 4 vrstev. První vrstvou je vždy rastr obsahující trénovací polygony převedené do formy rastru. Další vrstvy jsou pásma R, G, B. Případně další pomocné vrstvy. Tvorba kompozitu je provedena nástrojem *Composite Bands*.

Segmentace kompozitu a export mozaik

Segmentační skript postupně rozdělil scénu na mozaiky skládající se z jednotlivých vrstev kompozitu. Zároveň segmentační skript v případě přítomnosti trénovacích polygonů v segmentu uložil trénovací mozaiky do příslušných složek. Segmenty ležící z větší části mimo scénu jsou vynechány. O tom, zda segment leží mimo scénu rozhoduje příslušný poměr. Segmenty neobsahující trénovací polygony jsou uloženy do složky pro vlastní klasifikaci. Zároveň je segmentačním skriptem vytvořena SQLite databáze (dříve CSV) sloužící k řízení klasifikace. Veškeré důležité informace o scéně, nutné pro chod modelu, či zpětný import do ArcGIS jsou uloženy do metadatového JSON souboru.

Segmentace scény začíná jejím převedením na matici pomocí nástroje *Rastr to Array*, hodnotám *no_data* je přiřazena hodnota 0. Pro matici jsou odečteny obecné vlastnosti nutné pro další používání dat, jako název listu, velikost matice, souřadnice levého spodního rohu matice nebo velikost pixelu. Matice může také být základem pro výpočet dodatečných vrstev, zpravidla se jednalo o převod na černobílé zobrazení. V některých případech byla provedena analýza hran Canny edge různého stupně.

Následně se touto maticí postupně prochází v krocích o velikosti hrany odpovídající velikosti hran jednotlivých segmentů. Pokud se v segmentu objeví trénovací polygony je segment označen příslušným znakem.

Prahové hodnoty pro příslušnost do jednotlivých tříd byly pro jednotlivé modely měněny tak, aby bylo možné studovat vliv této změny na úspěšnost klasifikace. Segmenty ležící mimo scénu nebyly exportovány, zbývající segmenty byly uloženy do mozaiky a exportovány do příslušných složek. Adresa uložené mozaiky byla uložena do DB souboru.

Výpočet doplňkových vrstev

Z doplňkových vrstev byla nejčastěji tvořena černobílá varianta scény. Ta byla nejen další složkou mozaiky, ale sloužila jako vstup pro výpočet Canny Edge Filteru. Černobílá vrstva byla vytvořena pomocí následující rovnice (PTC 2024):

$$\text{Grayscale} = (0,3 * \text{Red}) + (0,59 * \text{Green}) + (0,11 * \text{Blue})$$

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země


Canny Edge Filter je vícestupňový detektor hran. K výpočtu intenzity gradientů používá filtr založený na derivaci Gaussova rozdělení. Nakonec jsou okrajové pixely zachovány nebo odstraněny pomocí prahování hystereze o velikosti gradientu. Černobílá mozaika byla podrobena tomuto filtru se třemi variantami parametru σ , a to 1, 2 a 3.

Délka hrany segmentu

Délka hrany segmentu udává hodnotu v pixelech délky hrany segmentu. Tímto je určena plošná velikost segmentu a do značné míry prostorové rozlišení, a tedy přesnost klasifikace. Délka hrany segmentu je shodná pro všechny vrstvy kompozitu, ze kterých se bude mozaika segmentů skládat. Díky vzájemnému posunu segmentů, je však výsledná přesnost dvojnásobná.

Vzájemný posun segmentů

Pro zvýšení přesnosti modelu a navýšení množství dat byl skript doplněn o posun segmentačního okna o polovinu délky segmentu ve vodorovném směru, svislém směru a oběma směry zároveň. Vzniká tak čtyřikrát více mozaik, které mohou být zatřízeny, případně použity k trénování modelu, zároveň je umožněno zvýšit prostorové rozlišení výsledku.



Obr. 8 Mozaiky se vzájemným posunem segmentu

Uspořádání mozaiky

Uspořádání mozaiky určuje, jak bude výsledná mozaika segmentů složena. Jedná se o šířku a výšku výsledné mozaiky udané jako počet segmentů. Segmenty jednotlivých vrstev kompozitu jsou postupně řazeny vedle sebe z leva doprava, po dosažení nastavené šířky mozaiky je pokračováno dalším řádkem.

Blue	Green	Red	FlowDirection	Grayscale
------	-------	-----	---------------	-----------

Obr. 9 Uspořádání mozaiky

Poměry pro označení mozaiky

Poměry pro zatřídění segmentu určují, do jaké skupiny budou přiřazeny vytvářené mozaiky. Tato hodnota může být vyjádřena i procenty. S klesající hodnotou thresholdu stačí pro označení mozaiky menší množství pixelů v segmentu označených příslušnou kategorií. Toto je rozhodující

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země

v případě úzkých rýh a větších délek hrany mozaiky kdy by byly úzké rýhy vynechány, protože tvoří pouze malou část plochy segmentu.

Poměr `noPix_threshold_ratio` určuje kolik procent segmentu musí být tvořeno hodnotou rastru `no_data` aby byl segment a tedy výsledná mozaika vyřazeny z analýzy. Tato hodnota byla standardně nastavena na 80 %. Segmenty ležící mimo scénu nebyly exportovány.

Poměr `Rill_threshold_ratio` určuje kolik procent segmentu musí být tvořeno hodnotou rastru `rýha`, aby byl segment, a tedy i výsledná mozaika zařazeny do trénovacího datasetu `rýh`. Tato hodnota byla standardně zvolena 25 %, ale může být i 1 %.

Poměr `Sheet_threshold_ratio` určuje kolik procent segmentu musí být tvořeno hodnotou rastru `plošná eroze`, aby byl segment, a tedy i výsledná mozaika zařazeny do trénovacího datasetu `plošného poškození`. Tato hodnota byla standardně zvolena 25 %.

Poměr `NoRill_threshold_ratio` určuje kolik procent segmentu musí být tvořeno hodnotou rastru `bez poškození`, aby byl segment, a tedy i výsledná mozaika zařazeny do trénovacího datasetu `povrchu bez poškození`. Tato hodnota byla standardně zvolena 25 %.

Formát, ve kterém byly mozaiky uloženy, byl zvolen JPG. Název exportované mozaiky je složen z předpony `Mosaic`, názvu lokality, X souřadnice segmentu, Y souřadnice segmentu, typu trénovacího polygonu, který obsahuje a typu posunu, vše odděleno podtržítka.

Otočení a zrcadlení segmentu

Další možností zvýšení počtu trénovacích mozaik je otáčení a zrcadlení segmentu. Celkem byly zvoleny tři možnosti pootočení, o 90°, 180° a 270°. Zrcadlení bylo zvoleno ze základního snímku podle svislé a vodorovné osy snímku. Celkem tak vzniká 5 dalších variant snímku. Otočení a zrcadlení segmentu lze kombinovat s posunutím segmentu. Otočení a zrcadlení segmentu je provedeno pro každou vrstvu kompozitu zvlášť a výstupní mozaika je složena až následně. Pořadí segmentů v mozaice tak není ovlivněno. Otočení a zrcadlení bylo použito pouze pro segmenty obsahující rýhové poškození, těchto segmentů bylo zpravidla nejméně. Trénovací dataset mozaik obsahujících rýhu tak byl navýšen zhruba šestkrát.

Místo uložení segmentu

Mozaiky jsou dle svého označení ukládány do příslušných složek. Mozaiky označeny jako `rýha` jsou uloženy do složky `Rill`. Mozaiky označeny jako `plošná eroze` jsou uloženy do složky `Sheet` a mozaiky označeny jako `bez poškození` jsou ukládány do složky `NoRill`. Ostatní exportované mozaiky jsou ukládány

do složky Others. V případě přeplnění této složky je vytvořena další vzestupně číslovaná složka. Mozaiky ze složek Rill, Sheet a NoRill jsou následně použity pro trénink modelu.

Validační mozaiky jsou ukládány do složky Others.

Řídící databáze

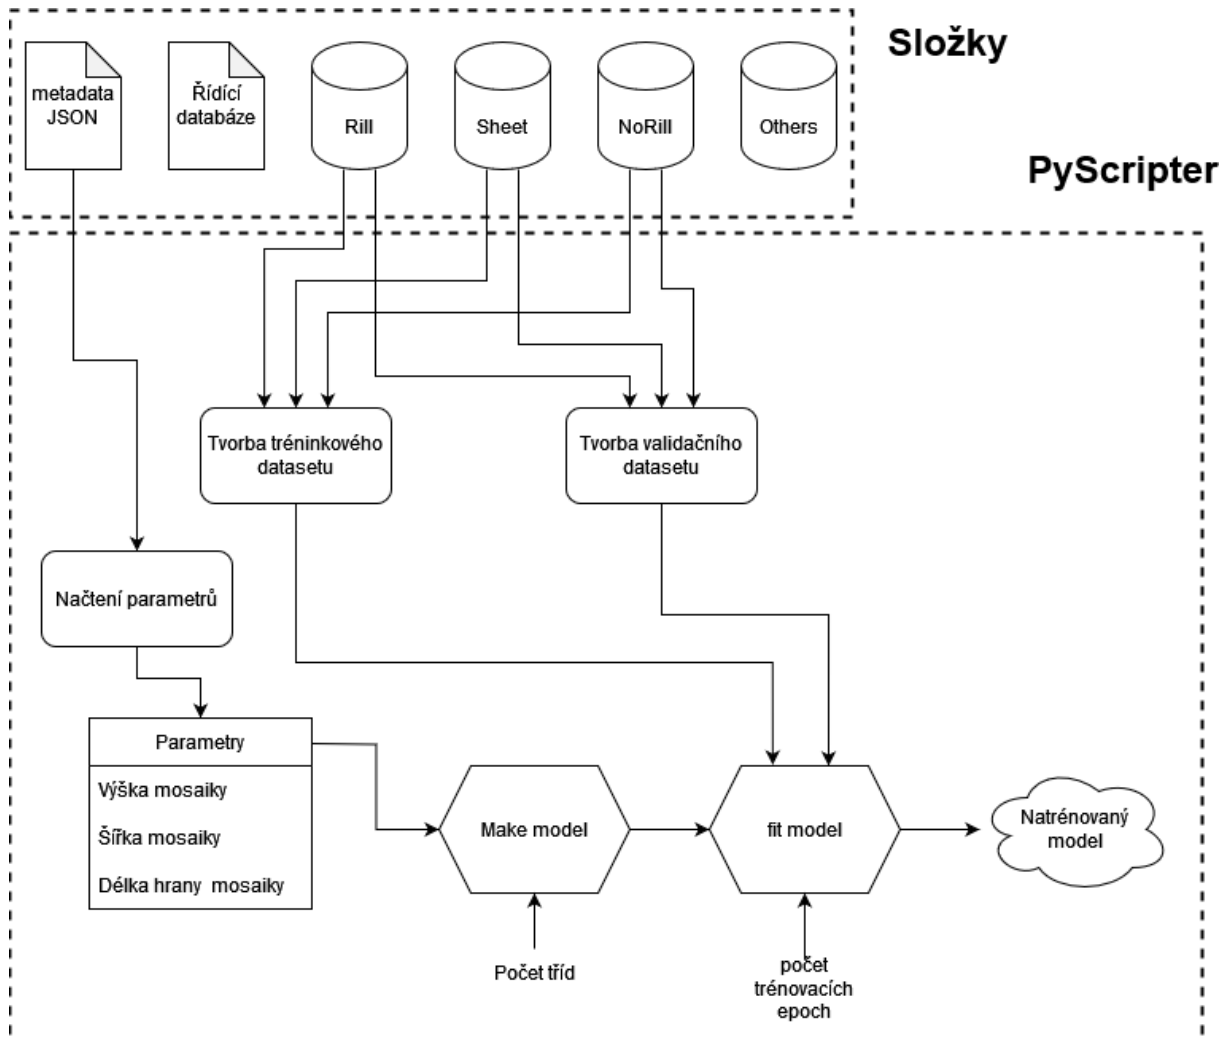
Veškerá data důležitá pro běh klasifikačního modelu byla původně ukládána do CSV souboru s příponou `_log`. V záhlaví souboru byla uložena metadata příslušného listu. Název listu, délka hrany pixelu v m, souřadnice levého spodního rohu rastru, délka hrany segmentu v pixelech, počet vrstev rastru a rozměry rastru, typ vzájemného posunu segmentů. Toto řešení se brzy ukázalo jako nedostatečné. CSV soubor byl sice jednoduchý na otevření a manuální prohlížení dat, nicméně strojové zpracování, zápis výsledků do správného sloupce a opětovné spuštění v případě pádu běžící klasifikace bylo obtížné. Ukládání do CSV souboru bylo tedy nahrazeno SQLite databází v souboru DB. Používání databáze umožnilo bezproblémové opětovné spuštění modelu po jeho pádu, práci dvou modelů na jedné scéně zároveň a rychlé třídění dat na data ke klasifikaci a trénovací data.

Řádky databáze nesou následující hodnoty. Úplnou adresu uložené mozaiky, název mozaiky, souřadnice X mozaiky jako krok o velikosti segmentu, souřadnice Y mozaiky jako krok o velikosti segmentu, hodnotu kategorie obsahuje-li mozaika tréninkový polygon, a příslušný počet sloupců s hodnotou 0 pro umístění výsledných hodnot klasifikace.

Poslední sloupec databáze je sloupec Done. Ten slouží k odlišení klasifikovaných a neklasifikovaných mozaik. Tento sloupec umožňuje kdykoliv zastavit klasifikaci a opět ji spustit, případně opět spustit klasifikaci po pádu klasifikačního skriptu.

5.3 Trénink modelu

Trénink modelu byl proveden v samostatném skriptu. Tento skript nejprve specifikuje parametry trénovacího a validačního datasetu modelu. V následujícím textu jsou popsány hlavní parametry skriptu, kurzívou jsou psány přesná znění kódu. Schéma skriptu je na Obr. 10.



Obr. 10 Schéma tréninkového skriptu modelu

Tvorba tréninkového a validačního datasetu je zajištěna funkcí `Train_ds`, `val_ds = tf.keras.preprocessing.image_dataset_from_directory`. Tento nástroj vytvoří z mozaik datasety se kterými může model následně pracovat. Nástroj pro svoji práci potřebuje specifikovat vlastnosti a požadavky na vstupní data.

`mosaics_folder` je název složky ve které se nacházejí složky s jednotlivými třídami mozaik určenými k trénování modelu.

`validation_split` určuje poměr jaké množství trénovacích dat bude použito k interní validaci modelu. Standardně byl validační poměr volen 0.2, tedy 20%.

`subset` určuje jaká matice je vytvářena. `Training` je matice pro trénink modelu a `validation` je matice pro validaci modelu.

`Seed` určuje číslo použité pro generování náhodných hodnot modelu. Použití stejného čísla umožňuje dosažení stejných, a tedy vzájemně porovnatelných výsledků modelu.

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země

image_size určuje délku hrany mozaiky jako počet pixelů. Tato hodnota je načítána z metadatového souboru. Všechny mozaiky musí mít jednotnou velikost.

batch_size určuje velikost dávky, která se použije pro natrénování neuronové sítě. Model při svém tréninku vždy vezme první dávku vzorků z trénovací datové sady a pomocí ní natrénuje síť. Dále odebere další dávku vzorků a znovu natrénuje síť. V tomto postupu pokračuje, dokud nezpracuje všechny trénovací data. Malé dávky vyžadují méně paměti. Vzhledem k tomu, že trénujeme síť pomocí menšího počtu vzorků, vyžaduje celkový tréninkový postup méně paměti. To je zvláště důležité, pokud nejsme schopni umístit celý soubor dat do paměti počítače.

Neuronové sítě jsou tvořeny uzly a vazbami mezi nimi. Jednotlivé uzly představují výsledky či mezivýsledky a vazby představují sílu jejich vzájemného spojení udanou jejich vahou. Síť se obvykle trénuje rychleji s malými dávkami dat. Je to proto, že se provádí aktualizace vah jednotlivých vazeb mezi uzly po každé iteraci. Pokud bychom během iterace použili všechny vzorky, provedli bychom pouze 1 aktualizaci parametrů sítě. Čím menší je dávka, tím méně přesný bude odhad daného kroku.

Labels určuje, jak jsou specifikovány názvy jednotlivých kategorií modelu. Byla použita možnost *inferred*, tedy názvy tříd jsou specifikovány názvy složek, jenž obsahují trénovací data.

label_mode popisuje, jak jsou názvy tříd zadány. Pro použití více než 2 tříd nelze použít možnost *Binary*, je tedy použita možnost *Categorical*, ta umožňuje specifikovat téměř neomezené množství tříd.

class_names obsahuje seznam názvů tříd. Pořadí tříd v tomto seznamu určuje pořadí, v jakém bude uvedeno výsledné skóre pravděpodobností později klasifikovaných tříd. Toto pořadí tedy bylo následující Rill (rýhové poškození), NoRill (povrch bez rýh) a Sheet (plošné poškození).

color_mode určuje jaký typ dat mozaiky obsahují. Byla použita buď možnost *grayscale*, nebo možnost *rgb*. Mozaiky tedy mají pouze jedno pásmo, nebo tři barevná pásma.

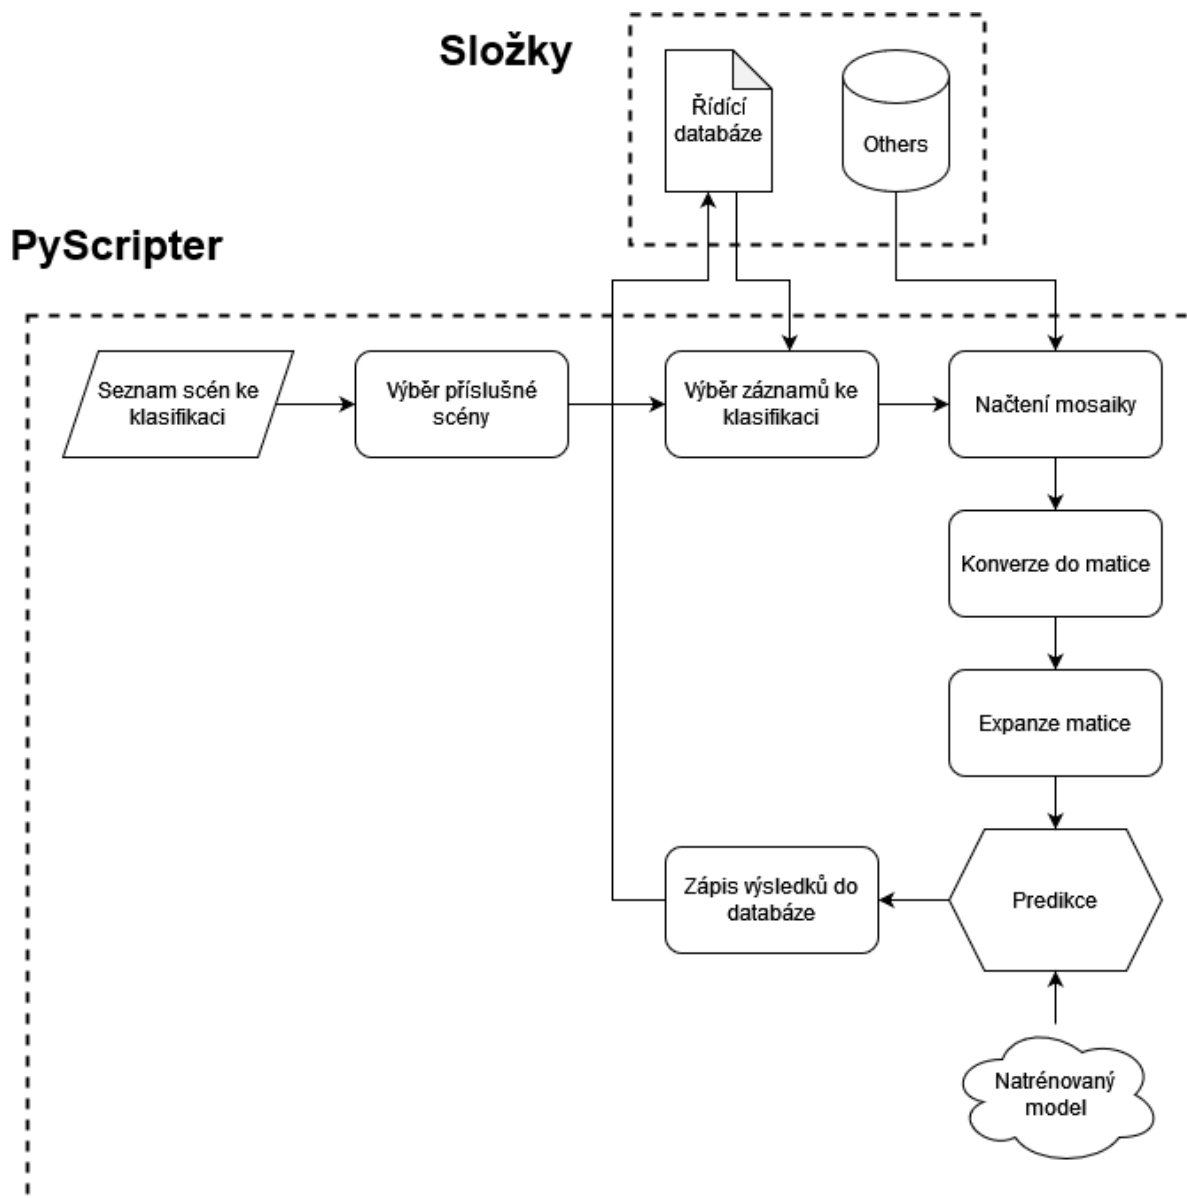
make_model (input_shape = image_size + (1,), num_classes = 3) funkce vytvářející model. *input_shape = image_size + (1,)* jedná se o parametr modelu, který udává rozměr vstupních mozaik jako vícevrstevných matic. Model je schopný pracovat s maticemi o více vrstvách, do modelu však vstupovaly pouze snímky s jednou vrstvou. Proto byl parametr doplněn o 1. *num_classes=3* označuje počet tříd modelu, tento parametr musí být shodný s počtem *class_names*.

epochs určuje počet trénovacích epoch, počáteční experimenty používaly 50 epoch, později byl počet epoch snížen na 30 a tak značně urychlen trénink modelu. Čas potřebný na průběh jedné epochy se pohyboval od 30 minut do 4 hodin i více.

Zkonstruovaný model byl následně trénován stanovený počet epoch pomocí funkce *model.fit*. Tato funkce má jako jeden z parametrů *callback*. Jedná se o adresu, kam se mají ukládat zálohy modelu po každé epoše. Trénink modelů standardně trval od 24 h do 7 dnů, během této doby mohlo dojít k pádu modelu, či počítače. *Callback* umožňoval pokračovat v tréninku od poslední dokončené epochy.

Natrénovaný model byl uložen pro další použití při vlastní klasifikaci dat pomocí funkce *model.save(main_folder)*. Parametr *main_folder* určoval adresu kam bude model uložen.

5.4 Klasifikace dat



Obr. 11 Schéma klasifikačního skriptu modelu

Klasifikace dat začíná načtením řídicí databáze obsahující adresy mozaiky ke klasifikaci (viz Obr. 11). Skript následně postupně prochází touto databází, načítá jednotlivé mozaiky, klasifikuje je a výsledky

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země

ukládá zpět do databáze, do příslušných sloupců. Adresa mozaiky je uložena do proměnné *mosaic_path*. Mozaika na příslušné adrese je načtena a předzpracována funkcí *tf.keras.preprocessing.image.load_img (mosaic_path, color_mode='grayscale')*. Parametr *color_mode* určuje barevné schéma načítaných snímků.

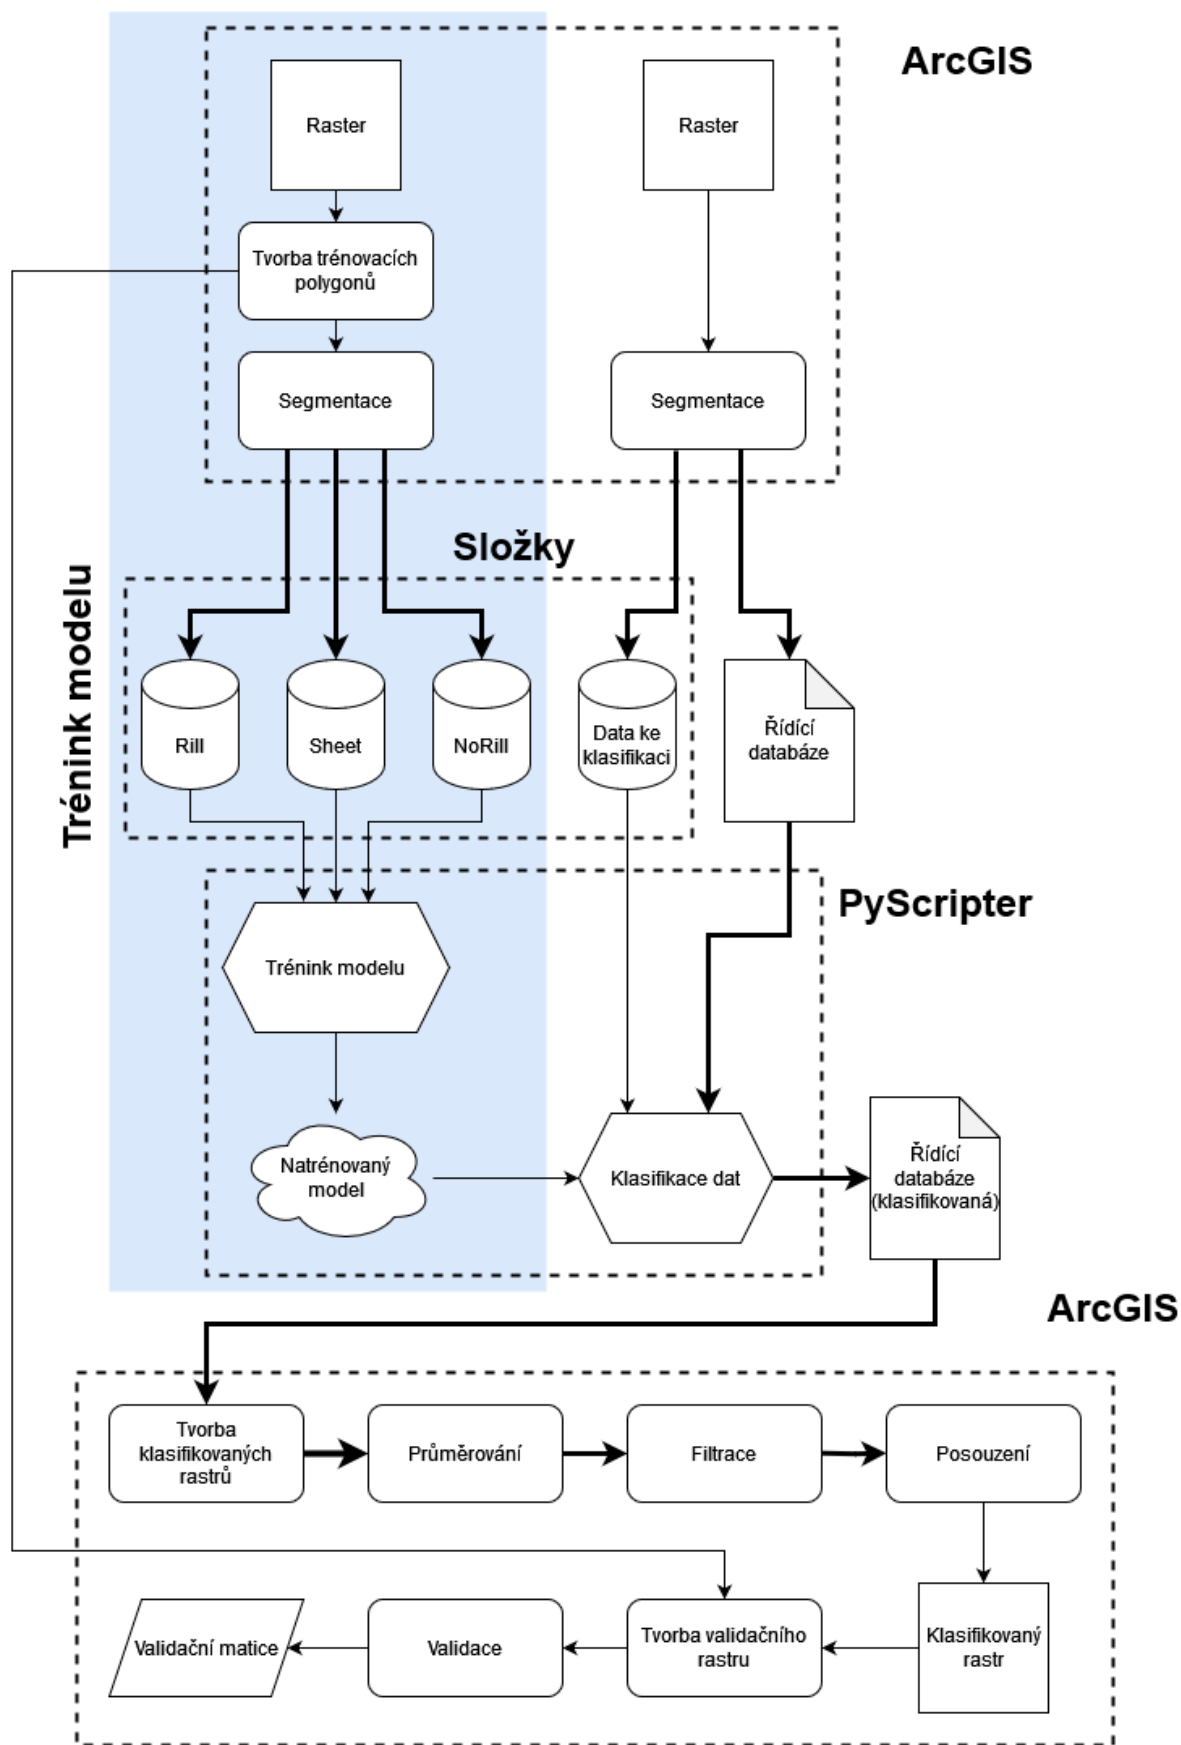
Následuje převod mozaiky na matici pomocí funkce *tf.keras.preprocessing.image.img_to_array(img)*.

Následuje expanze matice pomocí funkce *tf.expand_dims(img_array, 0)*.

Vlastní predikce probíhá pomocí funkce *model.predict(img_array)*. Tato funkce přebírá expandovanou matici posuzuje jí uloženým natrénovaným modelem a vytvoří hodnoty pravděpodobností příslušnosti mozaiky k jednotlivým klasifikovaným třídám. Tyto hodnoty jsou uloženy ve formě Python listu. Následně je tak velmi jednoduché tyto hodnoty vyjmout a uložit do databáze.

Tento cyklus je opakován pro každý snímek v řídicí databázi. Kromě tohoto hlavního cyklu byl klasifikační skript doplněn o pomocné procesy, jako zápis pomocných hodnot pro tréninkové neklasifikované mozaiky nebo vypisování procenta dokončenosti klasifikace databáze.

5.5 Kompletní model



Obr. 12 Schéma kompletního segmentačního modelu

Tvorba klasifikovaných rastrů

K importu výsledku klasifikace zpět do ArcGIS a tvorbě klasifikovaných rastrů slouží importovací skript. Tento skript načte metadatový soubor a získá z něj délku hrany segmentu, typ vzájemného posunu segmentu, rozměr původního rastru, souřadnici levého spodního rohu rastru a velikost pixelu.

Prvním krokem importu je vytvoření prázdného rastru s hodnotami 0 o rozměrech stejných jako původní rastr. Následně skript postupně prochází jednotlivé řádky databáze a načítá hodnoty příslušného sloupce výsledků a souřadnice segmentu. Výsledná hodnota je pak implantována na příslušnou pozici v rastru určenou načtenými souřadnicemi. Výsledná hodnota je přiřazena celé skupině pixelů odpovídající délce hrany segmentu. V případě vzájemného posunu segmentů je upraven počáteční bod každého řádku či sloupce.

Výsledný rastr je uložen. Vzhledem k následnému průměrování posunutých rastrů, je standardně uložení prováděno pouze do dočasné paměti. Po provedení průměrování jsou vytvořené rastry smazány a pouze zprůměrovaný rastr je uložen.

Průměrování

Pro importované rastry je pomocí nástroje *Raster Calculator* vypočítána průměrná hodnota, tato hodnota je uložena v novém rastru, zároveň je tento rastr převzorkován, je tedy provedena změna velikost pixelu. Nová velikost pixelu odpovídá poloviční délce segmentu. Tímto je získáno dvojnásobné rozlišení výsledného rastru.

Filtrace

Volitelným krokem analýzy může být filtrace. Filtrace je provedena pomocí Python skriptu. Tento skript nejprve vytvoří nový rastr s hodnotou 0. Následně je filtrovaný průměrovaný rastr procházen pixel po pixelu a analyzovány pixely nebo jejich bezprostřední okolí (okno 3x3 pixelů). Pokud je splněna podmínka pro uvažování pixelu jako platného pixelu, je do nového rastru zapsána hodnota 1.

Prvním krokem filtrace je vynulování pixelů s hodnotou menší než 0,5. Dále byly izolované pixely vynulovány. Pokud měl pixel hodnotu větší než 0,5 a zároveň byl v sousedství pixelu s hodnotou větší než 0,5, byla do výsledného rastru zapsána hodnota 1. Pro pixely s hodnotou větší než 0,75 a jejich bezprostřední okolí byla výsledná rastrová hodnota 1 zapsána do filtrovaného rastru.

Posouzení

Závěrečný krok je rozhodnutí, jaká kategorie bude pixelu bezešvého rastru finálně přiřazena. Prozatím se stále pracuje se zvláštním rastrem pro každou kategorii, ideálním výsledkem je ovšem bezešvý rastr

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země

pouze s jednotlivými kategoriemi. Tyto kategorie jsou označeny 0 – povrch bez rýhy, 1 – plošné poškození, 2 – rýhové poškození.

K rozhodnutí tak slouží jednoduchý rozhodovací strom, preferující plochu bez rýh, následuje plošná eroze a nejnižší prioritu má plocha s rýhovým poškozením.

Tvorba validačního rastru

Validační rastr je kompozitem klasifikovaného rastru a původního rastru validačních polygonů. Původní rastr validačních polygonů je použit jako 1. pásmo a klasifikovaný rastr je 2. pásmo. Rastr je převzorkován na rozměry pixelu odpovídající validačnímu rastru.

Validace

Účelem validačního skriptu je vytvořit validační matici. Tato matice podává jasný přehled úspěšnosti modelu. Validační matice zobrazuje, do jakých skupin byli zatříděny pixely tvořící validační polygony (viz Obr. 12). Validační matice je pro přehlednost převedena na procentuální vyjádření pro jednotlivé kategorie. Ideálním výsledkem validační matice jsou hodnoty 100 na diagonále matice. V takovém případě 100 % validačních pixelů každé kategorie bylo zatříděno jako příslušná kategorie. Tohoto výsledku je zřídka dosahováno. Validační matice tak zároveň poskytuje informace o tom, mezi kterými skupinami dochází k nejvyšší chybovosti analýzy.

Na příkladu průměrné validační matice scén z bezpilotních prostředků (Obr. 13), lze vidět, že 78 % validačních pixelů plochy bez poškození je zatříděno jako plocha bez poškození, 6 % validačních pixelů je zatříděno jako plocha s plošným poškozením a 17 % validačních pixelů plochy bez poškození je zatříděno jako plocha s rýhovým poškozením. Pro třídu plošné poškození je 56 % validačních pixelů zatříděno jako plocha bez poškození, 29 % je správně zatříděno jako plošné poškození a 15 % je zatříděno jako rýhové poškození. Pro třídu Rýhové poškození, je 60 % validačních pixelů zatříděno jako plocha bez poškození, 11 % jako plocha s plošným poškozením a 29 % je správně zatříděno jako plocha s rýhovým poškozením.

		Validace		
		Bez poškození	Plošné poškození	Rýhové poškození
Klasifikace	Bez poškození	78	56	60
	Plošné poškození	6	29	11
	Rýhové poškození	17	15	29

		Validace		
		Bez poškození	Plošné poškození	Rýhové poškození
Klasifikace	Bez poškození	100	0	0
	Plošné poškození	0	100	0
	Rýhové poškození	0	0	100

Obr. 13: Ukázka validační matice. Reálný výsledek pro scéný z bezpilotních prostředků – nalevo, ideální výsledek validační matice – napravo.

Validační skript postupně prochází celý kompozitní rastr a posuzuje hodnotu validačního a klasifikačního rastru. Základem skriptu je rozhodovací strom, který posuzuje jednotlivé varianty vzájemných vztahů těchto hodnot. Zároveň je vytvářena suma pixelů jednotlivých validačních tříd. Následuje přepočítání validační matice na procentuální hodnoty. Posledním krokem skriptu je vrácení vytvořené validační matice ve formě listu. To umožňuje provést skript automaticky pro několik scén a všechny výsledky uložit ve formě tabulky pro další zpracování.

5.6 Dostupnost modelu

Model je kompletně dostupný na serveru GitHub skrze následující odkaz:

https://github.com/adamtejkl/disertation_thesis_model

6 Experimentální aplikace – detekce erozního poškození

Motivace k provádění monitoringu erozních ploch je shrnuta v kapitole 1. Jak jsou jednotlivé druhy monitoringu prováděny a jaké poskytují výsledky shrnuje kapitola 2.2.

Experimentální aplikace byla provedena na třech datových sadách, s různým původem a prostorovým rozlišením. Jedná se o satelitní scény s prostorovým rozlišením 3 m/pixel, ortofoto snímky z bezpilotních prostředků s prostorovým rozlišením 20 – 30 cm/pixel a snímky vytvořené metodou SfM s prostorovým rozlišením 1 cm/pixel. Experimentální aplikace jsou uvedeny v pořadí dle zvyšujícího se prostorového rozlišení. Z důvodu časového překryvu zpracování jednotlivých experimentálních aplikací není řazení chronologické (viz Obr. 1).

6.1 Satelitní snímky PlanetScope

V rámci společné činnosti řešitelského týmu VÚMOP (Žížala, Minařík) a ČVUT byly podrobeny analýze využitelnosti při monitoringu erozních událostí a škod způsobených přívalovými srážkami data z cubesatelitů PlanetScope společnosti Planet. Tato aktivita pokračovala z roku 2020 a byla rozšířena o kvantitativní zhodnocení z velkého souboru dat. Přístup k datům byl získán prostřednictvím programu ESA Third Party Missions PLANET. V rámci aplikace krátkodobého projektu na základě tohoto programu bylo možné získat přístup k datům Planet o celkové kumulativní rozloze všech snímků 20 000 km². Analýza byla zaměřena na možnosti identifikace projevů eroze přímo ze snímků. K verifikaci projevů bylo použito několik datových sad. (Krása 2021)


Data Planet mají prostorové rozlišení 3 m/pixel a zahrnují 4 spektrální pásma (3 viditelná a 1 blízké infračervené). Časové rozlišení je téměř 1 den. Z archivu dat Planet byly staženy vždy minimálně 3 bezoblačné snímky korespondující s obdobím těsně před událostí, těsně po události a v delší době po události (30-180) s ohledem na analýzu projevů na vzrostlé vegetaci. (Krása 2021)

Následující tabulka uvádí data a lokality pro které byly snímky pořízeny

Třebešice	Netvořice	Libčice	Litultovice	Božetín	Hradce	Dobříš	Nečín
1.4.2019	4.9.2019	31.8.2019	22.9.2019	8.8.2020	4.9.2019	5.9.2019	4.9.2019
20.3.2019	1.9.2019		11.8.2019	1.8.2020	1.9.2019		31.8.2019
6.3.2019							
28.9.2018							
21.9.2018							
15.8.2017							
14.8.2017							
10.8.2017							

Tab. 2 Přehled dostupných satelitních scén pro zájmové lokality

Rozsah scén je od 3 × 1 km u scén lokality Litultovice po 9 × 6 km u scén lokality Libčice. Celkem bylo vyhodnoceno 20 scén. Velikost hrany segmentu byla volena 48 a 30 m, tedy 16 a 10 pixelů původní scény s velikostí pixelu 3 m. Ukázka scény a její vyhodnocení je na Obr. 14.

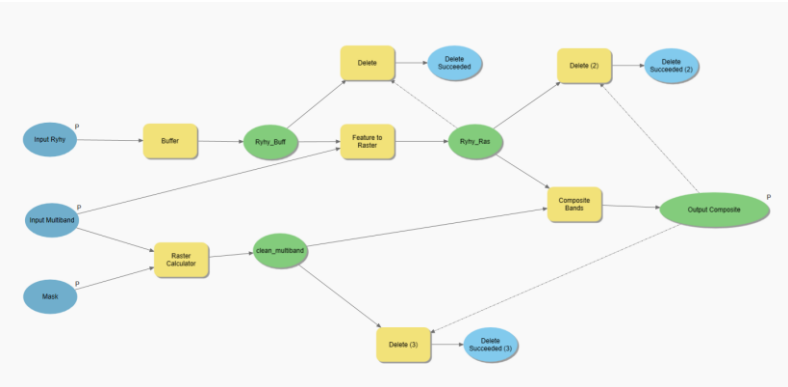



Obr. 14 Scéna Litultovice 22.9.2019 s vyznačenými trénovacími pásy povrchu bez rýh (červené zig-zag linie) a poškozeným povrchem (zelená, žlutá, oranžová). Na světlém půdním bloku ve spodní části snímku je viditelné erozní poškození neoznačeno, to je následně použito pro manuální validaci zatříděného snímku (vlevo). Zatříděná scéna Litultovice 22.9.2019. Trénovací oblasti nejsou zatříděny a jsou zcela průhledné, oblast zatříděná jako nepoškozená v odstínech zelené, oblast zatříděná jako poškozená v odstínech červené. Na půdním bloku ve spodní části snímku je vidět částečný zásah erozního poškození modelem (vpravo).

6.1.1 Postup

<p>Manuální tvorba trénovacích linií</p>	<p>Na scénách byly manuálně vytvořeny linie v osách vizuálně interpretovaného erozního poškození, k těmto liniím byla v atributové tabulce přiřazena hodnota šířky erozně poškozené plochy. Vizuální zatřídění se odvíjelo od hledání charakteristických projevů erozního poškození na snímcích vzdáleného průzkumu. Významná světlejší barva oblastí, charakteristická stromová struktura rýhového erozního poškození, depoziční kužel atd. Nejčastěji byla nalézána rýhová eroze projevující se světlou stromovou strukturou na tmavém podkladu, nebo tmavé depoziční projevy na světlém podkladu. Zároveň byly vytvořeny linie nad povrchem, který byl vizuálně interpretován jako nepoškozený. Těmto liniím je také přiřazena šířka, vzhledem k potřebě zasáhnout touto linií co největší</p>
---	---

	<p>plochu vzniká charakteristický zig zag linie (viz Obr. 14). Rastr takto vzniklých pásů pak sloužil pro označení vytvořených mozaik na trénovací a validační. Záměrně nebyla označena všechna nalezená poškození, neoznačené poškození bylo využito pro manuální validaci zatřízených snímků. Jsou vytvářeny pouze dvě trénovací kategorie. Rýhová eroze a nepoškozená plocha. Označení bylo později použito pro generování kódu označujícího, o jaká trénovací data se jedná.</p> <p>Kalibrační polygony rýhového poškození mají hodnotu mezi 1 až 98, plocha bez poškození je označena hodnotou 99. Pro urychlení postupu byl vytvořen Python skript, který na základě označení rýhy automaticky doplní hodnotu a dále defaultní šířku bufferu není-li šířka bufferu již doplněna. U linií bez poškození byla zvolena defaultní šířka bufferu 10 m, u linií rýhového poškození 3 m.</p>
<p>Tvorba polygonů</p>	<p>Polygony jsou tvořeny z trénovacích linií. Pomocí nástroje <i>Buffer</i> a sloupce definujícího šířku bufferu je linie převedena na polygon. Linie bez poškození s defaultní šířkou bufferu 10 m jsou tedy převedeny na 20 m široký polygon, linie rýhového poškození s šířkou 3 m, jsou převedeny na 6 m široký polygon. Zakončení polygonů bylo zvoleno <i>round</i>, tedy kruh s poloměrem rovným šířce bufferu.</p>
<p>Konverze do rastru</p>	<p>Vytvořené polygony jsou pomocí nástroje <i>Polygon to Raster</i> převedeny do rastrového formátu (Obr. 15). Hodnoty rastru odpovídají hodnotám označení polygonů. Plocha bez trénovacích a validačních polygonů je v rastru prezentována hodnotou <i>no_data</i>.</p> <div data-bbox="678 1413 1241 1886" data-label="Image"> </div> <p>Obr. 15 Linie a rastry rýh</p>

<p>Tvorba kompozitu</p>	<p>Kompozit použitý pro segmentaci je složen ze 4 vrstev. První vrstvou je rastr obsahující trénovací polygony převedené do formy rastru. Další vrstvy jsou pásma R, G, B. Byly hledány pouze erozní projevy na zemědělsky obdělávané půdě. Při tvorbě kompozitu tak bylo přikročeno k oříznutí snímků maskou polygonů LPIS. Postup se skládal z řady po sobě jdoucích kroků, tento postup pak bylo nutné opakovat pro každou scénu. Pro urychlení postupu tak bylo přikročeno k vytvoření ArcGIS modelu, jenž proces automatizoval (Obr. 16).</p> <p>Model se skládal z několika paralelních kroků. Prvním krokem je tvorba polygonů, následováno převedením polygonů do rastru. Zároveň byly scény očištěny maskou LPIS polygonů pomocí nástroje <i>Raster Calculator</i>. Takto vzniklé rastrové vrstvy byly následně sloučeny a vznikl finální kompozit. Model dále provedl smazání všech pracovních vrstev. Velikost pixelu vytvářeného rastru trénovacích polygonů byla odvozena od velikosti pixelu vstupní scény.</p>  <p>Obr. 16 Schéma kompozitního modelu</p>
<p>Segmentace kompozitu a export snímků</p>	<p>Segmentace scén probíhala s výstupem do CSV souboru jako řídicí databáze a TXT souborem pro uložení metadat.</p>
<p>Výpočet doplňkových vrstev</p>	<p>První model byl spuštěn pouze na originálních dostupných datech. Dále bylo přikročeno k vytvoření dalších vrstev rozšiřujících datové vstupy modelu. Nejprve byla vytvořena černobílá varianta segmentu z R, G a B vrstvy.</p> <p>Černobílá mozaika byla také podrobena Canny Edge Filtru se třemi variantami parametru σ, a to 1, 2 a 3.</p>
<p>Délka hrany segmentu</p>	<p>Zvolená délka hrany segmentu byla 16 a 10 pixelů, což odpovídá 48 a 30 m. Tato velikost byla zvolena z důvodu požadované přesnosti</p>

	výsledků. Díky vzájemnému posunu segmentů, je však výsledná přesnost dvojnásobná.								
Vzájemný posun segmentů	Byl proveden vzájemný posun segmentačního okna o polovinu délky segmentu ve vodorovném směru a svislém směru. Vzniklo tak dvakrát více mozaik, které mohou být zatříženy, případně použity k trénování modelu, zároveň je umožněno zvýšit prostorové rozlišení výsledku.								
Uspořádání mozaiky	<p>Byly vytvořeny mozaiky skládající se ze 4 až 8 vrstev v pořadí Blue, Green, Red, NIR, Grayscale, Canny 1, Canny 2, Canny 3. Výsledné mozaiky byly voleny s rozložením 4 snímky na šířku a 2 snímky na výšku.</p> <table border="1" data-bbox="571 712 1390 875"> <tr> <td>Blue</td> <td>Green</td> <td>Red</td> <td>Near Infra Red</td> </tr> <tr> <td>Grayscale</td> <td>Canny Edge 1</td> <td>Canny Edge 2</td> <td>Canny Edge 3</td> </tr> </table> <p><i>Obr. 17 Schéma uspořádání mozaiky modelů</i></p>  <p><i>Obr. 18 Uspořádání mozaik jednotlivých modelů, shora Model_001, Model_002 a Model_003</i></p>	Blue	Green	Red	Near Infra Red	Grayscale	Canny Edge 1	Canny Edge 2	Canny Edge 3
Blue	Green	Red	Near Infra Red						
Grayscale	Canny Edge 1	Canny Edge 2	Canny Edge 3						
Poměry pro označení mozaiky	Poměr noPix_threshold_ratio byl nastavena na 90 %. Prahové hodnoty pro příslušnost do jednotlivých tříd byly zvoleny 25 %. zbývající segmenty byly uloženy do mozaiky a exportovány do příslušných složek.								
Otočení a zrcadlení segmentu	Byly provedeny všechny uvažované možnosti otočení a zrcadlení segmentu, nicméně pouze pro kategorii rýhové poškození.								
CSV soubor	Veškerá data důležitá pro běh klasifikačního modelu byla ukládána do CSV souboru s příponou _log. V záhlaví souboru byla uložena metadata příslušného listu. Název listu, délka hrany pixelu v m, souřadnice levého spodního rohu rastru, délka hrany segmentu								

	<p>v pixelech, počet vrstev rastru a rozměry rastru, typ vzájemného posunu segmentů. Toto řešení bylo jednoduché a CSV soubor bylo možné otevřít a vizuálně zkontrolovat jeho obsah.</p> <p>Řádky CSV nesly následující hodnoty. Úplnou adresu uložené mozaiky, název mozaiky, souřadnice x mozaiky jako krok o velikosti segmentu, souřadnice y mozaiky jako krok o velikosti segmentu, hodnotu kategorie, obsahuje-li mozaika tréninkový polygon, a příslušný počet sloupců s hodnotou 0 pro umístění výsledných hodnot klasifikace.</p>
Model	<p>Původní model byl pouze minimálně modifikován a natrénován na příslušných tréninkových datech. Tréninkový datový soubor je načten do modelu a rozdělen na kalibrační a validační část pro účely kalibrace modelu. Toto rozdělení bylo zvoleno na 20 %. Velikost pracovních skupin (batch_size) modelu byla zvolena na 32 mozaik.</p> <p>Třídy modelu jsou vytvořeny nastavením složek, ze kterých model čerpá data. Každá složka a mozaiky v ní uložené pro model představuje jednu požadovanou třídu.</p> <p>Všechny mozaiky jsou klasifikovány takto natrénovaným modelem. Načítání segmentů pro klasifikaci je řízeno CSV souborem, který obsahuje název segmentu, pozici segmentu na mapovém listu a zda je určena pro trénování či nikoliv. Příslušné sloupce v CSV souboru jsou měněny z defaultní hodnoty 0 na hodnoty vycházející z klasifikace. Tréninkové segmenty jsou vynechány a je jim přiřazena příslušná hodnota.</p> <p>Je vytvořen nový CSV soubor s příponou _result. Tento soubor je identický se souborem log. Pouze dvě hodnoty 0 na konci řádku jsou nahrazeny pravděpodobnostmi příslušných tříd v desetinném formátu.</p>
Import zpět do ArcGIS	<p>K importu výsledku klasifikace zpět do ArcGIS slouží importovací skript. Tento skript načte metadatový soubor a získá z něj délku hrany segmentu, typ vzájemného posunu segmentu, rozměr původního rastru, souřadnici levého spodního rohu rastru a velikost pixelu.</p> <p>Prvním krokem importu je vytvoření prázdného rastru s hodnotami 0 o rozměrech stejných jako má původní rastr. Následně skript postupně prochází jednotlivé řádky databáze a načítá hodnoty příslušného sloupce výsledků a souřadnice segmentu. Výsledná</p>

	<p>hodnota je pak implantována na příslušnou pozici v rastru určenou načtenými souřadnicemi. Výsledná hodnota je přiřazena celé skupině pixelů odpovídající délce hrany segmentu. V případě vzájemného posunu segmentu je upraven počáteční bod každého řádku či sloupce.</p> <p>Výsledný rastr je uložen. Vzhledem k následnému průměrování posunutých rastrů, je standardně uložení prováděno pouze do dočasné paměti. A po provedení průměrování je rastr smazán.</p>
Průměrování	<p>Pro importované rastry je pomocí nástroje <i>Raster Calculator</i> vypočítána průměrná hodnota, tato hodnota je uložena v novém rastru, zároveň je tento rastr převzorkován, je tedy změna velikost pixelu. Nová velikost pixelu odpovídá poloviční délce segmentu. Tímto je získáno dvojnásobné rozlišení výsledného rastru.</p>

Počet vzniklých segmentů a nastavení parametrů pro porovnání jednotlivých analýz jsou uvedeny v následující tabulce:










Název modelu	Délka hrany segment	Threshold ratio	Počet segmentů Rill	Počet segmentů NoRill	Počet segmentů Others
Model_001	16	25	10 087	6 599	44 647
Model_002	16	25	13 147	8 704	44 636
Model_003	10	25	18 109	15 331	130 572

Tab. 3 Počet vzniklých segmentů a nastavení parametrů modelů pro satelitní scény

6.1.2 Výsledky

Analýza výsledků byla provedena pomocí vytvoření symbologie pro třídu rýhové poškození. Symbologie využila rozdělení výsledků do skupin v kroku 0,25. Hodnoty pravděpodobnosti 0 – 0,25 mají pískovou barvu, se stoupající hodnotou pravděpodobnosti přechází barva přes oranžovou směrem k sytě červené, pro pravděpodobnostní hodnoty 0,75 – 1,0.

Následující tabulka (Tab. 4) uvádí porovnání výsledků jednotlivých modelů. Model_001 a Model_002 mají téměř identické výsledky i přesto, že Model_002 používá 4 další vrstvy. Jedná se o vrstvu grayscale a 3 typy Canny Edge zvýrazněných linií. Oba modely mají stejnou velikost segmentu 16 pixelů. Model_003 vykazuje mnohem více heterogenní výsledky. Tento model obsahuje stejné vrstvy jako Model_002. Hlavním rozdílem je zde velikost segmentu, jenž je 10 pixelů.


	Model_001	Model_002	Model_003
Třebešice 1.4.2019			
Dobříš 5.9.2019			
Božetín 8.8.2020			

Tab. 4 Ukázka výsledků modelů pro satelitní scény

6.2 Data z bezpilotních prostředků

V rámci společné činnosti řešitelského týmu VÚMOP (Žížala, Minařík) a ČVUT byly podrobeny analýze využitelnosti při monitoringu erozních událostí a škod způsobených přívalovými srážkami data z bezpilotních monitorovacích. Tato aktivita pokračovala mezi roky 2019 a 2021. Celkem byl monitoring bezpilotními prostředky prováděn na 6 lokalitách, z čehož 4 se nacházejí v blízkém sousedství. Jedná se o lokalitu Býkovice 1 – 4, zájmové pozemky se nacházejí v okolí obcí Býkovice, Litichovice, Třebešice a Divišov. Lokalita Lišany se nachází severovýchodně od města Rakovník a lokalita Bulhary se nachází východně od města Lednice.

Data z bezpilotních prostředků mají různé prostorové rozlišení a zahrnují 3 viditelná spektrální pásma. Prostorové rozlišení se pohybuje od 0,75m/pixel pro lokalitu Bulhary po 0,23 m/pixel pro lokalitu Býkovice. Snímky tak vyžadovali převzorkování na stejnou velikost pixelu. Snímky jsou vytvořeny mozaikováním jednotlivých snímků pořízených bezpilotním prostředkem během náletu, nálet je vždy proveden během jednoho dne. Toto mozaikování je provedeno přímo softwarem bezpilotního prostředku, výsledkem je tak přímo ortofoto snímek lokality (viz Obr. 19).




Obr. 19 Snímek lokality Bulhary 25. 6. 2020

Následující tabulka uvádí data a lokality pro které byly snímky pořízeny

Býkovice 1	Býkovice 2	Býkovice 3	Býkovice 4	Bulhary	Lišany
18.12.2019	15.08.2017	05.10.2018	05.10.2018	10.05.2021	25.06.2020
14.03.2020	23.02.2021	10.05.2021		28.03.2022	21.05.2018
	18.05.2021	18.05.2021			

Tab. 5 Přehled dostupných scén pro zájmové lokality z bezpilotních prostředků

Rozsah snímků je maximálně 3 × 1 km u snímků lokality Bulhary, ostatní snímky jsou menší. Celkem bylo vyhodnoceno 13 scén. Analýza byla provedena s několika délkami hrany mozaiky. Délka hrany mozaiky tedy byla zvolena 4,9 m, 7,3 m, 10,1 m a 15,2 m. Tedy 21, 31, 43 a 65 pixelů snímku po převzorkování.



Obr. 20 Ukázka scény z bezpilotního prostředku, linie poškození a polygony poškození

6.2.1 Postup

Převzorkování	Původní snímky nemají stejnou velikost pixelu, bylo tedy nutné převzorkovat snímky tak aby stejnou velikost pixelu měli. Byla zvolena velikost pixelu 0,23 m, což je nejčastější velikost pixelu. Byl tak proveden nejmenší možný počet převzorkování.
Označování linií	Kalibrační polygony rýhového poškození mají hodnotu mezi 1 až 199, plošné poškození mezi 200 až 399 a bez poškození 400 až 599.
Rozdělení na trénovací a validační linie	Pro validaci modelu bylo náhodně vybráno 10 % kalibračních linií z každé třídy. Pokud bylo kalibračních linií pro určitý snímek a třídu méně než 10, byl náhodně vybrán 1. Takto vybrané linie byly označeny příslušným unikátním kódem. Validační polygony rýhového poškození mají hodnotu mezi 700 až 799, plošné poškození mezi 800 až 899 a bez poškození 900 až 999. Ostatním liniím zůstalo jejich původní označení.

Manuální tvorba trénovacích polygonů	<p>Na snímcích byly manuálně vytvořeny linie v osách vizuálně interpretovaného erozního poškození, k těmto liniím byla v atributové tabulce přiřazena hodnota šířky erozně poškozené plochy. Vizuální zatřídění se odvíjelo od hledání charakteristických projevů erozního poškození na snímcích. Významná světlejší barva oblasti, charakteristická stromová struktura rýhového erozního poškození, depoziční kužel atd. Nejčastěji byla nalézána rýhová eroze projevující se tmavou stromovou strukturou na světlém podkladu, nebo tmavé depoziční projevy na světlém podkladu (viz Obr. 20).</p> <p>Zároveň byly vytvořeny linie nad povrchem, který byl vizuálně interpretován jako nepoškozený. Těmto liniím je také přiřazena šířka, vzhledem k potřebě zasáhnout touto linií co největší plochu vzniká charakteristický zig zag pattern či bludiště. Model byl rozšířen o třídu plošné poškození pro oblasti poškozené plošnou erozí. Poškození těchto oblastí neodpovídalo klasické stromové struktuře poškození rýhovou erozí. Jednalo se především o depoziční kužele, oblasti s vysokou koncentrací krátkých erozních rýh či depozice materiálu mimo polní bloky. Rastr takto vzniklých pásů pak sloužil pro označení vytvořených mozaik na trénovací a validační.</p>
Segmentace kompozitu a export snímků	Segmentace scén probíhala s výstupem do CSV souboru jako řídicí databáze a TXT souborem pro uložení metadat.
Výpočet doplňkových vrstev	Model byl spuštěn pouze s doplňkovou černobílou vrstvou.
Délka hrany segmentu	Zvolená délka hrany segmentu byla 21, 65, 31 a 43 pixelů, což odpovídá 4,9 m, 7,3 m, 10,1 m a 15,2 m. Tato velikost byla zvolena z důvodu minimální předpokládané potřeby přesnosti modelu, jež je odhadnuta jako 5 m. Díky vzájemnému posunu segmentů, je však výsledná přesnost dvojnásobná, tedy 2,457 m, 7,605 m, 3,627 m a 5,031 m.
Vzájemný posun segmentů	Byl proveden vzájemný posun segmentačního okna o polovinu délky segmentu ve vodorovném směru, svislém směru a oběma směry zároveň. Vzniklo tak čtyřikrát více mozaik, které mohou být zatříděny, případně použity k trénování modelu, zároveň je umožněno zvýšit prostorové rozlišení výsledku.

Uspořádání mozaiky	<p>Byly vytvořeny mozaiky skládající se ze 4 vrstev v pořadí Blue, Green, Red, Grayscale. Výsledné mozaiky byly voleny s rozložením 2 snímky na šířku a 2 snímky na výšku.</p> <table border="1" data-bbox="766 369 1069 481"> <tr> <td>Blue</td> <td>Green</td> </tr> <tr> <td>Red</td> <td>Grayscale</td> </tr> </table> <p><i>Obr. 21 Uspořádání mozaiky modelu pro bezpilotní prostředky</i></p>	Blue	Green	Red	Grayscale
Blue	Green				
Red	Grayscale				
Poměry pro označení mozaiky	<p>Poměr noPix_threshold_ratio byl zvolen 80 %. Poměry pro ostatní kategorie byly zvoleny 25 %.</p>				
Otočení a zrcadlení segmentu	<p>Otočení a zrcadlení segmentu nebylo provedeno</p>				
CSV soubor	<p>Veškerá data důležitá pro běh klasifikačního modelu byla ukládána do CSV souboru s příponou _log. V záhlaví souboru byla uložena metadata příslušného listu. Název listu, délka hrany pixelu v m, souřadnice levého spodního rohu rastru, délka hrany segmentu v pixelech, počet vrstev rastru a rozměry rastru, typ vzájemného posunu segmentů.</p> <p>Další řádky CSV nesly následující hodnoty. Úplnou adresu uložené mozaiky, název mozaiky, souřadnice x mozaiky jako krok o velikosti segmentu, souřadnice y mozaiky jako krok o velikosti segmentu, hodnotu kategorie obsahuje-li mozaika tréninkový polygon, a příslušný počet sloupců s hodnotou 0 pro umístění výsledných hodnot klasifikace.</p>				
Model	<p>Původní model byl rozšířen o třetí kategorii a natrénován na příslušných tréninkových datech. Tréninkový datový soubor je načten do modelu a rozdělen na kalibrační a validační část pro účely kalibrace modelu. Toto rozdělení bylo zvoleno na 20 %. Velikost pracovních skupin (batch_size) modelu byla zvolena na 32 mozaik.</p> <p>Třídy modelu jsou vytvořeny nastavením složek, ze kterých model čerpá data. Každá složka a mozaiky v ní uložené pro model představuje jednu požadovanou třídu.</p> <p>Všechny mozaiky jsou klasifikovány takto natrénovaným modelem. Načítání segmentů pro klasifikaci je řízeno CSV souborem, který obsahuje název segmentu, pozici segmentu na snímku a zda je určena</p>				

	<p>pro trénování či nikoliv. Příslušné sloupce v CSV jsou měněny z defaultní hodnoty 0 na hodnoty vycházející z klasifikace. Tréninkové segmenty jsou vynechány a je jim přiřazena příslušná hodnota.</p> <p>Je vytvořen nový CSV soubor s příponou <code>_result</code>. Tento soubor je identický se souborem <code>log</code>. Pouze tři hodnoty 0 na konci řádku jsou nahrazeny pravděpodobnostmi příslušných tříd v desetinném formátu.</p> <p>Je vytvořen nový CSV soubor s příponou <code>_result</code>. Tento soubor je identický se souborem <code>log</code>. Pouze dvě hodnoty 0 na konci řádku jsou nahrazeny pravděpodobnostmi příslušných tříd v desetinném formátu.</p>
Import zpět do ArcGIS	<p>K importu výsledku klasifikace zpět do ArcGIS slouží importovací skript. Tento skript načte metadatový soubor a získá z něj délku hrany segmentu, typ vzájemného posunu segmentu, rozměr původního rastru, souřadnici levého spodního rohu rastru a velikost pixelu.</p> <p>Prvním krokem importu je vytvoření prázdného rastru s hodnotami 0 o rozměrech stejných jako má původní rastr. Následně skript postupně prochází jednotlivé řádky CSV a načítá hodnoty příslušného sloupce výsledků a souřadnice segmentu. Výsledná hodnota je pak implantována na příslušnou pozici v rastru určenou načtenými souřadnicemi. Výsledná hodnota je přiřazena celé skupině pixelů odpovídající délce hrany segmentu. V případě vzájemného posunu segmentu je upraven počáteční bod každého řádku či sloupce.</p> <p>Výsledný rastr je uložen. Vzhledem k následnému průměrování posunutých rastrů, je standardně uložení prováděno pouze do dočasné paměti. A po provedení průměrování je rastr smazán.</p>
Průměrování	<p>Pro importované rastry je pomocí nástroje <i>Raster Calculator</i> vypočítána průměrná hodnota, tato hodnota je uložena v novém rastru, zároveň je tento rastr převzorkován, je tedy změna velikost pixelu. Nová velikost pixelu odpovídá poloviční délce segmentu. Tímto je získáno dvojnásobné rozlišení výsledného rastru.</p>
Filtrace	<p>Volitelným krokem analýzy může být filtrace. Filtrace je provedena pomocí skriptu Python. Tento skript nejprve vytvoří nový rastr s hodnotou 0. Následně je filtrovaný průměrovaný rastr procházen pixel po pixelu a analyzovány pixely nebo jejich bezprostřední okolí</p>

	<p>(okno 3x3 pixelů). Pokud je splněna podmínka pro uvažování pixelu jako platného pixelu, je do nového rastru zapsána hodnota 1.</p> <p>Prvním krokem filtrace je vynulování pixelů s hodnotou menší než 0,5. Dále byly izolované pixely vynulovány. Pokud měl pixel hodnotu větší než 0,5 a zároveň byl v sousedství pixelu s hodnotou větší než 0,5, byla do výsledného rastru zapsána hodnota 1. Pro pixely s hodnotou větší než 0,75 a jejich bezprostřední okolí byla výsledná rastrová hodnota 1 zapsána do filtrovaného rastru.</p>
Posouzení	<p>Závěrečný krok je rozhodnutí, jaká kategorie bude pixelu finálně přiřazena. Prozatím se stále pracuje se zvláštním rastrem pro každou kategorii, ideálním výsledkem ovšem je bezešvý rastr pouze s jednotlivými kategoriemi. Tyto kategorie jsou označeny 0 – povrch bez rýhy, 1 – plošné poškození, 2 – rýhové poškození.</p> <p>K rozhodnutí tak je použit jednoduchý rozhodovací strom, preferující plochu bez rýh, následuje plošná eroze a nejnižší prioritu má plocha s rýhovým poškozením.</p>

Počet vzniklých segmentů a nastavení parametrů pro porovnání jednotlivých analýz jsou uvedeny v následující tabulce:


Název modelu	Délka hrany segment	Threshold ratio	Počet segmentů Rill	Počet segmentů NoRill	Počet segmentů Sheet	Počet segmentů Others
Model_001	21	25	2 6354	228 312	29 235	947 938
Model_002	65	25	3 875	24 904	3 623	91 126
Model_005	31	25	16 858	120 833	15 393	524 841
Model_006	43	25	7 759	55 945	7 619	211 752

Tab. 6 Počet vzniklých segmentů a nastavení parametrů modelů pro bezpilotní prostředky

6.2.2 Výsledky

Graf 1 porovnávající hodnoty diagonál validačních matic scén pro Model_001 ukazuje vysokou úspěšnost pro kategorii Bez poškození (NoRill). 9 za 14 testovaných ploch překročilo hodnotu 90% úspěšnosti pro tuto kategorii. V kategorii Plošné poškození (Sheet) přesahují 90 % úspěšnost pouze 2 scény. U kategorie Rýhové poškození (Rill) má jedna scéna úspěšnost vyšší 90 % a jedna scéna této hranici téměř dosahuje.


Délka hrany segmentu byla 21 pixelů, tedy 4,9 m po zprůměrování.



Graf 1 Úspěšnost pro Model_001 pro scény z bezpilotních prostředků

Graf 2 porovnávající hodnoty diagonál validačních matic scén pro Model_002 ukazuje vysokou úspěšnost pro kategorii Bez poškození (NoRill). 9 za 14 testovaných ploch překročilo hodnotu 90 % úspěšnosti a jedna scéna překonala hodnotu 80 % pro tuto kategorii. V kategorii Plošné poškození (Sheet) překonává 90 % úspěšnost pouze jedna scéna. U kategorie Rýhové poškození (Rill) má jedna scéna úspěšnost vyšší 90 %.

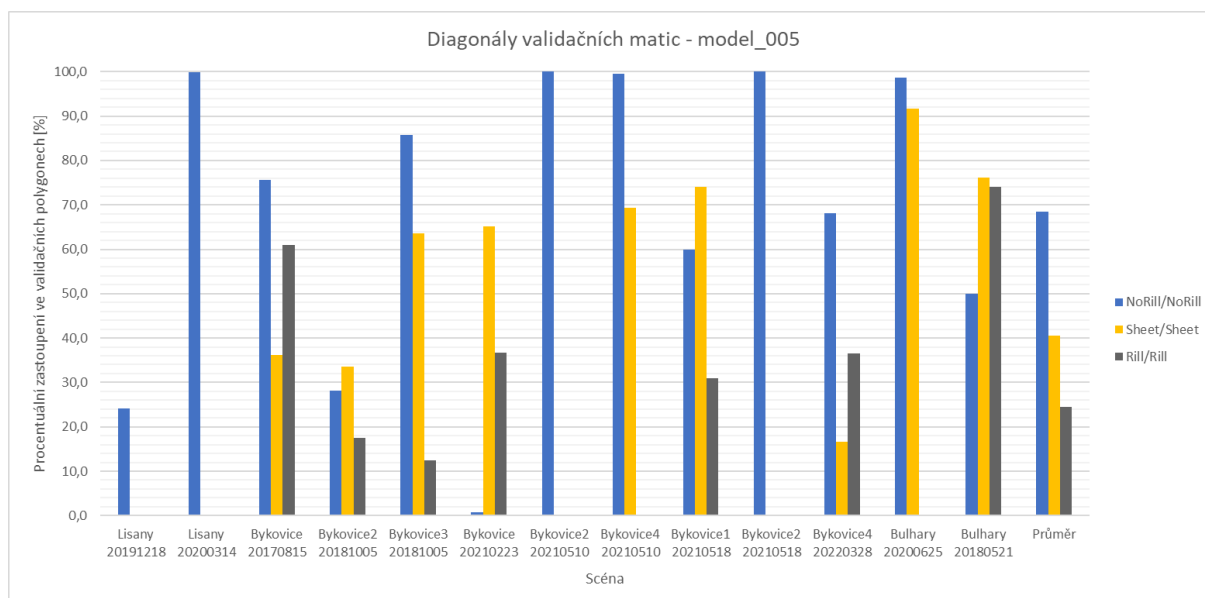
Délka hrany segmentu byla 65 pixelů, tedy 15,2 m po zprůměrování.



Graf 2 Úspěšnost pro Model_002 pro scény z bezpilotních prostředků

Graf 3 porovnávající hodnoty diagonál validačních matic scén pro Model_005 ukazuje stále ještě vyšší úspěšnost pro kategorii Bez poškození (NoRill). 5 za 14 testovaných ploch překročilo hodnotu 90% úspěšnosti a 4 scény se přiblížily nebo překonaly hodnotu 70 % pro tuto kategorii. V kategorii Plošné poškození (Sheet) překonává 90% úspěšnost pouze jedna scéna. U kategorie Rýhové poškození (Rill) žádná scéna nepřekračuje úspěšnost 90 %.

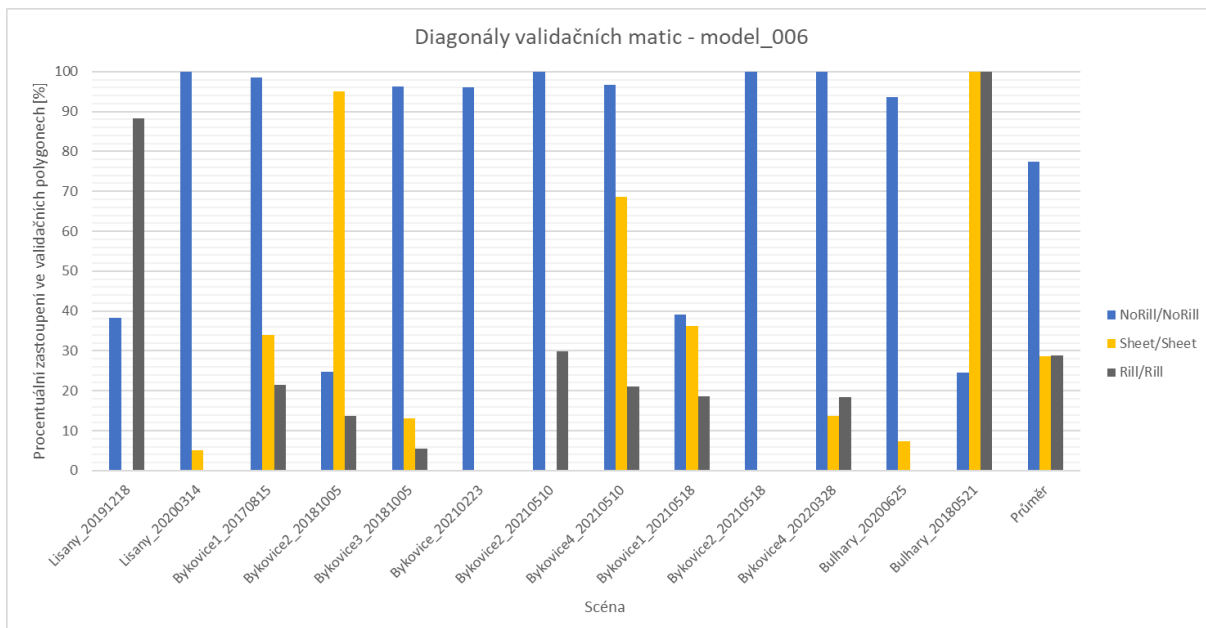
Délka hrany segmentu byla 31 pixelů, tedy 7,3 m po zprůměrování.



Graf 3 Úspěšnost pro Model_005 pro scény z bezpilotních prostředků

Graf 4 porovnávající hodnoty diagonál validačních matic scén pro Model_006 ukazuje vysokou úspěšnost pro kategorii Bez poškození (NoRill). 9 za 14 testovaných ploch překročilo hodnotu 90 % úspěšnosti a jedna scéna se přiblížila hodnotě 80 % pro tuto kategorii. V kategorii Plošné poškození (Sheet) překonávají 90% úspěšnost dvě scény. U kategorie Rýhové poškození (Rill) má jedna scéna úspěšnost vyšší 90 % a jedna scéna se jí přibližuje.

Délka hrany segmentu byla 43 pixelů, tedy 10 m po zprůměrování.



Graf 4 Úspěšnost pro Model_006 pro scény z bezpilotních prostředků

6.3 Experimentální plochy Jirkov

V rámci projektu Navrhování technických opatření pro stabilizaci a ochranu svahů před erozí bylo v průběhu let 2017 až 2020 provedeno celkem 78 erozních experimentů, přičemž každý experiment zahrnoval kombinaci suché a mokré simulace. Během těchto experimentů bylo prováděno celkem 234 fotogrammetrických snímkování, což zahrnovalo tři snímky (snímkování 1 až 3) u každé simulace.

Z těchto 234 snímkování bylo 84 měření vyhodnoceno v plné kvalitě na celé experimentální ploše, 110 měření bylo vyhodnoceno v menším rozsahu na menší ploše a 40 měření nebylo možné vyhodnotit vůbec kvůli nízké kvalitě vstupních dat. Tato nízká kvalita dat byla způsobena různými faktory, jako je nevhodné osvětlení experimentálních ploch, omezený přístup pro fotografování kvůli konstrukci zadešťovacího zařízení, nepravidelné zastínění povrchu, znečištění objektivu vodou z konstrukce zadešťovacího zařízení a další důvody.

Vzhledem k dostupnosti dvou ucelených sad dat, R1 a R2, byl zvolen postup, kdy bude model natrénován na sadě R1 a sada R2 bude zatříděna a vizuálně zhodnocena úspěšnost modelu. Dále bude model natrénován na sadě R2 a zatříděna bude sada R1. Následovat bude opět vizuální zhodnocení.



Obr. 22 Snímek plochy 2 lokality Jirkov varianta biomac_c_R2_12_2_03

Následující tabulka uvádí data a lokality pro které byly snímky pořízeny

R1					
Plocha 2		Plocha 3		Plocha 4	
Ryhy_12	Ryhy_34	Ryhy_12	Ryhy_34	Ryhy_12	Ryhy_34
biomac_c R1_12_2_01	biomac_c R1_34_2_01	biomac_c R1_12_3_01	biomac_c R1_34_3_01	biomac_c R1_12_4_01	biomac_c R1_34_4_01
biomac_c R1_12_2_02	biomac_c R1_34_2_02	biomac_c R1_12_3_03	biomac_c R1_34_3_02	biomac_c R1_12_4_02	biomac_c R1_34_4_02
	biomac_c R1_34_2_03		biomac_c R1_34_3_03	biomac_c R1_12_4_03	biomac_c R1_34_4_03

R2

Plocha 2		Plocha 3		Plocha 4	
Ryhy_12	Ryhy_34	Ryhy_12	Ryhy_34	Ryhy_12	Ryhy_34
biomac_c R2_12_2_01	biomac_c R2_34_2_01	biomac_c R2_12_3_01	biomac_c R2_34_3_01	biomac_c R2_12_4_01	biomac_c R2_34_4_01
biomac_c R2_12_2_02		biomac_c R2_12_3_02	biomac_c R2_34_3_02	biomac_c R2_12_4_02	biomac_c R2_34_4_02
biomac_c R2_12_2_03	biomac_c R2_34_2_03	biomac_c R2_12_3_03	biomac_c R2_34_3_03		biomac_c R2_34_4_03

Tab. 7 Přehled dostupných scén pro lokalitu Jirkov

Rozsah ploch je 3,2 x 1 m u plochy 2, 3,4 x 1 m u plochy 3 a 3,6 x 1 m u plochy 4. Celkem bylo vyhodnoceno 32 scén. Analýza byla provedena pouze s jednou délkou hrany mozaiky. Délka hrany mozaiky tedy byla zvolena 5 cm. Tedy 50 pixelů snímku.

6.3.1 Postup

Tvorba polygonů	Nad analyzovanými daty byly manuálně vytvořeny polygony obkličující erozní rýhy. V případě nepoškozeného povrchu byl většinou vytvářen obdélník. Vizualní zatřídění se odvíjelo od hledání charakteristických projevů erozního poškození na scénách. Významná světlejší barva oblasti, charakteristická stromová struktura rýhového erozního poškození, depoziční kužel atd. Nejčastěji byla nalézána rýhová eroze projevující se odhalením podkladního světlého štěrkového materiálu. Jsou vytvářeny tři trénovací kategorie. Rýhová eroze, plošná eroze a nepoškozená plocha (viz Obr. 22). Takto vytvořené polygony byly označeny příslušným unikátním názvem. Tento název byl později použit pro generování kódu třídy.
Označování polygonů	Polygonům byla v atributové tabulce přiřazena třída označující, zda se jedná o nepoškozené, rýhově nebo plošně poškozené plochy. Tréninkové polygony rýhového poškození mají hodnotu mezi 1 až 87, plošné poškození 88 a bez poškození 99.
Segmentace kompozitu a export snímků	Segmentace scén probíhala s výstupem do CSV souboru jako řídicí databáze a TXT souborem pro uložení metadat.
Výpočet doplňkových vrstev	Z doplňkových vrstev byly tvořeny: černobílá varianta a Canny Edge Filter se třemi variantami parametru σ , a to 1, 2 a 3.
Délka hrany segmentu	Zvolená délka hrany segmentu byla 50 pixelů, což odpovídá 5 cm. Tato velikost byla zvolena z důvodu minimální předpokládané potřeby

	přesnosti modelu, jež je odhadnuta jako 5 cm. Díky vzájemnému posunu segmentů, je však výsledná přesnost dvojnásobná, tedy 2,5 cm.							
Vzájemný posun segmentů	Byl proveden posun segmentačního okna o polovinu délky segmentu ve vodorovném směru a svislém směru zároveň.							
Uspořádání mozaiky	<p>Byly vytvořeny mozaiky skládající se ze 4 vrstev v pořadí Blue, Green, Red, Grayscale. Výsledné mozaiky byly voleny s rozložením 2 snímky na šířku a 2 snímky na výšku.</p> <table border="1"> <tr> <td>Blue</td> <td>Green</td> <td>Red</td> <td>Grayscale</td> <td>Canny Edge 1</td> <td>Canny Edge 2</td> <td>Canny Edge 3</td> </tr> </table> <p><i>Obr. 23 Uspořádání mozaik pro scény z lokality Jirkov</i></p>	Blue	Green	Red	Grayscale	Canny Edge 1	Canny Edge 2	Canny Edge 3
Blue	Green	Red	Grayscale	Canny Edge 1	Canny Edge 2	Canny Edge 3		
Poměry pro označení mozaiky	Poměr noPix_threshold_ratio byl zvolen 80 %. Poměr Rill_threshold_ratio byl zvolen 1 %. Poměr Sheet_threshold_ratio byl zvolen 10 %. Poměr NoRill_threshold_ratio byl také zvolen 10 %.							
Otočení a zrcadlení segmentu	Otočení a zrcadlení segmentu nebylo provedeno							
CSV soubor	<p>Veškerá data důležitá pro běh klasifikačního modelu byla ukládána do CSV souboru s příponou _log. V záhlaví souboru byla uložena metadata příslušného listu. Název listu, délka hrany pixelu v m, souřadnice levého spodního rohu rastru, délka hrany segmentu v pixelech, počet vrstev rastru a rozměry rastru, typ vzájemného posunu segmentů.</p> <p>Další řádky CSV nesly následující hodnoty. Úplnou adresu uložené mozaiky, název mozaiky, souřadnice x mozaiky jako krok o velikosti segmentu, souřadnice y mozaiky jako krok o velikosti segmentu, hodnotu kategorie obsahuje-li mozaika tréninkový polygon, a příslušný počet sloupců s hodnotou 0 pro umístění výsledných hodnot klasifikace.</p>							
Model	Původní model byl rozšířen o třetí kategorii a natrénován na příslušných tréninkových datech. Tréninkový datový soubor je načten do modelu a rozdělen na kalibrační a validační část pro účely kalibrace modelu. Toto rozdělení bylo zvoleno na 20 %. Velikost pracovních skupin (batch_size) modelu byla zvolena na 32 mozaik.							

	<p>Třídy modelu jsou vytvořeny nastavením složek, ze kterých model čerpá data. Každá složka a mozaiky v ní uložené pro model představuje jednu požadovanou třídu.</p> <p>Všechny mozaiky jsou klasifikovány takto natrénovaným modelem. Načítání segmentů pro klasifikaci je řízeno CSV souborem, který obsahuje název segmentu, pozici segmentu na snímku a zda je určena pro trénování či nikoliv. Příslušné sloupce v CSV jsou měněny z defaultní hodnoty 0 na hodnoty vycházející z klasifikace. Tréninkové segmenty jsou vynechány a je jim přiřazena příslušná hodnota.</p> <p>Je vytvořen nový CSV soubor s příponou _result. Tento soubor je identický se souborem log. Pouze tři hodnoty 0 na konci řádku jsou nahrazeny pravděpodobnostmi příslušných tříd v desetinném formátu.</p>
Import zpět do ArcGIS	<p>K importu výsledku klasifikace zpět do ArcGIS slouží importovací skript. Tento skript načte metadatový soubor a získá z něj délku hrany segmentu, typ vzájemného posunu segmentu, rozměr původního rastru, souřadnici levého spodního rohu rastru a velikost pixelu.</p> <p>Pro importované rastry byla vypočítána průměrná hodnota pixelu, byla uložena v novém rastru, zároveň a ten byl převzorkován. Nová velikost pixelu odpovídala poloviční délce segmentu. Tímto bylo získáno dvojnásobné rozlišení výsledného rastru.</p>
Průměrování	Průměrování nebylo provedeno
Filtrace	Filtrace nebyla provedena
Posouzení	Posouzení nebylo provedeno

Počet vzniklých segmentů a nastavení parametrů pro porovnání jednotlivých analýz jsou uvedeny v následující tabulce:


Název modelu	Délka hrany segment	Počet segmentů Rill	Počet segmentů NoRill	Počet segmentů Sheet	Počet segmentů Others
Model_002	50	11 595	14 222	8 810	35 771
Model_003	50	15 022	13 669	6 877	31 368

Tab. 8 Počet vzniklých segmentů a nastavení parametrů pro lokalitu Jirkov


6.3.2 Výsledky

Analýza snímků z lokality Jirkov byla první analýzou dat pomocí vytvářeného modelu. Nebyla v té době připravená celková metodika analýzy dat. Vyhodnocení tedy bylo provedeno pouze pomocí optického porovnání. Na následujících snímcích jsou zobrazeny některé výsledky modelu.


Za symbologii bylo zvolena zelená – povrch bez rýhy, fialová – plošné poškození, šedá – rýhové poškození. A různé odstíny, respektive průhlednosti. Rozdělení bylo provedeno v kroku 0,25.



Jirkov R1 12 2 1




Jirkov R1 12 2 2



Jirkov R1 12 3 1



Jirkov R1 12 4 2



Jirkov R1 12 4 3

Obr. 24 Ukázka výsledků pro lokalitu Jirkov

Snímek Jirkov R1_12_2_1 zobrazuje plochu před experimentem, tedy se zcela neporušenou půdou. Snímek by tak měl být zcela označený za neporušenou půdu, zcela pokryt symbologií zelené barvy. Toto je do značné míry splněno, nacházejí se zde však plochy označené jak za plošné poškození, tak rýhové poškození.

Snímek Jirkov R1_12_2_2 zobrazuje plochu po první části experimentu. Plocha je tedy ve stavu, kdy byla podrobena 30minutové srážce. Plocha bez poškození je zmenšená, přibývá plocha, kde je pravděpodobnost výskytu půdy bez poškození velmi nízká (<25 %). Ve střední části plochy je vidět jasné označení rýhového poškození modelem. Nicméně objevuje se nesprávně označené rýhové poškození za nepoškozenou půdu.

Snímek Jirkov R1_12_3_1 zobrazuje opět plochu před experimentem, tedy se zcela neporušenou půdou. Snímek by tak měl být zcela označený za neporušenou půdu, zcela pokryt symbologií zelené barvy. Toto téměř zcela splněno, nacházejí se zde však drobné plochy označené za rýhové poškození.

Snímek Jirkov R1_12_4_2 zobrazuje plochu po první části experimentu. Plocha bez poškození je zmenšená vytvořenými rýhami. Je vidět nově vytvořená stromová struktura rýhového poškození. A dále se rozšířila oblast s nízkou pravděpodobností výskytu plochy bez poškození. Nicméně i zde se vyskytují plochy nesprávně zatříděné do jedné nebo druhé třídy.

Snímek Jirkov R1_12_4_3 zobrazuje plochu po druhé části experimentu. Plocha je tedy ve stavu, kdy byla podrobena dvěma 30minutovým srážkám proloženým 15minutovou pauzou. Plocha bez poškození je významně zmenšená. Významně přibyla oblast označená za plochu s plošným poškozením. Je vidět nově vytvořená stromová struktura rýhového poškození. Nesprávně zatříděné plochy se téměř nevyskytují.

Obecně se ukazuje potenciál modelu pro zatřídění erozního poškození na plochách experimentálního srážkového simulátoru. Úspěšnost je nejvyšší u třídy bez poškození, která má nejvíce dostupných tréninkových dat, třída plošné poškození se vyskytuje pouze ve specifických případech. Třída rýhové poškození vytváří spojitou charakteristickou stromovou strukturu.

6.4 Laboratorní dešťový simulátor

Během let 2018 až 2020 proběhlo v rámci různých projektů 31 erozních experimentů, které zahrnovaly kombinaci suchých a mokřých simulací. Během těchto experimentů bylo celkem provedeno 77 úspěšných fotogrammetrických měření, což znamená, že bylo vytvořeno 77 ortofoto snímků a digitálních modelů terénu (DEM).

Bohužel, v některých případech byla kvalita snímků nedostatečná pro získání kvalitního finálního ortofoto a DEM, a proto nebylo možné tato měření použít jako vstupu do modelu. Toto se stalo u 16 fotogrammetrických měření.

Ve výsledku tak bylo pro model dostupných pouze 34 jednotlivých fotogrammetrických měření. Část měření byla pro stav před experimentem, nenacházelo se tak na snímcích žádné poškození. První část experimentu nevytvoří vždy rýhové poškození plochy, to dále snižuje množství dostupných dat pro trénink modelu.

Poškození na snímcích z Laboratorního dešťového simulátoru bylo již zčásti manuálně digitalizováno v rámci projektu STRIX. Digitalizace však nebyla pro použití v modelu dostatečná, polygony tedy byly zkontrolovány a upraveny. Došlo k doplnění rýh o menší osamocené rýhy. Dále byla přidána kategorie nepoškozený povrch. Tato kategorie se vyskytovala na snímcích před simulací a v horní části simulátoru (viz Obr. 25). Rýhy se objevují v drtivé většině případů ve spodní části simulačního žlabu. Pro kalibraci modelu byla také vytvořena nová skupina kalibračních polygonů obsahujících povrch poškozený plošnou erozí.



Obr. 25 Ukázka polygonů pro Laboratorní dešťový simulátor. Nepoškozený povrch – zelená, plošná eroze – oranžová, rýhy – červená

6.4.1 Postup

Výpočet FlowDirection	Nástroj <i>Flow Direction</i> je základní nástroj využívaný pro hydrologickou analýzu v GIS aplikacích. Tento nástroj je dostupný také v programu ArcGIS Pro. Pracuje tak, že určuje směr toku pro jednotlivé pixely tvořící digitální model reliéfu (DEM). Tento nástroj využívá algoritmus D8 k určení směru, kterým by voda vytekla z každého pixelu, na základě nejstrmějšího sklonu, tedy poměru mezi hodnotami rozdílu výšky pixelů a vzdálenosti jejich středů. Každému pixelu ve výstupním rastrovém datasetu je přiřazena hodnota jednoho z osmi možných směrů: sever, severovýchod, východ, jihovýchod, jih, jihozápad, západ nebo severozápad. Výstup z tohoto nástroje je cennou informací pro další analýzy jako je vymezení plochy povodí, identifikace směru odtoku vody a modelování toku povrchové vody v GIS analýzách. Vzhledem k předpokladu tvorby erozního poškození v oblastech s největším průtokem vody, tedy v místech, kde povrchový tok proudí stejným ve stejném směru, se přidání vrstvy FlowDirection jeví jako užitečné pro usnadnění práce modelu. Podobnou funkci může zajistit i přidání vrstvy FlowAccumulation, tedy počet pixelů, ze kterých do daného pixelu přitéká povrchový tok. Tato vrstva však neposkytuje normalizovaný výstup.
Tvorba polygonů	Polygon rýhové poškození kopíroval viditelnou rýhu s velmi malým odstupem, tvorba těchto polygonů byla časově nejnáročnější. Polygony třídy plošné poškození byly většinou tvořeny jako obdélníky či polygony v oblastech, ve kterých nebylo vizuálně zjištěno rýhové poškození, polygony nepoškozeného povrchu byly vytvářeny nad vizuálně nepoškozenou homogenní půdou.
Označování polygonů	Tréninkové polygony rýhového poškození mají hodnotu mezi 1 až 199, plošné poškození mezi 200 až 399 a bez poškození 400 až 599. Tato úprava umožnila detailní sledování každého tréninkového polygonu, a tedy validaci modelu.
Rozdělení na trénovací a validační linie	Pro validaci modelu bylo náhodně vybráno 10 % kalibračních linií z každé třídy. Pokud bylo kalibračních linií pro určitý snímek a třídu méně než 10, byl náhodně vybrán 1. Takto vybrané linie byly označeny příslušným unikátním kódem. Validační polygony rýhového

	poškození mají hodnotu mezi 700 až 799, plošné poškození mezi 800 až 899 a bez poškození 900 až 999. Ostatním liniím zůstalo jejich původní označení.					
Tvorba kompozitu	Rastr trénovacích a validačních polygonů byl spojen s RGB snímkem. Trénovací a validační polygony byly vždy použity jako první pásmo kompozitu, následovalo pásmo B, G, R a Flow Direction. Tyto kompozity byly následně použity pro segmentaci.					
Segmentace kompozitu a export snímků	Segmentace scén probíhala s výstupem do SQLite databáze a JSON souborem pro uložení metadat.					
Výpočet doplňkových vrstev	Model byl spuštěn pouze s doplňkovou černobílou vrstvou vytvořenou z vrstev R, G a B.					
Délka hrany segmentu	Zvolená délka hrany segmentu byla pro jednotlivé modely měněna tak aby bylo možné studovat vliv této změny na úspěšnost klasifikace. Zároveň byly hodnoty udržovány v mezích, které jsou vhodné pro vyhodnocení erozního poškození. Zvoleny byly tedy délky hrany 50, 75 a 100 pixelů odpovídající 50, 75 a 100 mm.					
Vzájemný posun segmentů	Byl proveden posun segmentačního okna o polovinu délky segmentu ve vodorovném směru, svislém směru a oběma směry zároveň. Vzniká tak čtyřikrát více mozaik.					
Uspořádání mozaiky	Byly vytvořeny mozaiky skládající se ze 4 vrstev v pořadí Blue, Green, Red, Grayscale. Výsledné mozaiky byly voleny s rozložením 2 snímky na šířku a 2 snímky na výšku. <table border="1" data-bbox="571 1368 1390 1424"> <tr> <td>Blue</td> <td>Green</td> <td>Red</td> <td>FlowDirection</td> <td>Grayscale</td> </tr> </table> <p><i>Obr. 26 Uspořádání mozaik pro scény z Laboratorního dešťového simulátoru</i></p>	Blue	Green	Red	FlowDirection	Grayscale
Blue	Green	Red	FlowDirection	Grayscale		
Poměry pro označení mozaiky	Poměr noPix_threshold_ratio byl zvolen 80 %. Hodnoty poměrů pro nepoškozený povrch, rýhu a plošné poškození byly postupně měněny tak aby vznikla řada výsledků vhodná pro další analýzu modelu. Byly zvoleny 4 hodnoty thresholdů: 25, 40, 55 a 75 %. Hodnoty thresholdů byly vždy stejné pro všechny třídy.					
Otočení a zrcadlení segmentu	Byly provedeny všechny zvolené otočení a zrcadlení segmentu pro třídu rýhové poškození.					
Databázový soubor	Vzhledem k vysokému počtu vytvořených databází a časové náročnosti klasifikace dat, bylo opuštěno používání CSV souborů a ty byly nahrazeny SQLite databází pro ukládání řídicích dat. Používání					


	<p>databáze umožnilo bezproblémové opětovné spuštění modelu po jeho pádu, práci dvou modelů na jedné scéně zároveň a rychlé třídění dat na data ke klasifikaci a trénovací data.</p>
Model	<p>Byl využit model rozšířený o třetí kategorii. Ten byl následně natrénován na příslušných tréninkových datech. Tréninkový datový soubor je načten do modelu a rozdělen na kalibrační a validační část pro účely kalibrace modelu. Toto rozdělení bylo zvoleno na 20 %. Velikost pracovních skupin (<code>batch_size</code>) modelu byla zvolena na 32 mozaik.</p> <p>Třídy modelu jsou vytvořeny nastavením složek, ze kterých model čerpá data. Každá složka a mozaiky v ní uložené pro model představuje jednu požadovanou třídu.</p> <p>Všechny mozaiky jsou klasifikovány takto natrénovaným modelem. Načítání segmentů pro klasifikaci je řízeno DB databází, která obsahuje název segmentu, pozici segmentu na mapovém listu a zda je určena pro trénování či nikoliv. Příslušné sloupce v DB jsou měněny z defaultní hodnoty 0 na hodnoty vycházející z klasifikace. Tréninkové segmenty jsou vynechány a je jim přiřazena příslušná hodnota.</p> <p>Původně byl vytvořen nový CSV soubor s příponou <code>_result</code>. Tento soubor je identický se souborem <code>log</code>. Pouze tři hodnoty 0 na konci řádku jsou nahrazeny pravděpodobnostmi příslušných tříd v desetinném formátu. To je nyní nahrazeno opětovným zápisem do původní databáze.</p>
Import zpět do ArcGIS	<p>K importu výsledku klasifikace zpět do ArcGIS slouží importovací skript. Tento skript načte metadatový soubor a získá z něj délku hrany segmentu, typ vzájemného posunu segmentu, rozměr původního rastru, souřadnici levého spodního rohu rastru a velikost pixelu.</p> <p>Výsledný rastr je uložen. Vzhledem k následnému průměrování posunutých rastrů, je standardně uložení prováděno pouze do dočasné paměti. A po provedení průměrování je rastr smazán.</p>
Průměrování	<p>Pro importované rastry je pomocí nástroje <i>Raster Calculator</i> vypočítána průměrná hodnota, tato hodnota je uložena v novém rastru, zároveň je tento rastr převzorkován, je tedy změněna velikost</p>

	<p>pixelu. Nová velikost pixelu odpovídá poloviční délce segmentu. Tímto je získáno dvojnásobné rozlišení výsledného rastru.</p>
Filtrace	<p>Byla provedena standardní filtrace průměrovaného rastru. Prvním krokem filtrace bylo vynulování pixelů s hodnotou menší než 0,5. Dále byly izolované pixely vynulovány. Pokud měl pixel hodnotu větší než 0,5 a zároveň byl v sousedství pixelu s hodnotou větší než 0,5, byla do výsledného rastru zapsána hodnota 1. Pro pixely s hodnotou větší než 0,75 a jejich bezprostřední okolí byla výsledná rastrová hodnota 1 zapsána do filtrovaného rastru.</p>
Posouzení	<p>Závěrečným krokem bylo rozhodnutí, jaká kategorie bude pixelu finálně přiřazena, tak aby výsledkem byl bezešvý rastr pouze s jednotlivými kategoriemi. Tyto kategorie jsou označeny 0 – povrch bez rýhy, 1 – plošné poškození, 2 – rýhové poškození.</p> <p>K rozhodnutí sloužil jednoduchý rozhodovací strom, preferující plochu bez rýh, následuje plošná eroze a nejnižší prioritu má plocha s rýhovým poškozením.</p>


Počet vzniklých segmentů a nastavení parametrů pro citlivostní analýzu jsou uvedeny v následující tabulce:

Název modelu	Délka hrany segment	Threshold ratio	Počet segmentů Rill	Počet segmentů NoRill	Počet segmentů Sheet	Počet segmentů Others
Model_001	50	25	60887	294857	278449	987088
Model_002	50	40	50470	286011	267685	996791
Model_003	50	55	12043	80356	73792	291166
Model_004	50	70	9810	78419	70857	298271
Model_005	75	25	30254	134125	128652	439544
Model_006	75	40	23881	129130	121887	448487
Model_007	75	55	5180	36100	33061	132284
Model_008	75	70	3678	34935	31000	137012
Model_009	100	25	15752	68759	67271	213924
Model_010	100	40	11410	66289	62857	220566
Model_011	100	55	7840	64411	58939	229932
Model_012	100	75	1355	17725	15641	68401

Tab. 9 Přehled počtu vytvořených segmentů a nastavení parametrů jednotlivých modelů pro Laboratorní dešťový simulátor



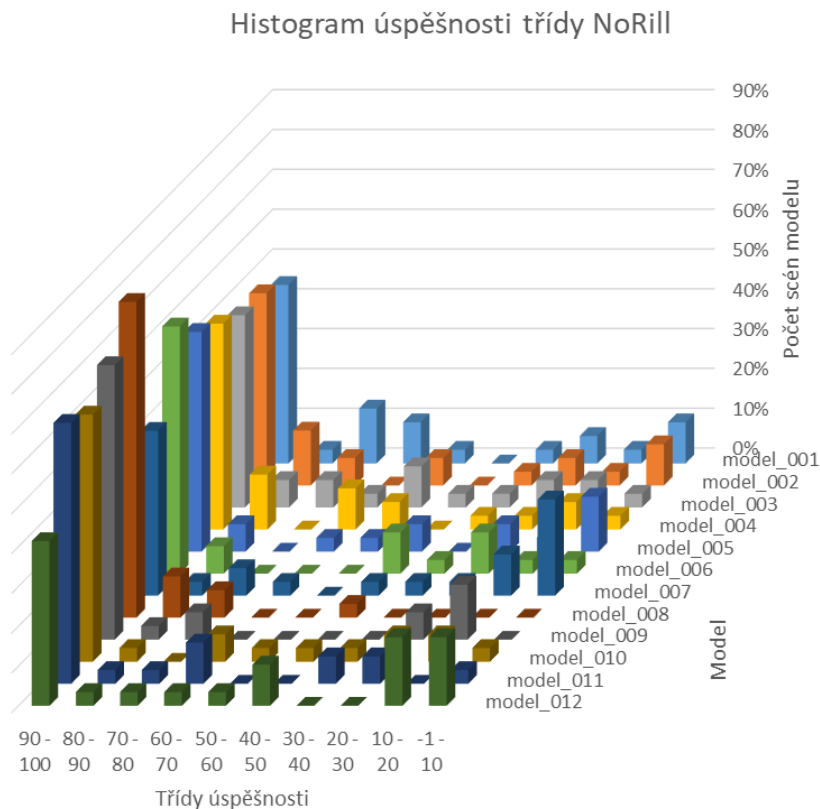
Graf 5 Závislost počtu trénovacích segmentů na hodnotě tresholdu




Graf 6 Závislost počtu trénovacích segmentů na velikosti segmentu

6.4.2 Histogram úspěšnosti klasifikace dle třídy


Histogram úspěšnosti klasifikace dle třídy umožňuje porovnat výsledky jednotlivých modelů dle klasifikačních tříd. Pro vyhodnocení byly zvoleny hranice tříd po 10 % od 0 do 100 %. Ideálním výsledkem je maximální počet validačních dat ve skupině 90 – 100 %.



Graf 7 Histogram úspěšnosti pro třídu NoRill (Bez poškození)




Graf 8 Histogram úspěšnosti pro třídu Sheet (Plošné poškození)



Graf 9 Histogram úspěšnosti pro třídu Rill (Rýhové poškození)

Z Graf 7 je patrné, že nejlepších výsledků dosahuje třída Bez poškození (NoRill) téměř u všech modelů, a tedy i velikostí a počtu segmentů. Další úspěšnou skupinou je Plošné poškození (Sheet). Především u modelů 005 až 008 (viz Graf 8), s velikostí segmentu 75 pixelů je konzistentní úspěšnost s maximem až 90 % u modelu 007. Nejhorších výsledků je dosaženo u třídy Rýhové poškození (Rill). Zde převládá třída 0 – 10 % (viz Graf 9). Většina ploch tedy byla úspěšně zatříděna pouze z méně než 10 %. Nejlepších výsledků tak dosahují modely 005 a 010, u kterých 30 % ploch bylo zatříděno s více než 90% úspěšností.


6.4.3 Závislost úspěšnosti dle tříd na velikosti segmentu



Graf 10 Závislost úspěšnosti dle tříd na velikosti segmentu

Neukázala se jasná závislost úspěšnosti klasifikace na velikosti segmentu. Třídy Bez poškození a Plošné poškození soustavně vykazují vysokou úspěšnost, a to při všech velikostech segmentu, přičemž o málo úspěšnější se zdají být modely s velikostí segmentu 75 pixelů. Třída Rýhové poškození trvale vykazuje nižší úspěšnost s maximy pod 60 %. U některých modelů však nedosahuje ani 10 % a vykazuje značnou variabilitu.

6.4.4 Závislost úspěšnosti dle tříd na počtu tréninkových segmentů



Graf 11 Závislost úspěšnosti dle tříd na počtu tréninkových segmentů

Ukazuje se mírná závislost úspěšnosti na počtu trénovacích segmentů. Tato závislost se ukazuje především u třídy Rýhové poškození. Od dosažení určitého počtu segmentů úspěšnost výrazně neroste. Tato hranice je zhruba 10 000 segmentů pro třídu.

6.5 Souhrn výsledků a diskuse

Analýza výsledků ukázala vyšší úspěšnost klasifikace pro třídu Bez poškození a Plošná eroze. Třída Rýhové poškození trvale vykazuje nejhorší výsledky úspěšnosti. Kritériem úspěšnosti je dostatek trénovacích segmentů. Získat trénovací segmenty pro třídu Rýhové poškození je složité a těchto segmentů je vždy nejméně. Dále mají tyto segmenty vysokou vnitřní variabilitu ve srovnání se segmenty nepoškozené půdy, či plošného poškození (viz Obr. 25). Tato vnitřní variabilita dále zvyšuje potřebu počtu trénovacích segmentů.

Porovnání úspěšnosti jednotlivých modelů ukazuje, že nelze zvolit optimální velikost segmentu pro klasifikaci všech tříd. Jednotlivé klasifikované jevy mají různou prostorovou velikost a vztah této velikosti jevu a velikosti segmentu napomáhá úspěšnosti klasifikace. Nejlepších výsledků dosahuje velikost segmentu 75 pixelů, která odpovídá 3,5 cm po zprůměrování posunutých segmentů. Nejmenší velikost segmentu 50 pixelů odpovídající 2,5 cm po zprůměrování posunutých segmentů vykazuje nejhorší výsledky. Velikost segmentu 100 pixelů odpovídající 5 cm po zprůměrování posunutých segmentů má střední úspěšnost.

Ideální cestou se tak jeví kombinace výsledků více modelů s různou velikostí segmentu. Tento přístup ale vyžaduje metodu, jak rozhodnout o syntéze výsledků modelů do finálního klasifikovaného rastru.

7 Experimentální aplikace na skenech map

7.1 Motivace pro vyhodnocení map metodami strojového učení

Veškeré zpracovávané mapy byly původně vytvořené tiskem v papírové podobě. Tyto papírové mapy byly naskenovány a georeferencovány poskytovatelem dat. Před digitalizací došlo k jejich stažení a případným úpravám.

Digitalizace map má několik výhod. Digitalizace umožňuje vytvoření databáze, kde je možné zaznamenat jednotlivé mapy a údaje o nich. K digitalizovaným mapám lze připojit různé informace, jako je stáří mapy, autor mapy, zobrazované území apod. Dále je možné fyzicky ochránit mapové listy před jejich mechanickým poškozením. (Housková 2008)

Digitalizováním map se otevírají nové možnosti. Pro práci s mapou není nutné chodit do archivů a hledat složitě vybrané mapy. Pomocí internetu lze přistupovat k mapám 24 hodin denně. (Housková 2008)

Skenování map probíhá pomocí skenerů. Je tak vytvořen digitální obraz skládající se z jednotlivých pixelů, Základní dva parametry skenování jsou hustota skenování a barevná hloubka. Každý pixel nese tři informací, a to intenzity základních barev (R, G, B). Pro skenování map je nejvhodnější rozlišení mezi 300 dpi a 500 dpi. (Housková 2008)

Barevná hloubka udává, nakolik přesný je převod barev při digitalizaci. Čím vyšší je barevná hloubka, tím více barev se rozlišuje a tím přesnější je vykreslení obrazu. Oko sice není schopno přesně rozeznat miliardy barev, ale pokud se s digitálním obrazem dále pracuje, pak vyšší kvalita znamená lepší výsledky při úpravách. Pro skenování barevných map jsou nejpoužívanější dvě metody. První z nich je metoda 8bitové snímání do barevné palety a druhá je 24bitové snímání pro složky RGB (tzv. „true color“) (viz 10).

Druh obrazu	Počet bitů	Počet barev	Aplikace
Černobílý 1	1	$2^1 = 2$ (bílá a černá)	
Stupně šedi 8	8	$2^8 = 256$ (odstínů šedi)	Stabilní katastr, ZM z 80.tých let
8bitový barevný (color)	8	$2^8 = 256$ (barev)	Mapy ZVM
16bitový barevný (high color)	16	$2^{16} = 65\,536$ (barev)	
24bitový barevný (true color)	24	$2^{24} = 16\,777\,216$ (barev)	
32bitový barevný (true color)	32	$2^{32} = 4\,294\,967\,296$ (barev)	

Tab. 10 Rozdělení skenů map dle kvality

Aplikace vyvíjeného segmentačního modelu na dostupných skenech mapových podkladů měla několik důvodů. Mapová díla jsou vysoce unifikované datasey. Lze tedy předpokládat vysokou úspěšnost zatřídění, a tedy zjistit teoretickou maximální úspěšnost segmentačního modelu. Na mapových dílech lze vyzkoušet identifikaci prvků různých typů (body, linie, plochy) a tím získat přehled o univerzálnosti modelu. Mapová díla umožňují klasifikaci do více tříd, než nabízí použití na erozních plochách, lze tak získat informace o robustnosti modelu. V neposlední řadě existovala potřeba převodu mapových děl do vektorové podoby, případně potřeba separace daných objektů z mapy pro jejich následné kvantitativní posouzení, nebo tvorbu jiné mapy

7.1.1 TIFF15

Formát TIFF (neboli „Tagged Image File Format“) je spolu s formáty JPEG a PNG mezinárodním standardem pro kódování statických obrazů. TIFF byl původně vytvořen za účelem získání jednotného formátu pro skenery. Tento formát je typickým představitelem bitmapového formátu, tzn. grafická informace je v něm vyjádřena formou pixelů, přičemž u každého pixelu je udána informace o jeho barvě. Tento rastrový formát má mnoho výhod. Největší výhodou uvedeného typu je schopnost věrné kopie daného obrazu (sejmutého skenerem nebo i digitálním fotoaparátem). Další je, že neztrácí informace při přenosu do jiného prostředí. A v neposlední řadě je jeho rozšířenost, tudíž je zaručeno, že data bude možno otevřít v maximálním počtu softwarů. Nevýhodou je velkým objem souborů, rostoucí úměrně s rozměry a rozlišením. (Housková 2008)

7.1.2 JPEG

Skutečným pojmenováním tohoto grafického formátu je JFIF (JPEG File Interchange Format). Formát JFIF (pro vžitý výraz dále jen JPEG) používá mnoho přípon - *.JPG, *.JPG, *.jfif, *.jpe. V současné době nejvíce využívaný formát při kompresi obrázků obsahuje plnou barevnou informaci. Můžeme mít tak v jednom obrázku cca 16 milionů barev. Díky tomu je vhodný pro fotografie nebo obrázky s hladkými přechody. Formát JPEG by bylo v podstatě možné aplikovat i pro digitalizaci map. (Housková 2008)


7.2 Základní vodohospodářské mapy

Základní vodohospodářskou mapu ČR 1:50 000 (dále jen ZVM) vydával Český úřad zeměměřický a katastrální jako tematické státní mapové dílo pro Ministerstvo životního prostředí ČR. Gestorem za aktualizaci tematického obsahu byl Výzkumný ústav vodohospodářský T.G.M. Mapu zpracovával a tiskl Zeměměřický úřad na papíru formátu 58x47 cm v kladu listů základních map středních měřítek. Každoročně se aktualizovalo kolem 20 mapových listů.

Mapa byla dotiskem tematického obsahu do základní mapy ČR 1:50 000. Zobrazuje síť vodních toků, rozvodnic a hydrologického členění povodí, objekty státních pozorovacích sítí, stavby a opatření na využití povrchových a podzemních vod, ochranná pásma vodních objektů, objekty a zařízení hlavních uživatelů vody (např. vodovodů a kanalizací, využití vodní energie, vodní dopravy, průmyslu) a další informace.

Skeny listů ZVM ve formátu TIFF byly importovány do ArcGIS. Jedná se o rastry s velikostí pixelu 3,18 m. Souřadnicový systém rastrů je S-JTSK Křovák. Rastr je 8bitový jednopásmový. Rozsah hodnot v jednom pixelu tak může být od 0 do 255.

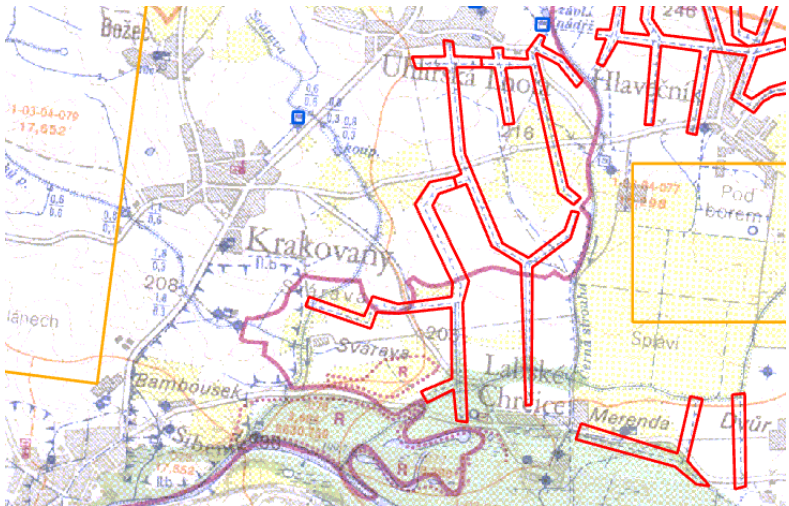
Pro účely digitalizace byly nejdůležitější linie symbolizující podzemní závlahová potrubí a symboly závlahových čerpacích stanic. Tyto linie se skládají z modré čárkované čáry, přičemž každá 3 až 5 čára obsahuje výstupěk. Směr výstupků se u závlahových potrubí nestřídá, nicméně jednotlivé čáry mají v podstatě libovolný zeměpisný směr výstupků, vždy však stále stejný po linii. Vzhledem k manuální tvorbě těchto map, se vyskytují různé délky mezer a čárek, různé šířky a mění se mírně i odstín použité modré barvy (Obr. 27). Čáry na jednom mapovém listě jsou si však vždy velmi podobné.



Obr. 27 Různá provedení čáry symbolizující závlahové potrubí

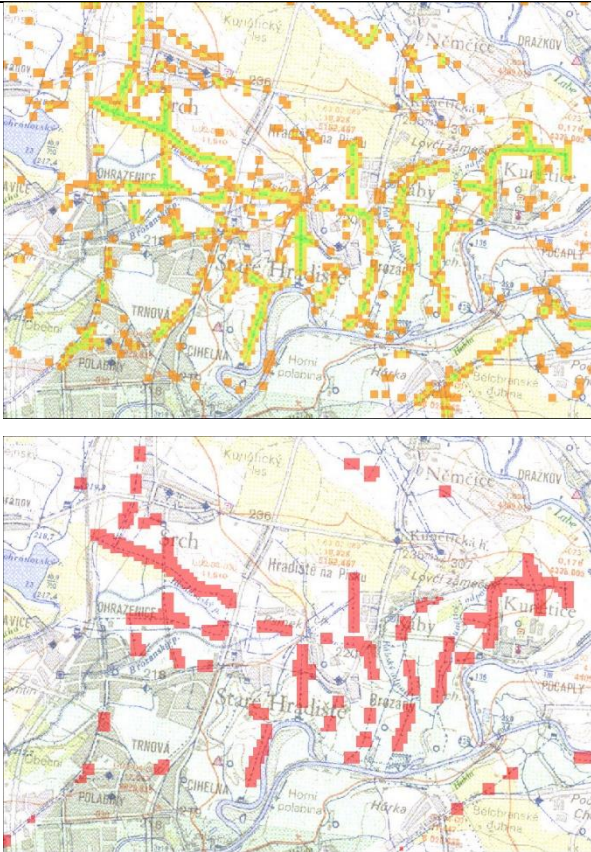
7.2.1 Postup

Tvorba tréninkových polygonů	Modelové tréninkové polygony byly ručně vytvořeny přes georeferencované listy ZVM. Byly vytvořeny tři tréninkové kategorie. Zavlažovaná plocha, Ostatní plocha a Čerpací stanice. Polygony závlahy kopíroval linii symbolizující řady zavlažovacích potrubí s malým odsazením, tvorba těchto polygonů byla jedním z časově
-------------------------------------	--

	<p>nejnáročnějších procesů. Polygony druhé třídy byly většinou tvořeny jako obdélníky v oblastech, kde nebylo závlahové vedení vizuálně detekováno, polygony čerpacích stanic obklopovaly symbol čerpací stanice.</p>  <p>Obr. 28 Ukázka polygonů jednotlivých klasifikovaných tříd. Červená – závlaha, modrá – čerpací stanice, oranžová – ostatní plocha</p>
Označování polygonů	Tréninkové polygony závlah mají hodnotu 1, čerpací stanice 8 a ostatní plocha 9.
Tvorba kompozitu	Vytvářet kompozit nebylo potřeba
Segmentace kompozitu a export snímků	Segmentace scén probíhala s výstupem do CSV souboru a JSON souborem pro uložení metadat.
Výpočet doplňkových vrstev	Doplňkové vrstvy nebyly vytvářeny
Délka hrany segmentu	Zvolená délka hrany segmentu byla 31 pixelů, což odpovídá 98,58 m. Díky posunu segmentu je však výsledná přesnost dvojnásobná, tedy 49,29 m. Tato velikost byla zvolena z důvodu velikosti symbolu čerpací stanice, takže se celý symbol vejde do jednoho segmentu. Větší velikost segmentu by snížila přesnost a tím by se zvýšilo riziko, že pole bez zavlažovacího potrubí budou považována za zavlažovaná.
Vzájemný posun segmentů	Bylo provedeno posunutí segmentačního okna o polovinu délky hrany segmentu v horizontálním směru, ve vertikálním směru i v obou směrech současně.
Uspořádání mozaiky	Mozaika obsahovala pouze jeden segment.

Poměry pro označení mozaiky	Prahové hodnoty pro příslušnost k jednotlivým třídám byly následující: segmenty ležící mimo mapový list 90 %, závlaha 25 %, ostatní 25 %, čerpací stanice 25 %.
Otočení a zrcadlení segmentu	Otočení a zrcadlení segmentu nebylo provedeno
CSV soubor	Pro běh klasifikačního modelu byla ukládána data do CSV souboru s příponou _log. Nicméně vzhledem k vysokému počtu listů se začali projevovat problémy s tímto typem uložení dat. Především docházelo ke ztrátě výsledků, a tedy narůstání času nutného ke klasifikaci z důvodu pádu modelu. Byly tedy hledány výhodnější metody uložení. Toto hledání vedlo k přechodu na SQLite databázi.
Model	<p>Původní klasifikační model je umělá neuronová síť určená k třídění barevných obrázků do dvou skupin. Tento model byl rozšířen o třetí kategorii a trénován na příslušných tréninkových datech. Tréninková data se načítají z jednotlivých adresářů, každý adresář obsahuje jednu třídu. Tato vstupní data jsou rozdělena na trénovací a validační část pro účely kalibrace modelu. Toto rozdělení bylo zvoleno na 20 %, tato hodnota se běžně používá.</p> <p>Během trénovací fáze modelu model načte dávky segmentů do vstupní vrstvy, klasifikuje ji a poté získá její úspěšnost. Velikost dávky modelu byla zvolena na 32 mozaik. V případě nízké úspěšnosti model změní váhy spojení jednotlivých vrstev uzlů v několika skrytých vrstvách a cyklus opakuje. Nakonec se model ověří na validačních datech.</p> <p>Jednotlivé mapové listy nepoužité pro trénování modelu byly klasifikovány trénovaným modelem. Načítání segmentů pro klasifikaci bylo řízeno pomocí CSV souboru, který obsahuje název segmentu, polohu segmentu na mapovém listu a zda je určen pro trénování či nikoliv. Hodnota pravděpodobnosti, se kterou jsou segmenty klasifikovány jako Závlaha, Čerpací stanice nebo Ostatní oblast, se pak přidá do tohoto CSV souboru a uloží se s koncovkou _log změněnou na _result. Tréninkové segmenty jsou vynechány a je jim přiřazena hodnota no_data. Tedy pouze tři nuly na konci řádku</p>

	<p>jsou nahrazeny pravděpodobnostmi příslušných tříd v desetinném formátu. Součet těchto pravděpodobností je roven jedné.</p> <p>Tento proces se opakuje pro každý klasifikovaný segment a několik tisíc segmentů pro každý mapový list. Tato část je časově nejnáročnější.</p>
Import zpět do ArcGIS	<p>CSV soubor byl načten zpět do prostředí ArcGIS pomocí importovacího Python skriptu. Skript otevře CSV soubor a vytvoří prázdnou matici podle informací o počtu řádků a sloupců v záhlaví CSV souboru. Dále je postupně pocházen celý CSV soubor a vytváří se klasifikovaná matice podle údajů v jednotlivých řádcích a příslušném sloupci. Poloha změněného segmentu rastru se odečte od hodnot souřadnic X a Y segmentu, hodnota segmentu je určena hodnotou pravděpodobnosti v příslušném sloupci. Klasifikovaná matice je poté převedena na rastr pomocí funkce <i>NumPyArrayToRaster</i>.</p>
Průměrování	<p>Vzájemným posunem segmentů vznikají z jednoho mapového listu čtyři klasifikované rastry. Výpočtem aritmetického průměru byl vytvořen rastr průměrných pravděpodobností. Během tohoto kroku byl rastr také převzorkován. Délka hrany pixelu nového rastru je 49,12 m, tj. polovina délky hrany klasifikačního segmentu.</p>
Filtrace	<p>Filtrování bylo provedeno pomocí skriptu Python. Tento skript nejprve vytvořil nový rastr s hodnotou 0. Následně byl filtrovaný závlahový rastr naskenován pixel po pixelu a analyzovány pixely nebo jejich bezprostřední okolí (okno 3x3 pixelů). Pokud byly splněny podmínky pro uvažování pixelu jako pixelu obsahujícího irigaci, byla do nového rastru zapsána hodnota 1.</p> <p>Prvním krokem filtrování bylo vynulování pixelů s hodnotou menší než 0,5. Dále byly izolované pixely vynulovány. Pokud měl pixel hodnotu větší než 0,5 a zároveň byl v sousedství pixelu s hodnotou větší než 0,5, byla do výsledného rastru zapsána hodnota 1. Pro pixely s hodnotou větší než 0,75 a jejich bezprostřední okolí byla výsledná rastrová hodnota 1 zapsána do filtrovaného rastru.</p>


	 <p>Obr. 29 Klasifikovaný rastr před filtrací (nahore) a po filtraci (dole).</p>
<p>Tvorba polygonů</p>	<p>Filtrovaný rastr byl převeden na polygon nástrojem <i>Raster to Polygon</i>. Následně byly vytvořeny kruhové Buffery s poloměrem 1000 m u všech polygonů s plochou větší než 30 000 m². Polygony s plochou menší než 30 000 m² a neležící uvnitř bufferů byly smazány. Tímto vznikla vrstva čítající přes 4700 polygonů. Vzniklé polygony byly označeny katastrem obce, na kterém se nacházely a následně byly podle označení katastru spojeny do multipartových polygonů.</p>
<p>Ruční čištění</p>	<p>Následovalo manuální procházení vrstvy polygonů od nejmenších polygonů dle velikosti a mazání v případě, že polygon neoznačil správně linie závlahového potrubí.</p> <p>Zde se projevila problém zaměnitelnosti závlahového a odpadního potrubí. Odpadní potrubí je symbolizováno stejným typem linie, pouze každý zhruba 5 dílec má opačnou orientaci. Dále byl špatně označen přivaděč pitné vody z ÚV Želivka, používající stejnou symbologii pouze zdvojenou.</p>



7.2.2 Výsledky

Modelem bylo vygenerováno celkem 23 658 174 segmentů včetně posunutých segmentů. Z toho bylo 136 309 použito na výcvik. Tréninkový soubor dat sestával ze 106 942 segmentů třídy Ostatní, 6 835 segmentů třídy čerpacích stanic a 22 532 segmentů třídy Závlaha. To znamená, že pro trénování modelu bylo použito méně než 1 % z celkového počtu segmentů. Natrénovaný model byl následně použit ke klasifikaci 23 521 865 segmentů.


Rozdělení tréninkového datasetu



Graf 12 Složení trénovacího datasetu

Po vytvoření klasifikovaných průměrovaných rastrů a jejich filtraci bylo dosaženo celkového počtu 344 615 závlahových pixelů. To je 83 724,36 ha. Tyto pixely byly převedeny na polygony a bylo vytvořeno celkem 4783 polygonů. Díky použitému nástroji *Rastr to Polygon* s možností zjednodušit polygon je plocha těchto polygonů pouze 77 524,61 ha. Bufferová filtrace snížila počet polygonů na rok

1962 o rozloze 58 617,46 ha. Následným ručním procházením a úpravou vzniklo 238 polygonů o rozloze 69 082,97 ha. Tento prudký pokles počtu polygonů vzniká spojením souvislých sítí polygonů a jejich sloučením do vícedílného prvku.



Graf 13 Změna počtu polygonů závlahy a příslušné plochy

7.3 Mapy Stabilního katastru

V rámci projektu *The impact of depopulation on ecosystem services in Europe. A pilot study in France, Czech Republic and Poland* (KU Leuven 2024) bylo nutné vytvořit hydrologický model povodí vodní nádrže Římov. Tento projekt předpokládá, že pokračující opouštění venkovské periferie otevírá jedinečné možnosti pro obnovu přírody a klade si za cíl prohloubit vědecké poznatky o důsledcích opouštění půdy. Vstupem do hydrologického modelu byl rekonstruovaný stav před poválečnými změnami ve využití území na základě dostupných map a leteckých snímků.

Cílem projektu je umožnit lépe pochopit souvislost mezi vylidňováním a změnou krajinného pokryvu a za další, zkoumat dopad pozorované změny krajinného pokryvu na vybrané ekosystémové služby. Jednou ze zvolených služeb je schopnost krajiny snížit špičkové průtoky v řekách. Z dlouhodobého hlediska má výzkum vést k tvorbě doporučení pro tvůrce politik na regionální, národní a evropské úrovni, jak zacházet s vylidňujícími se oblastmi, tak, aby se obnovily klíčové ekosystémové služby.

7.3.1 Císařské otisky stabilního katastru

Jedná se o barevné rastrové kopie tzv. císařských povinných otisků map stabilního katastru Čech. Jedná se o mapy z let 1826-1843, původně určené k archivaci v Centrálním archivu pozemkového katastru ve Vídni, odkud byly po vzniku Československé republiky v rámci archivní rozluky předány do Prahy. Na rozdíl od tzv. originálních map stabilního katastru zachycují původní stav krajiny bez dodatečného zákresu pozdějších změn. Otiskům pro území Čech připadá souřadnicový systém Gusterberg (Ferro). Mapa je v měřítku 1:2880.

Stabilní katastr měl představovat stálý seznam pozemků, které podléhaly pozemkové dani. Stabilní, jelikož se mělo jednat o trvalý registr. Počátek stabilního katastru byl dán dne 23. 12. 1817, kdy byl vydán rakouským císařem Františkem I. nejvyšší císařský patent o dani pozemkové a vyměření půdy. Pro nový katastr bylo zvoleno Cassini-Soldnerovo nekonformní transversální válcové zobrazení. Jako souřadnicový systém byl zvolen systém pravoúhlých souřadnic s různými počátky. Pro území Čech byl zvolen počátek v trigonometrickém bodě Gusterberg a pro území Moravy a Slezska v trigonometrickém bodě Svatý Štěpán. Základním měřítkem map bylo zvoleno měřítko 1:2 880. Toto měřítko vycházelo z požadavku, aby 1 dolnorakouské jitro (čtverec o straně 40 sáhů) bylo v mapě zobrazeno jako 1 čtvereční palec. Základem stabilního katastru byl přesný soupis veškeré půdy a její geodetické zaměření. Na území Čech probíhalo geodetické zaměření mezi léty 1826 a 1843. Na území Moravy a Slezska mezi léty 1824 a 1836. Všechny zaměřené pozemky byly zobrazeny a očíslovány. Výměra jednotlivých pozemků byla určena z mapy. Jelikož nebyl stabilní katastr systematicky doplňován, bylo nutné jej alespoň jednorázově doplnit. V letech 1869 až 1881 byla prováděna tzv. reambulace stabilního

katastru. Bohužel však tyto narychlo prováděné práce nespĺnily dřívější přesnost a kvalitu původních map. Došlo tedy k částečnému znehodnocení stabilního katastru.(Gruber 2016)

Císařské povinné otisky jsou barevné. Černou barvou jsou v mapě vyobrazeny administrativní hranice (krajské, okresní, obecní atd.), hranice nemovitostí, hranice pozemků, názvy obcí, pomístní názvy, parcelní čísla stavebních parcel a mnoho jiných objektů. Červenou barvou jsou v mapě vyznačeny parcelní čísla nestavebních parcel. Dále má každý pozemek přiřazenou určitou barvu podle, které lze dobře rozpoznat druh využití pozemku. Pro lepší názornost budou jednotlivé barvy a jejich příslušnost ke druhu využití podrobněji rozepsány. Mapa zahrnuje následující barvy:

- modrá barva – jezera, rybníky, řeky, potoky,
- zelená barva – louky (suché, mokré, s ovocnými sady),
- tmavě zelená barva – zahrady (ovocné, zelinářské),
- světle zelená barva – pastviny,
- světle hnědá barva – pole (role), chmelnice,
- tmavě růžová barva – významné budovy,
- růžová barva – budovy zděné (nespalné),
- žlutá barva – budovy dřevěné (roubené, spalné),
- šedá barva – lesy.

Jednotlivé barvy jsou dále doplněny mapovými značkami. Je tedy možné rozeznat např. jehličnatý les od listnatého nebo sad s ovocnými stromy od vinice. Mapa je dále doplněna dalšími mapovými značkami a liniemi, které podrobně vystihují přilehlý terén. Lze rozeznat např. kříž, milník, mlýn, studnu a další. Povinné císařské otisky jsou zobrazeny na obrázku Obr. 31.

Velikost pixelu dostupných scén byla 0,459 m. Jednalo se o třípásmové rastry s pásmy R, G a B.




Obr. 31 Ukázka map Povinných císařských otisků

7.3.2 Postup

Tvorba tréninkových polygonů	Modelové tréninkové polygony byly ručně vytvořeny přes připojené WMS Císařských otisků. Bylo vytvořeno pět tréninkových kategorií. Zastavěné území (Urban), orná půda (Arable), les (Forest), vodní plochy (Water) a louky (Meadow). Polygony zastavěného území opisovala symboly měst či obcí, tvorba těchto polygonů byla jedním z časově nejnáročnějších procesů. To bylo způsobeno snahou přesně kopírovat hranici zastavěného území a okolní orné půdy či luk. Polygony ostatních tříd byly většinou tvořeny jako obdélníky v oblastech, kde se příslušná symbologie vyskytovala.
-------------------------------------	--

<p>Rozložení na listy</p>	<p>Zájmové území je příliš velké, aby bylo převedeno na jednu matici. Bylo tedy přikročeno k rozložení na jednotlivé listy. K tomu byl použit nástroj <i>Create Fishnet</i>. Byly tak vytvořeny 4 základní listy a několik doplňkových listů pro okrajové partie zájmového území. Tyto listy pak byly individuálně segmentovány.</p>	

Obr. 32 Kalibrační polygony jednotlivých tříd. Urban – fialová, Arable – hnědá, Forest – zelená, Water – modrá, Meadow – tyrkysová



Obr. 33 Rozložení mapy na jednotlivé listy


Označování polygonů Orná půda (Arable) - 1, les (Forest) - 2, louky (Meadow) – 3, zastavěné území (Urban) – 4 a vodní plochy (Water) - 9.

Tvorba kompozitu Vytvářet kompozit nebylo potřeba

Segmentace kompozitu a export snímků Segmentace listů byla provedena pomocí stejného segmentačního skriptu jako ZVM. Segmentační skript byl doplněn o další dvě kategorie, a všechny kategorie byly příslušně přejmenovány tak, aby odpovídaly klasifikovaným třídám.

Třída	Počet segmentů	Poměr
Arable	6 368	21 %
Forest	19 360	63 %
Meadow	2 589	8 %
Urban	1 183	4 %
Water	1 425	5 %
Training polygons	30 925	100 %
Others	3 722 690	

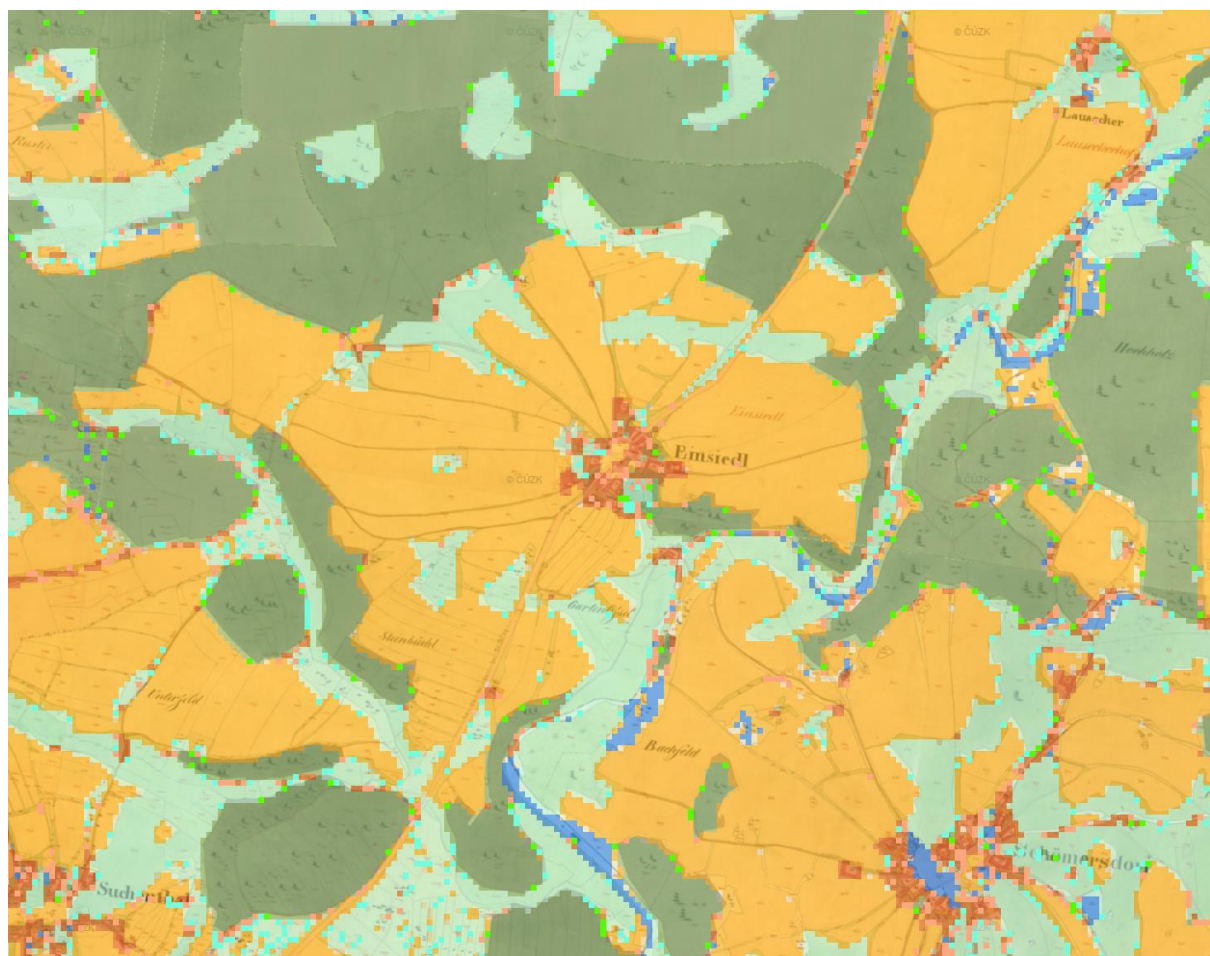
Tab. 11 Počet segmentů a jejich zastoupení pro mapy Povinných císařských otisků

	<p style="text-align: center;">Mapy Stabilního katastru</p>  <p style="text-align: center;"><i>Graf 14 Poměr vytvořených segmentů pro mapy Povinných císařských otisků</i></p>
Výpočet doplňkových vrstev	Byla vytvořena pouze doplňková vrstva odstínů šedi.
Délka hrany segmentu	Zvolená délka hrany segmentu byla 51 pixelů, což odpovídá 25,908 m a po zprůměrování 12,954 m. Tato velikost byla zvolena z důvodu dalšího použití pro tvorbu hydrologických modelů.
Vzájemný posun segmentů	Byl proveden posun v horizontálním směru, ve vertikálním směru, i v obou směrech současně.
Uspořádání mozaiky	Výsledná mozaika se skládala ze čtyř segmentovaných vrstev v pořadí červená, zelená, modrá a odstíny šedi.
Poměry pro označení mozaiky	Prahové hodnoty pro příslušnost k jednotlivým třídám byly následující: segmenty ležící mimo mapový list 90 %, všechny klasifikované kategorie 25 %.
Otočení a zrcadlení segmentu	Otočení a zrcadlení segmentu nebylo provedeno.
CSV soubor	Segmentační skript postupně exportoval všechny mozaiky ve formátu JPG do příslušných adresářů. Stejně jako u segmentačního skriptu byly adresáře přejmenovány a doplněny, tak aby vše odpovídalo klasifikovaným třídám. Segmenty, které neobsahují trénovací polygony, byly ukládány do adresáře Others, který se nacházel v kořenové složce. Vzhledem k značnému počtu segmentů, který

	převyšoval maximální počet souborů uložitelných do složky, bylo vytvořeno několik složek Others, s příponami _0 až _5.
Model	Byl použit identický model jako ke klasifikaci ZVM. Model byl upraven vzhledem ke zvýšenému množství klasifikovaných tříd změnou Python listu <code>class_names</code> . <pre>class_names = ['Arable', 'Forest', 'Meadow', 'Urban', 'Water']</pre> To vyvolalo požadavek upravit i klasifikační skript. Klasifikační skript byl doplněn o zápis do příslušných sloupců v CSV souboru.
Import zpět do ArcGIS	CSV soubor byl načten zpět do prostředí ArcGIS pomocí importovacího Python skriptu. Skript otevře CSV soubor a vytvoří prázdnou matici podle informací o počtu řádků a sloupců v záhlaví CSV souboru. Dále je postupně pocházen celý CSV soubor a vytváří se klasifikovaná matice podle údajů v jednotlivých řádcích a příslušném sloupci. Poloha změněného segmentu rastru se odečte od hodnot souřadnic X a Y segmentu, hodnota segmentu je určena hodnotou pravděpodobnosti v příslušném sloupci. Klasifikovaná matice je poté převedena na rastr pomocí funkce <code>NumPyArrayToRaster</code> . CSV byl načten zpět do prostředí GIS pomocí Python skriptu použitého pro digitalizaci ZVM. Skript byl pouze doplněn o více klasifikačních kategorií.
Průměrování	Vzájemným posunem segmentů vznikají z jednoho mapového listu čtyři klasifikované rastry. Výpočtem aritmetického průměru byl vytvořen rastr průměrných pravděpodobností. Během tohoto kroku byl také rastr převzorkován. Délka hrany pixelu nového rastru byla 12,954 m, tj. polovina délky hrany klasifikačního segmentu.
Filtrace	Filtrace nebyla provedena
Spojení	Výsledné klasifikované rastry pro všechny listy byly spojeny pomocí nástroje <i>Mosaic To New Raster</i> . Bylo tak vytvořeno 5 rastrů, jeden pro každou klasifikovanou skupinu. Rozměr pixelu jednotlivých rastrů je 12,954 m. Rozsah hodnot rastrů je od 0 do 1. Hodnota představuje pravděpodobnost, s jakou příslušný pixel patří do dané skupiny.

7.3.3 Výsledky

U výsledných rastrů nebyla provedena filtrace a posouzení. Pro další analýzy byl použit threshold 0,5, kdy pixely překračující tuto hodnotu byly použity pro tvorbu finální Land Use vrstvy. Vzniklé bezešvé Land Use vrstvy posloužily pro tvorbu hydrologických modelů historického stavu povodí (viz Obr. 34).



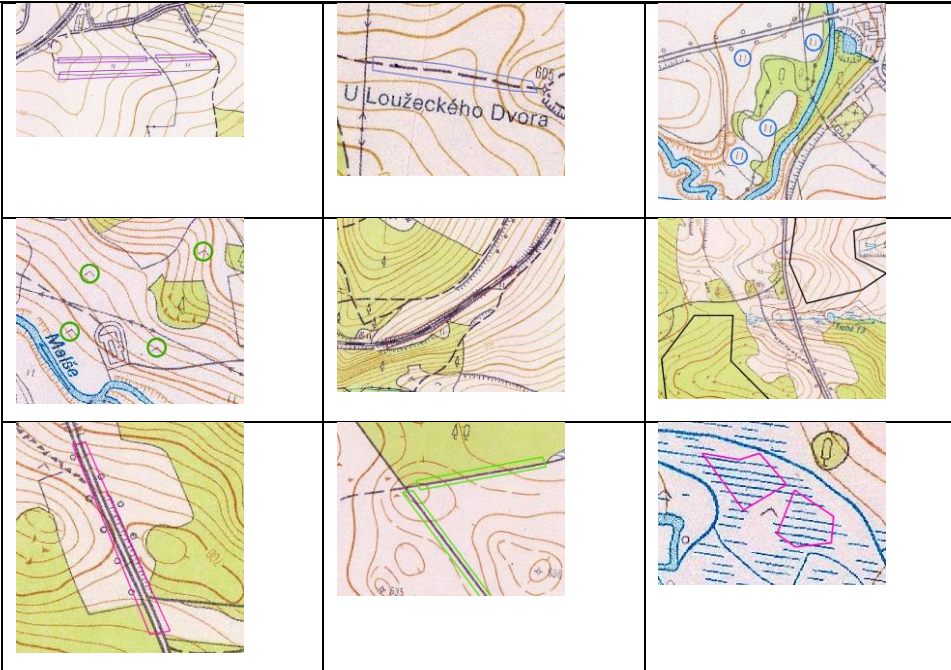
Obr. 34 Ukázka klasifikovaného listu map Povinných císařských otisků

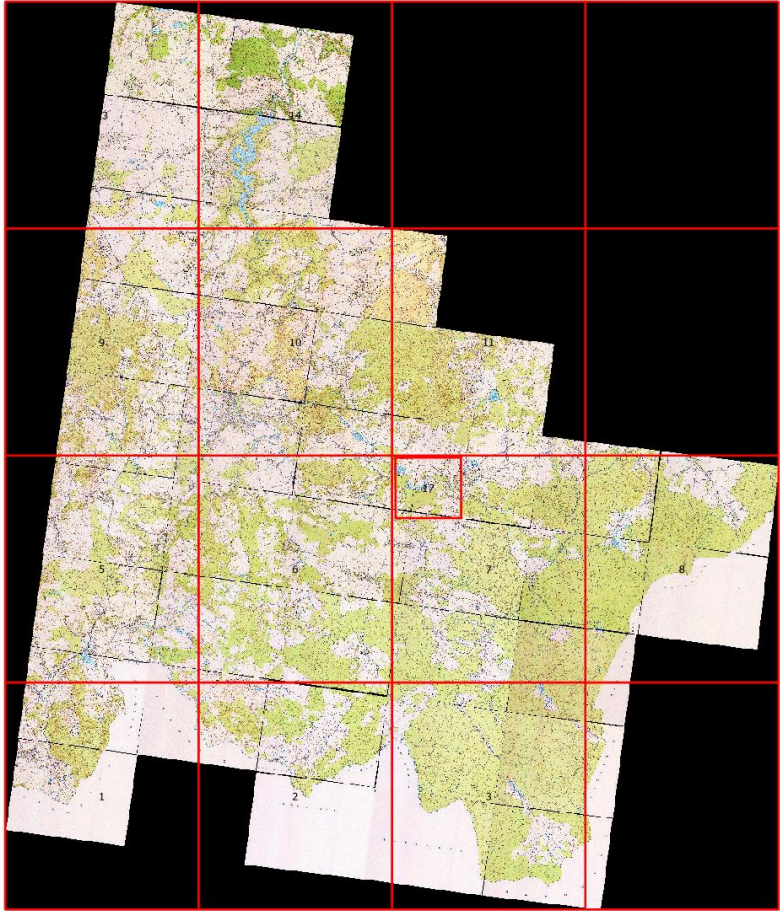
7.4 Základní mapy z 80. let

V rámci digitalizace Základní mapy z 80. let byl vyzkoušen přístup s použitím více velikostí segmentu. Velikost pixelu skenů map byla 0,459 m. Byly vytvořeny tři modely s různou velikostí segmentu, a to 25, 35 a 45 pixelů. Odpovídající přibližně 22, 30 a 40 m a 11, 15 a 20 m po zprůměrování. Threshold pro všechny modely byl zvolen 40 %.

7.4.1 Postup

<p>Tvorba tréninkových polygonů</p>	<p>Modelové tréninkové polygony byly ručně vytvořeny nad rastrovými listy mapy z 80. let. Bylo vytvořeno devět tréninkových kategorií. Třída Boundaries označovala linie dělící jednotlivé kultury, na mapě symbolizována tenkou černou plnou čarou. Třída Dashed Roads označovala polní a lesní nezpevněné cesty, na mapě symbolizována tenkou čárkovanou černou čarou. Třída DashedRoads označovala polní a lesní nezpevněné cesty, na mapě symbolizována tenkou čárkovanou černou čarou. Třída Meadow označovala louky, na mapě symbolizována dvěma svislými tenkými černými čarami. Třída Pasture označovala pastviny, na mapě symbolizována stříškou tenkou černou čarou. Třída Railway označovala železnici, na mapě symbolizována dvojitou černou čarou s pravidelnými černými segmenty. Třída Rest označovala plochy lesa nebo orné půdy bez linií komunikací a symbolů využití území. Třída Roads označovala hlavní silnice, na mapě symbolizována dvojitou tenkou plnou černou čarou. Třída Small Roads označovala polní a lesní zpevněné cesty, na mapě symbolizována tenkou plnou černou čarou. Třída Wetland označovala bažiny a mokřady, na mapě symbolizována horizontální čárkovanou modrou šrafou.</p>
--	---

	 <p data-bbox="421 860 1375 972"><i>Obr. 35 Ukázka tříd a kalibračních polygonů Mapy z 80.tých let. Kalibrační polygony jednotlivých tříd. Od levého horního rohu postupně: Boundaries, Dashed Roads, Meadow, Pasture, Railway, Rest, Roads, Small Roads, Wetland</i></p>
<p>Rozložení na listy</p>	<p>Zájmové území je příliš velké, aby bylo převedeno na jednu matici. Bylo tedy přikročeno k rozložení na jednotlivé listy. K tomu byl použit nástroj <i>Create Fishnet</i>. Bylo tak vytvořeno 13 listů. Pro prvotní odladění modelu byl vytvořen jeden pomocný zmenšený list. Tyto listy pak byly individuálně segmentovány.</p>

	 <p>Obr. 36 Rozdělení Mapy z 80. let na jednotlivé listy</p>
<p>Označování polygonů</p>	<p>Boundaries - 1, Dashed Roads - 2, Meadow - 3, Pasture - 4, Railway - 6, Roads - 7, Small Roads - 8, Wetland – 9, Rest - 10</p>
<p>Tvorba kompozitu</p>	<p>Vytvářet kompozit nebylo potřeba</p>
<p>Segmentace kompozitu a export snímků</p>	<p>Segmentace listů byla provedena pomocí stejného segmentačního skriptu jako ZVM.</p>
<p>Výpočet doplňkových vrstev</p>	<p>Byl proveden pouze výpočet vrstvy odstíny šedi.</p>
<p>Délka hrany segmentu</p>	<p>Zvolená délka hrany segmentu byla 25, 35 a 45 pixelů, což odpovídá 22,958 m, 32,141 m a 41,324 m a po zprůměrování 11,478 m, 16,07 m a 20,662 m. Tyto velikosti byly zvoleny z důvodu dalšího použití pro tvorbu hydrologických modelů, a potřeby posoudit použití více velikostí segmentů pro klasifikaci.</p>

Vzájemný posun segmentů	Byl proveden posun segmentu v horizontálním směru, ve vertikálním směru, i v obou směrech současně. Pro všechny zvolené velikosti hran segmentu.
Uspořádání mozaiky	Výsledná mozaika se skládala ze čtyř segmentovaných vrstev v pořadí R, G, B a odstíny šedi.
Poměry pro označení mozaiky	Prahová hodnota pro příslušnost k jednotlivým třídám byla zvolena 40 % a pro segmenty ležící mimo mapový list 90 %. Ostatní nastavení exportu segmentů zůstalo stejné.
Otočení a zrcadlení segmentu	Otočení a zrcadlení segmentu nebylo provedeno.
DB soubor	<p>Nevýhodou ukládání dat do souboru typu CSV je riziko ztráty dat při pádu klasifikačního skriptu. Toto bylo vyřešeno přechodem ze souboru CSV na SQLite databázi. Pro účely klasifikace Základní mapy z 80. let tak bylo přikročeno k úpravě segmentačního skriptu tak aby se data ukládala do SQLite databáze. Přičemž vzniká jedna databáze pro každý segmentovaný list.</p> <p>Segmentační skript postupně exportoval všechny mozaiky ve formátu JPG do příslušných adresářů. Stejně jako u segmentačního skriptu byly adresáře přejmenovány a doplněny, tak aby vše odpovídalo klasifikovaným třídám. Segmenty, které neobsahují trénovací polygony, byly ukládány do adresáře Others, který se nacházel v kořenové složce. Vzhledem k značnému počtu segmentů, který převyšoval maximální počet souborů uložitelných do složky, bylo vytvořeno několik složek Others, s příponami _0 až _4.</p>
Model	<p>Byl použit upravený model jako ke klasifikaci ZVM. Model byl upraven vzhledem ke zvýšenému množství klasifikovaných tříd změnou listu class_names a uložení dat v databázi.</p> <pre>class_names = ['Meadow', 'Boundaries', 'Wetland', 'Rest', 'DashedRoads', 'Pasture', 'Railway', 'Roads', 'SmallRoads,']</pre> <p>To vyvolalo požadavek upravit i klasifikační skript. Klasifikační skript byl doplněn o zápis do příslušných sloupců v databázi a o načítání dat z databáze. Načítání dat z databáze umožňuje načíst pouze data vhodná ke klasifikaci. Lze tedy přeskočit načítání trénovacích dat, a v případě pádu klasifikačního skriptu, lze jednoduše načíst pouze zbývající ještě neklasifikovaná data.</p>

Import zpět do ArcGIS	Databáze byla načtena zpět do prostředí ArcGIS pomocí upraveného Python skriptu použitého pro digitalizaci ZVM. Skript byl pouze doplněn o více klasifikačních kategorií.
Průměrování	Vzájemným posunem segmentů vznikají z jednoho mapového listu čtyři klasifikované rastry. Výpočtem aritmetického průměru byl vytvořen rastr průměrných pravděpodobností. Během tohoto kroku je také rastr převzorkován. Délka hrany pixelu nového rastru je 11,478 m, 16,07 m a 20,662 m, tj. polovina délky hrany klasifikačních segmentů.
Filtrace	Filtrování bylo provedeno pomocí skriptu Python. Tento skript nejprve vytvořil nový rastr s hodnotou 0. Následně byl filtrovaný závlahový rastr naskenován pixel po pixelu a analyzovány pixely nebo jejich bezprostřední okolí (okno 3x3 pixelů). Pokud byly splněny podmínky pro uvažování pixelu jako pixelu obsahujícího posuzovanou třídu, byla do nového rastru zapsána hodnota 1. Prvním krokem filtrování bylo vynulování pixelů s hodnotou menší než 0,8. Dále byly izolované pixely vynulovány. Pokud měl pixel hodnotu větší než 0,8 a zároveň byl v sousedství pixelu s hodnotou větší než 0,85, byla do výsledného rastru zapsána hodnota 1. Pro pixely s hodnotou větší než 0,95 a jejich bezprostřední okolí byla výsledná rastrová hodnota 1 zapsána do filtrovaného rastru.
Spojení	Výsledné klasifikované rastry pro všechny listy byly spojeny pomocí nástroje <i>Mosaic To New Raster</i> . Bylo tak vytvořeno 5 rastrů, jeden pro každou klasifikovanou skupinu. Rozměr pixelu jednotlivých rastrů je 11,478 m, 16,07 m a 20,662 m. Rozsah hodnot rastrů je 0 nebo 1. Hodnota představuje finální zatřídění příslušných pixelů do dané skupiny.

Segmentační skript byl doplněn o dalších šest kategorií, a všechny kategorie byly příslušně přejmenovány tak, aby odpovídaly klasifikovaným třídám. Na mapě tak bylo určováno celkem 9 tříd.

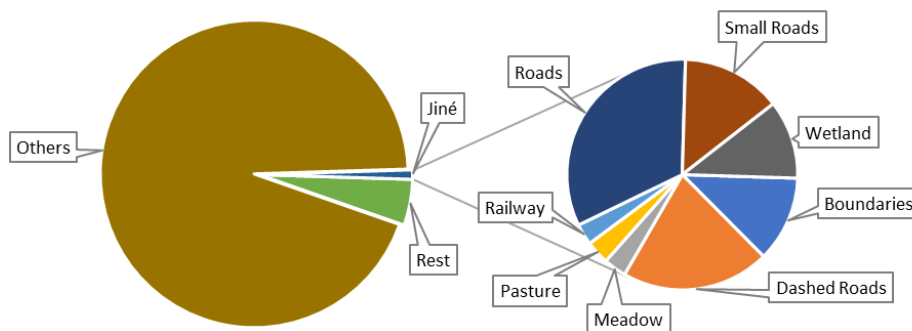
Třída	Model_001	Model_002	Model_003
Boundaries	6 207	3 022	780
Dashed Roads	10 696	5 299	1 187
Meadow	1 634	687	0
Pasture	1 702	705	3
Railway	1 529	812	265
Rest	252 077	1 9311	75 618
Roads	16 804	8 835	2 733
Small Roads	7 209	3 458	547
Wetland	5 675	2 924	1 374
Others	4 906 764	2 504 247	1 525 307

Tab. 12 Počty trénovacích segmentů pro jednotlivé modely Mapy z 80. let

Třída	Model_001	Model_002	Model_003
Boundaries	100 %	49 %	13 %
Dashed Roads	100 %	50 %	11 %
Meadow	100 %	42 %	0 %
Pasture	100 %	41 %	0 %
Railway	100 %	53 %	17 %
Rest	100 %	8 %	30 %
Roads	100 %	53 %	16 %
Small Roads	100 %	48 %	8 %
Wetland	100 %	52 %	24 %
Others	100 %	51 %	31 %

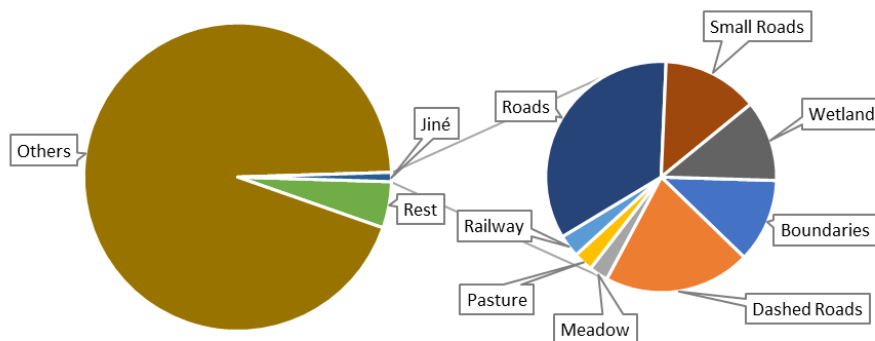
Tab. 13 Poměry trénovacích segmentů vzhledem k modelům Mapy z 80. let

Model_001



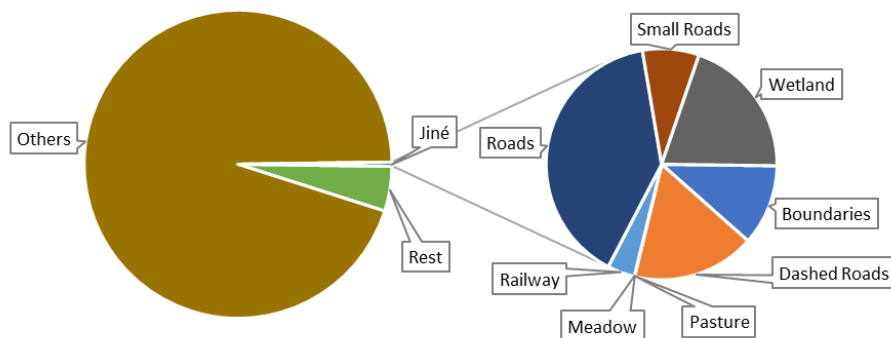
Graf 15 Zastoupení jednotlivých tříd segmentů pro Model_001

Model_002



Graf 16 Zastoupení jednotlivých tříd segmentů pro Model_002

Model_003




Graf 17 Zastoupení jednotlivých tříd segmentů pro Model_003

7.4.2 Výsledky

Shoda modelů

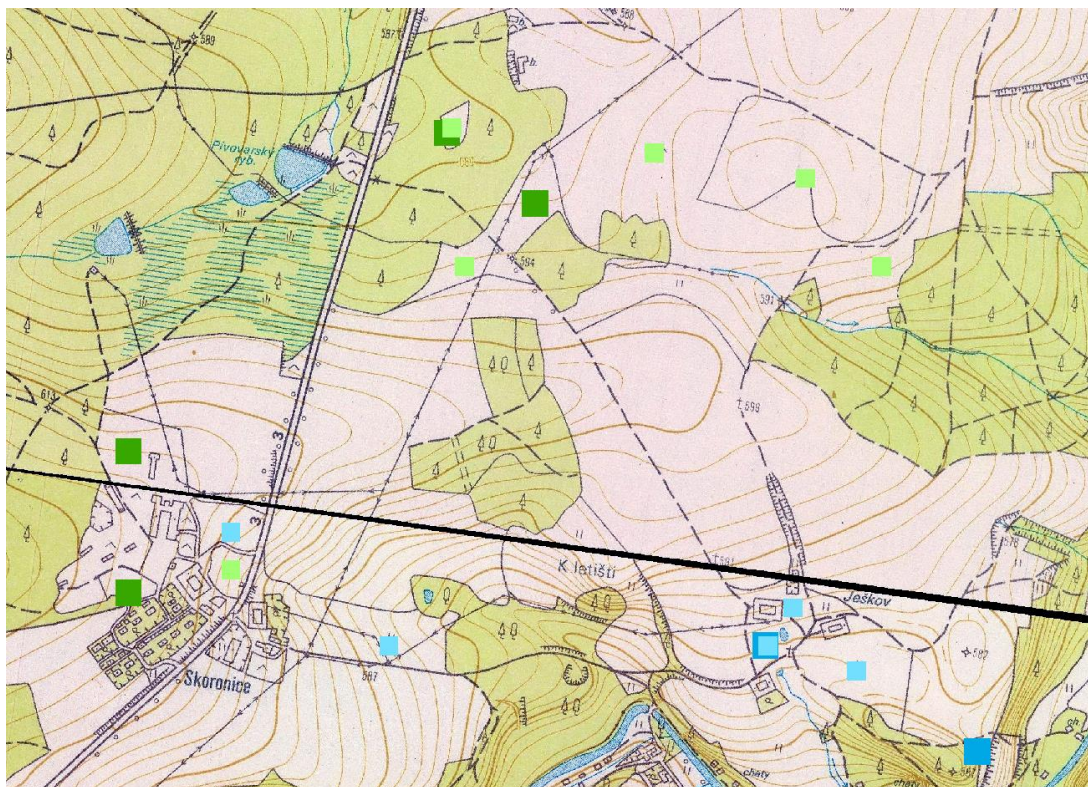
Základním výsledkem analýzy více modelů s různou velikostí segmentu je jejich vzájemný překryv. Překrývají-li se zatřížené segmenty stejné kategorie u více modelů, svědčí to o správnosti zatřídění určité kategorie. Tohoto může být využito při rozhodování o volbě finální kategorie, při tvorbě výsledné bezešvé mapy.



Obr. 37 Světle písková – Roads (Model_001), Písková – Roads (Model_002), Oranžová – Roads (Model_003)

Komplementarita modelů


Úspěšnost identifikace je různá pro různé rozměry segmentu. Případně jsou symboly neurčené jedním modelem určeny jiným modelem, úspěšnost klasifikace se tak zvýší kombinací výsledků více modelů. Toto se projevilo především při určování bodových symbolů – Pastures, Meadows.



Obr. 38 Světle zelená – Pastures (model_001), Tmavě zelená – Pastures (model_002), Světle modrá – Meadows (model_001), Tmavě modrá – Meadows (model_002)

Rozlišení modelu

Menší rozměr segmentu zvyšuje rozlišení modelu, to je jasně patrné na porovnání výsledků pro kategorii Rest. Model_001 s rozměrem segmentu zhruba 11 m po zprůměrování a filtraci kopíruje nejpřesněji ostatní vyskytující se kategorie modelu.



Obr. 39 Rozlišení jednotlivých modelů. Zleva – Model_001, Model_002, Model_003

8 Diskuse

8.1 Výběr použitých metod

Při výběru vhodných metod digitalizace projevů erozního poškození půd za účelem Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země byl brán ohled na standardně využívané metody při podobných aplikacích. Za základní metodu je považována manuální digitalizace. Tato metoda se stala standardním procesem získávání erozních dat a obecně se na ni dá spoléhat jako na referenční metodu pro porovnání s dalšími metodami (Báčová et al. 2019).

Metody strojového učení dlouhodobě vychází ze srovnatelných metod (manuální digitalizace, filtry, klasifikace jednotlivých pixelů) jako nejlepší volba z hlediska poměru kvality výsledných dat, proveditelnosti, časové a materiální náročnosti. (Malinowski et al. 2023) dokázala, že s využitím strojového učení lze dosáhnout kvalitativně velmi blízkých dat jako v případě využití manuální digitalizace, avšak s výhodou menší časové i finanční náročnosti. Se stejným závěrem pracovala i studie od (Padarian, Minasny, and McBratney 2020). Porovnání různých metod digitalizace podobného provedl například (Rasam 2021), který metody strojového učení označil za srovnatelné z hlediska přesnosti a kvality dat v porovnání s manuální digitalizací, avšak pouze s přibližně desetinovými finančními náklady. Ke stejnému závěru ohledně srovnatelnosti obou metod dospěla i studie od (Zatelli, Gabellieri, and Besana 2022). Zřejmá nevýhoda digitalizace projevů erozního poškození půd je fakt, že pomocí ní lze odhadovat pouze kumulativní poškození vztahující se ke stavu po erozní události. V případě dešťových simulátorů se však začínají vyskytovat první studie snažící se eliminovat tuto nevýhodu, pomocí snímání povrchu několika různými kamerami nahrazující jednotlivé pozice při snímání jedním přístrojem. Tímto způsobem byla provedena například studie od (Eltner et al. 2017), která za využití 3 fotoaparátů získala ortofoto scény v časovém kroku 10 a 15 vteřin během simulace s dešťovým simulátorem i pomocí přirozené srážky. Nicméně vzhledem k použité technologii bylo zjištěno, že stojící či tekoucí voda v povrchových depresích způsobuje značné problémy při finálním vyhodnocení dat.

Obecně však lze konstatovat, že na základě výše zmíněných studií lze strojové učení považovat za velmi vhodnou metodu pro digitalizaci erozního poškození na datech získaných bezkontaktním způsobem s dostatečně kvalitními výsledky a s dobrým poměrem časové, materiální a tím i finanční náročnosti.

8.2 Výsledky experimentálních aplikací

Porovnání výsledků jednotlivých modelů experimentální aplikace na satelitních snímcích ukázalo, že Model_001 a Model_002 mají téměř identické výsledky i přesto, že Model_002 používá 4 další vrstvy. Jedná se o vrstvu grayscale a 3 typy Canny Edge zvýrazněných linií. Oba modely mají stejnou

velikost segmentu 16 pixelů. Model_003 však vykazuje mnohem více heterogenní výsledky, hlavním rozdílem je velikost segmentu 10 pixelů.

Výsledky analýzy validačních polygonů scén pro Model_001 ukazují bezpilotních prostředků ukazují vysokou úspěšnost pro kategorii Bez poškození (NoRill). Model_001, Model_002 a Model_006 mají vyšší úspěšnost, 9 ze 14 testovaných ploch překročilo hodnotu 90 % úspěšnosti pro tuto kategorii. Model_005 má nižší úspěšnost, pouze 5 ze 14 testovaných ploch překročilo hodnotu 90%. Výsledky analýzy validačních polygonů scén z bezpilotních prostředků ukazují nízkou úspěšnost v kategorii Plošné poškození (Sheet). Úspěšnost 90 % přesahují 90 % úspěšnosti pouze 2 scény. U kategorie Rýhové poškození (Rill) má jedna scéna úspěšnost vyšší než 90 % a jedna scéna této hranici téměř dosahuje.

Graf porovnávající hodnoty diagonál validačních matic scén pro Model_002 ukazuje vysokou úspěšnost pro kategorii Bez poškození (NoRill). 9 za 14 testovaných ploch překročilo hodnotu 90 % úspěšnosti u Model_001. Model_002 a Model_005 překonává 90 % úspěšnost pouze jedna scéna. U Model_006 překonávají 90% úspěšnost dvě scény. U kategorie Rýhové poškození (Rill) pro Model_001, Model_002 a Model_006 má pouze jedna scéna úspěšnost vyšší 90 %. Pro Model_005 žádná scéna nepřekračuje úspěšnost 90 %.

Snímky plochy před experimentem z dešťového simulátoru na lokalitě jirkov, by měly být zcela označeny za neporušenou půdu. Toto je do značné míry splněno, nacházejí se zde však plochy označené jak za plošné poškození, tak rýhové poškození. Snímky plochy po první části experimentu ukazují zmenšenou plochu bez poškození vytvořenými rýhami, přibývá plocha, kde je pravděpodobnost výskytu půdy bez poškození velmi nízká (<25 %). Ve střední části ploch je vidět jasné označení rýhového poškození modelem. Je vidět nově vytvořená stromová struktura rýhového poškození. Nicméně vyskytují se plochy nesprávně zatříděné do jedné nebo druhé třídy. Snímek ploch po druhé části experimentu ukazují významně zmenšenou plochu bez poškození. Významně přibyla oblast označená za plochu s plošným poškozením. Je vidět nově vytvořená stromová struktura rýhového poškození. Nesprávně zatříděné plochy se téměř nevyskytují.

Obecně se na scénách z dešťového simulátoru na lokalitě jirkov ukazuje potenciál modelu pro zatřídění erozního poškození na plochách experimentálního srážkového simulátoru. Úspěšnost je nejvyšší u třídy bez poškození, která má nejvíce dostupných tréninkových dat, třída plošné poškození se vyskytuje pouze ve specifických případech. Třída rýhové poškození vytváří spojitou charakteristickou stromovou strukturu.

Citlivostní analýza modelů pro Laboratorní dešťový simulátor poskytla nejvíce dat, a tedy i nejvíce robustní výsledky. Nejlepších výsledků dosahuje třída Bez poškození (NoRill) téměř u všech modelů, a tedy i velikostí a počtu segmentů. Další úspěšnou skupinou je Plošné poškození (Sheet). Především u

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země

modelů 5 až 8, s velikostí segmentu 75 pixelů je konzistentní úspěšnost s maximem až 90 % u modelu 007. Nejhorších výsledků je dosaženo u třídy Rýhové poškození (Rill). Zde převládá třída 0 – 10 %. Většina ploch tedy byla úspěšně zatříděna pouze z méně než 10 %. Nejlepších výsledků tak dosahují modely 005 a 010, u kterých 30 % ploch bylo zatříděno s více než 90% úspěšností.

Neukázala se jasná závislost úspěšnosti klasifikace na velikosti segmentu. Třídy Bez poškození a Plošné poškození soustavně vykazují vysokou úspěšnost, a to při všech velikostech segmentu, přičemž o málo úspěšnější se zdají být modely s velikostí segmentu 75 pixelů. Třída Rýhové poškození trvale vykazuje nižší úspěšnost s maximy pod 60 %. U některých modelů však nedosahuje ani 10 % a vykazuje značnou variabilitu.

Ukazuje se mírná závislost úspěšnosti na počtu trénovacích segmentů. Tato závislost se ukazuje především u třídy Rýhové poškození. Od dosažení určitého počtu segmentů úspěšnost výrazně neroste. Tato hranice je zhruba 10 000 segmentů pro třídu.

Porovnání úspěšnosti jednotlivých modelů pro Laboratorní dešťový simulátor ukazuje, že nelze zvolit optimální velikost segmentu pro klasifikaci všech tříd. Jednotlivé klasifikované jevy mají různou prostorovou velikost a vztah této velikosti jevu a velikosti segmentu napomáhá úspěšnosti klasifikace. Nejlepších výsledků dosahuje velikost segmentu 75 pixelů, která odpovídá 3,5 cm po zprůměrování posunutých segmentů. Nejmenší velikost segmentu 50 pixelů odpovídající 2,5 cm po zprůměrování posunutých segmentů vykazuje nejhorší výsledky. Velikost segmentu 100 pixelů odpovídající 5 cm po zprůměrování posunutých segmentů má střední úspěšnost. Ideální cestou se tak jeví kombinace výsledků více modelů s různou velikostí segmentu. Tento přístup ale vyžaduje metodu, jak rozhodnout o syntéze výsledků modelů do finálního klasifikovaného rastru.

Analýza zpracování map více modely s různou velikostí segmentu poskytla informace o vzájemném působení výsledků. Překrývají-li se zatříděné segmenty stejné kategorie u více modelů, svědčí to o správnosti zatřídění určité kategorie. Tohoto může být využito při rozhodování o volbě finální kategorie, při tvorbě výsledné bežešvé mapy. Případně jsou symboly neurčené jedním modelem určeny jiným modelem, úspěšnost klasifikace se tak zvýší kombinací výsledků více modelů. Toto se projevilo především při určování bodových symbolů. Analýza mapových děl zároveň prokázala nutnost dostatečně pestrého tréninkového datasetu. Odstíny stejných mapových kategorií se mohou lišit na různých mapových listech, v případě Map stabilního katastru nebyl list s odlišnou barevností dostatečně reprezentován v tréninkovém datasetu, což vyústilo ve značnou chybovost klasifikace.

Menší rozměr segmentu zvyšuje rozlišení modelu, to je jasně patrné na porovnání výsledků pro kategorii Rest. Model_001 s rozměrem segmentu zhruba 11 m po zprůměrování a filtraci kopíruje nejpřesněji ostatní vyskytující se kategorie modelu.

8.3 Výhody a nevýhody modelu

Vytvořený model prokazuje vysokou přesnost, což je charakteristický rys neuronových sítí. V procesu segmentace je schopen účinně odstranit šum a nepodstatné informace ze vstupních dat, poskytujíc tak robustní základ pro celkovou funkčnost modelu. Omezení spočívající v nedostatku uspokojivě označených tréninkových dat omezuje jeho aplikaci na identifikaci některých konkrétních tříd, což je v kontextu jeho využití klíčovým faktorem. V praxi je model efektivní především díky schopnosti zpracovávat menší dávky dat pomocí segmentace. Tato strategie nejenže výrazně snižuje nároky na výpočetní zdroje, ale též umožňuje použití modelu na běžných počítačích, což představuje praktický benefit v porovnání s náročnějšími výpočetními stanicemi.

Odpovědět na konkrétní potřeby používání modelu v daném kontextu závisí na specifikách řešeného problému a kvalitě dostupných vstupních dat. V případě, že se model používá pro identifikaci některých tříd nebo objektů, kde jsou k dispozici dostatečná označená tréninková data, jeho vysoká přesnost a efektivnost při zpracování dat mohou být výhodami. Naopak v situacích, kdy dochází k aplikaci modelu na data s nízkou specifičností tréninkových dat, je třeba s přístupovat k jeho využití s opatrností. Zhodnocení skutečné účinnosti modelu v praxi je vždy závislé na konkrétních podmínkách a požadavcích dané aplikace.

Hlavní nevýhodou modelu, která byla identifikována, je nutnost velkého označeného datového souboru. Pro trénování supervizovaných neuronových sítí je klíčové mít k dispozici dostatečně rozsáhlý a přesně označený soubor dat, což v našem případě představovalo časově náročný a komplikovaný proces. Tato nevýhoda je zejména patrná při řešení segmentačních úloh, které vyžadují precizní označení, například při identifikaci rýh či čerpacích stanic.

Dalším aspektem, který vyžaduje zvýšenou pozornost, je komplexnost modelu. Původní model Kaggle Cats and Dogs byl adaptován pro naše specifické potřeby, ale jádro tohoto modelu zůstává částečně nezmapované. Pochopení vnitřní struktury a chování neuronové sítě je klíčové pro dosažení optimálních výsledků. Přestože model dosahuje očekávaných výsledků, je nutné mít na paměti, že složitost modelů může vést k obtížnějšímu ladění a interpretaci.

V širším kontextu lze konstatovat, že implementace segmentace do struktury supervizované neuronové sítě přináší s sebou jak výhody, tak i nevýhody. Zároveň výsledná účinnost této metody závisí na specifikách řešeného problému a na kvalitě dostupných vstupních dat a příslušných označení. Využití segmentace umožňuje přesnější a cílenější zpracování dat, což může vést ke zlepšení výkonnosti modelu v oblasti, kde je potřeba rozlišit a analyzovat různé části vstupních informací. Nicméně, s těmito výhodami přicházejí i některé potenciální nevýhody, jako například vyšší nároky na označený datový soubor a komplexitu modelu, což může ztížit optimalizaci a ladění. Celková efektivita segmentace

a neuronových sítí je tedy těsně svázána s konkrétními parametry a podmínkami daného problému a datové sady.

8.4 Problémy modelu

Jedním ze základních předpokladů pro úspěch modelu je značné množství označených tréninkových dat. Supervizované učení, běžný přístup při tréninku neuronových sítí, silně závisí na přesně označených datasetech. Získání takových datasetů pro různé typy erozního poškození je časově náročným procesem, což omezuje použitelnost modelu pro malé a jedinečné úkoly.

Nedostatek tréninkových dat je spojen s dalším rizikem použití modelu a tím je přílišné přizpůsobení se tréninkovým datům, takzvaný „overfitting“. Model může dobře fungovat na dostupných datech, ale selhává při přechodu na nová, zatím neviděná data. Je tak nutné najít rovnováhu mezi počtem tréninkových dat a jejich pestrostí. Dále je nutné neustále ověřovat, zda nedošlo k overfittingu pomocí robustní strategií validace modelu. Toto je spojeno s rizikem tzv. adverzárního útoku, kdy jsou vstupní data vědomě či nevědomě manipulována tak, že model zavádějí. Je tedy nutné získávat trénovací data od široké skupiny expertů, kteří poskytnou široké vzájemně se doplňující spektrum trénovacích dat.

Model je charakterizován relativně složitými architekturami s mnoha vrstvami a parametry, především při porovnání s metodami jednoduchého zatřídění pixelů pomocí hodnoty či manuální digitalizací. Zatímco tato složitost přispívá k schopnosti modelu učit se složitým vzorům, představuje také problém v oblasti interpretovatelnosti modelu. Porozumění tomu, jak neuronová síť dospěje k určitým rozhodnutím, je obtížné, což může vést k obavám a ztrátě důvěry v model.

Efektivní trénink a běh modelu vyžaduje kvalitní výpočetní zdroje, s výkonnými GPU nebo TPU. To může představovat bariéru pro použití v případech omezeného přístupu k takovým zdrojům.

8.5 Zjištěné poznatky

Hlavním poznatkem je doporučení vytvářet více modelů, které by byly specializované na různé typy zjišťovaných prvků v geografických datech. Modely by měly být stavěny pro jednotlivé skupiny prvků, například body. Tato skupina může zahrnovat specifické vlastnosti a charakteristiky bodových prvků. Tato specializace modelů umožní dosažení vyšší přesnosti a účinnosti při zpracování a analýze bodových dat, a to prostřednictvím optimalizace algoritmů a parametrů specifických pro tuto kategorii geografických prvků.

Tento koncept je možné aplikovat i na vytváření modelů pro linie a plochy. Každý model bude natrénován tak, aby reflektoval unikátní vlastnosti a potřeby každé kategorie geografických prvků. Tato diferenciací zkomplikuje stavbu modelu, nicméně zlepší schopnost lépe reagovat na specifika různých typů dat. Celkově umožní vytvoření více specializovaných modelů pro jednotlivé kategorie

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země geografických prvků efektivnější zpracování a analýzu geografických dat, přispívající tak k vyšší kvalitě výsledků v oblasti geoinformatiky.

Pro dosažení vyšší robustnosti a přesnosti modelu je možné implementovat kategorii "neurčeno" pro segmenty s nízkou hodnotou pravděpodobnosti většiny tříd. Tato kategorie bude sloužit k identifikaci a označení segmentů, u kterých model není schopen s vysokou jistotou určit správnou třídu. Tímto způsobem lze zvýšit důvěryhodnost výstupů modelu tím, že explicitně označuje oblasti, kde není dostatek informací pro přesné zařazení do určité třídy. Tento inovativní přístup umožní uživatelům systematictěji vyhodnotit spolehlivost výsledků a zároveň zvýší použitelnost modelu v situacích s neurčitými či komplexními daty.

8.6 Další postup výzkumu

Další postup výzkumu se bude věnovat především ošetření nalezených slabých míst modelu. Primárně bude pozornost věnována vývoji modelové vrstvy, která umožní vytvářet více modelů s různou velikostí segmentu najednou. Toto se jasně ukázalo při validaci modelu změnou velikosti segmentu, kdy jednotlivé klasifikační kategorie mají významně větší úspěšnost zatřídění při různých velikostech segmentu. Zároveň tak musí být ošetřena komplementarita modelu, při následné syntéze výsledků pro více vzniklých modelů.

Samostatným úkolem je analýza počtu tříd. Je nutné posoudit, zda jednotlivé součásti erozního poškození, jako pravá/levá hrana rýhy, přechod nepoškozená půda/plošné poškození atd. nevyžadují zavedení vlastních kategorií. Toto je nutně spojeno s poklesem počtu tréninkových dat při současném množství dostupných tréninkových datasetů, nicméně lze předpokládat přesnější výsledky takového modelu.

Samostatnou otázkou je převod modelu z prostředí několika softwarů do samostatného programu. Tento krok by demokratizoval použití modelu a umožnil použít model i bez instalace ArcGIS, případně znalostí programovacího jazyka Python.

Ve výzkumu bude dále pokračováno v rámci projektu TQ03000408 – Detekce zvýšeného erozního poškození za využití neuronových sítí na kombinaci obrazových dat DPZ a erozně hydrologického modelování.

9 Závěr

Snaha rozvinout metody monitoringu eroze půdy, zejména se zaměřením na automatickou detekci erozních projevů byla úspěšná. Na sebraných datech z období let 2015-2023 byla provedena řada experimentálních aplikací modelu, a výsledky modelů mohou být použity pro vývoj a optimalizaci metod monitoringu. Automatická detekce erozních projevů byla testována na datech s různými měřítky vytvořenými různými metodami. Je tak možné efektivně tvořit podklady k hodnocení rozsahu a závažnosti erozních jevů na zemědělské půdě z různých druhů monitoringu. Vytvořená metoda přináší významný pokrok ve sledování eroze půdy a poskytuje nástroj pro detailní analýzu vlivu různých faktorů na dynamiku erozních procesů.

V rámci této disertační práce bylo úspěšně dosaženo hlavního cíle, kterým bylo vytvořit a natrénovat klasifikační model využívající postupy strojového učení neuronových sítí. Pro dosažení tohoto cíle bylo provedeno rozsáhlé množství experimentálních analýz, a tímto byl vyvinut klasifikační model schopný zatřídit různé oblasti na snímcích experimentálních ploch. Tento model byl navržen tak, aby byl schopný klasifikovat plochy na oblasti bez poškození erozí, oblasti postižené plošnou erozí a oblasti s rýhovou erozí. Kvalitně postavený model, je široce použitelný, neboť dokáže pracovat s daty z různých zdrojů, včetně satelitních snímků, snímků z bezpilotních prostředků a leteckých snímků. Model se také ukázal jako efektivní při zpracování snímků vytvořených fotogrammetrickou metodou SfM, což posiluje jeho univerzální využitelnost pro výzkum erozních jevů v laboratorním prostředí.

V rámci dalšího cíle disertační práce byla úspěšně provedena evaluace klasifikačního modelu, a zároveň byly identifikovány silné a slabé stránky modelu. Pro dosažení tohoto cíle byl model spuštěn na jednotné datové sadě s různými nastaveními parametrů modelu. Zvláštní pozornost byla věnována vlivu velikosti segmentu na úspěšnost klasifikace, s ohledem na snahu zmenšovat velikost segmentu pro praktické využití modelu. Tímto způsobem byl zkoumán vliv parametrů na výslednou přesnost klasifikace, což je klíčový faktor pro praktické nasazení modelu v různých aplikacích. Dále bylo posouzeno, jak množství trénovacích dat ovlivňuje přesnost modelu. V souladu s obecným předpokladem bylo zjištěno, že se snižujícím se množstvím tréninkových dat klesá úspěšnost modelu. Tato analýza přesně stanovila hranice, od kterých se úspěšnost modelu snižuje významně, což má praktický význam pro efektivní využití modelu v různých scénářích s omezenými tréninkovými daty.

V rámci doplňujícího cíle disertační práce bylo úspěšně ověřeno použití vyvinutého klasifikačního modelu pro další typy analýz a aplikací. Model byl úspěšně využit pro digitalizaci map, což například umožní získat detailní informace o využití území bez potřeby zdlouhavé manuální práce. Dále byla provedena identifikace určitých prvků na mapách, což rozšiřuje možnosti využití modelu pro různé geografické a prostorové analýzy. Analyzovaly se také výsledky různých modelů, přičemž byly hledány

cesty a doporučení, jak s takovými výsledky dále pracovat. Tato analýza přispívá k porozumění možnostem a omezením modelu při různých typech analýz a poskytuje směr pro jeho efektivní využití v širším kontextu geografického a prostorového zkoumání.

Disertační práce úspěšně dosáhla klíčových cílů, zaměřených na rozvoj metod monitoringu eroze půdy prostřednictvím automatické detekce erozních projevů. S pomocí vyhodnocení rozsáhlého množství erozních experimentů byl vytvořen a natrénován klasifikační model, schopný klasifikovat experimentální plochy podle stupně erozního poškození. Model, využívající strojové učení a data z různých zdrojů, byl následně úspěšně využit i pro další analýzy, jako je digitalizace map či identifikace prvků na mapách. Důkladná evaluace modelu odhalila jeho silné a slabé stránky, včetně vlivu parametrů, jako je velikost segmentu a množství trénovacích dat, na jeho úspěšnost. Získané poznatky jsou klíčové pro praktické využití modelu v různých aplikacích s ohledem na omezené množství tréninkových dat a specifické požadavky monitoringu eroze půdy.

10 Seznamy

10.1 Seznam použité literatury

- Abudi, I., G. Carmi, and P. Berliner. 2012. "Rainfall Simulator for Field Runoff Studies." *Journal of Hydrology* 454–455:76–81.
- Akgun, Devrim. 2022. "TensorFlow Based Deep Learning Layer for Local Derivative Patterns." *Software Impacts* 14(December):100452.
- Amon, Philipp, Ursula Riegl, Peter Rieger, Martin Pfennigbauer, and others. 2015. "UAV-Based Laser Scanning to Meet Special Challenges in Lidar Surveying." *Proceedings of the Geomatics Indaba*.
- Anon. 2019a. "BeginnersGuide/Overview - Python Wiki." Retrieved July 16, 2019 (<https://wiki.python.org/moin/BeginnersGuide/Overview>).
- Anon. 2019b. "Operational Land Imager (OLI) « Landsat Science." Retrieved July 4, 2019 (<https://landsat.gsfc.nasa.gov/operational-land-imager-oli/>).
- Anon. 2019c. "User Guides - Sentinel-2 MSI - Overview - Sentinel Online." Retrieved June 24, 2019 (<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/overview>).
- Anon. 2019d. "Weblet Importer." Retrieved July 10, 2019 (<https://scihub.copernicus.eu/dhus/#/home>).
- Anon. 2023. "About SQLite."
- Artasanchez, Alberto and Prateek Joshi. 2020. *Artificial Intelligence with Python (TOP Reference)*.
- Báčová, Markéta. 2018. "Monitoring Projevů Vodní Eroze Na Zemědělských Půdách."
- Báčová, Markéta and Josef Krása. 2016. "Application of Historical and Recent Aerial Imagery in Monitoring Water Erosion Occurrences in Czech Highlands." *Soil and Water Research* 11(4):267–76.
- Báčová, Markéta, Josef Krása, Jan Devátý, and Petr Kavka. 2019. "A GIS Method for Volumetric Assessments of Erosion Rills from Digital Surface Models." *European Journal of Remote Sensing* 52(sup1):96–107.
- Borrelli, Pasquale, David A. Robinson, Larissa R. Fleischer, Emanuele Lugato, Cristiano Ballabio, Christine Alewell, Katrin Meusburger, Sirio Modugno, Brigitta Schütt, Vito Ferro, Vincenzo Bagarello, Kristof Van Oost, Luca Montanarella, and Panos Panagos. 2017. "An Assessment of the Global Impact of 21st Century Land Use Change on Soil Erosion." *Nature Communications* 8(1).
- Calvo, Adolfo. 1988. "(PDF) Un Simulador de Lluvia Portátil de Fácil Construcción." Retrieved February 10, 2022 (https://www.researchgate.net/publication/285677837_Un_simulador_de_lluvia_portatil_de_facil_construccion).
- Casalí, Javier, Rafael Giménez, and Sean Bennett. 2009. "Gully Erosion Processes: Monitoring and Modelling." *Earth Surface Processes and Landforms* 34(14):1839–40.
- Cerdà, A. 1999. "Parent Material and Vegetation Affect Soil Erosion in Eastern Spain." *Soil Science Society of America Journal* 63(2):362–68.
- Cerdà, A., S. Ibáñez, and A. Calvo. 1997. "Design and Operation of a Small and Portable Rainfall Simulator for Rugged Terrain." *Soil Technology* 11(2):163–70.
- Chakraborty, Rabin, Subodh Chandra Pal, Mehebab Sahana, Ayan Mondal, Jie Dou, Binh Thai Pham, and Ali P. Yunus. 2020. *Soil Erosion Potential Hotspot Zone Identification Using Machine Learning and Statistical Approaches in Eastern India*. Vol. 104. Springer Netherlands.
- Chang, Chih Chung and Chih Jen Lin. 2011. "LIBSVM: A Library for Support Vector Machines." *ACM Transactions on Intelligent Systems and Technology* 2(3):1–40.
- Christiansen, J. E. 1942. "Irrigation by Sprinkling." *University of California College of Agriculture Agricultural Experiment Station Berkeley, California* 1–126.

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země

- Comino, J. R. 2021. *Precipitation: Earth Surface Responses and Processes*. Elsevier Science.
- Cook, Kristen L. 2017. "An Evaluation of the Effectiveness of Low-Cost UAVs and Structure from Motion for Geomorphic Change Detection." *Geomorphology* 278:195–208.
- Cukierski, Will. 2013. "Dogs vs. Cats." *Kaggle*. Retrieved (<https://www.kaggle.com/c/dogs-vs-cats>).
- Curnick, David J., Alasdair J. Davies, Clare Duncan, Robin Freeman, David M. P. Jacoby, Hugo T. E. Shelley, Cristian Rossi, Oliver R. Wearn, Michael J. Williamson, and Nathalie Pettoelli. 2022. "SmallSats: A New Technological Frontier in Ecology and Conservation?" *Remote Sensing in Ecology and Conservation* 8(2):139–50.
- Demir, Sinan and İbrahim Dursun. 2023. "Assessment of Pre - and Post - Fire Erosion Using the RUSLE Equation in a Watershed Affected by the Forest Fire on Google Earth Engine : The Study of Manavgat River Basin." (0123456789).
- Dube, Timothy, Onesimo Mutanga, Mbulisi Sibanda, Khoboso Seutloali, and Cletah Shoko. 2017. "Use of Landsat Series Data to Analyse the Spatial and Temporal Variations of Land Degradation in a Dispersive Soil Environment: A Case of King Sabata Dalindyebo Local Municipality in the Eastern Cape Province, South Africa." *Physics and Chemistry of the Earth, Parts A/B/C* 100:112–20.
- Elson, Jeremy, John R. Douceur, Jon Howell, and Jared Saul. 2007. "Asirra: A CAPTCHA That Exploits Interest-Aligned Manual Image Categorization." *Proceedings of the ACM Conference on Computer and Communications Security* 366–74.
- Eltner, Anette, Andreas Kaiser, Antonio Abellan, and Marcus Schindewolf. 2017. "Time Lapse Structure-from-motion Photogrammetry for Continuous Geomorphic Monitoring." *Earth Surface Processes and Landforms* 42(14):2240–53.
- Eltner, Anette, Hans Gerd Maas, and Dominik Faust. 2018. "Soil Micro-Topography Change Detection at Hillslopes in Fragile Mediterranean Landscapes." *Geoderma* 313(June 2017):217–32.
- Eltner, Anette and Giulia Sofia. 2020. "Structure from Motion Photogrammetric Technique." Pp. 1–24 in *Developments in Earth Surface Processes*. Vol. 23. Elsevier.
- Geoportál, ČÚZK: 2023. "ČÚZK: Geoportál." Retrieved ([https://geoportal.cuzk.cz/\(S\(auqkhdvihht2taj12evfyznj\)\)/Default.aspx?lng=CZ&mode=TextMeta&side=vyskopis&metadataID=CZ-CUZK-DMP1G-V&mapid=8&menu=303](https://geoportal.cuzk.cz/(S(auqkhdvihht2taj12evfyznj))/Default.aspx?lng=CZ&mode=TextMeta&side=vyskopis&metadataID=CZ-CUZK-DMP1G-V&mapid=8&menu=303)).
- Goldberger, Jacob, Geoffrey E. Hinton, Sam Roweis, and Russ R. Salakhutdinov. 2004. "Neighbourhood Components Analysis." in *Advances in Neural Information Processing Systems*. Vol. 17, edited by L. Saul, Y. Weiss, and L. Bottou. MIT Press.
- Gouillart, Emmanuelle. 2017. "Analyzing Tomography Data with Python and the Scikit-Image Library." (June).
- Gruber, Josef. 2016. "VÝVOJ OBCE ROPICE (FRÝDEK-MÍSTEK) – ANALÝZA MAPOVÝCH PODKLADŮ." ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE.
- Hänsel, Phoebe, Marcus Schindewolf, Anette Eltner, Andreas Kaiser, and Jürgen Schmidt. 2016. "Feasibility of High-Resolution Soil Erosion Measurements by Means of Rainfall Simulations and SfM Photogrammetry." *Hydrology* 3(4):1–16.
- Haralick, Robert M., Its'hak Dinstein, and K. Shanmugam. 1973. "Textural Features for Image Classification." *IEEE Transactions on Systems, Man and Cybernetics* SMC-3(6):610–21.
- Holz, Daniel J., Karl W. J. Williard, Pamela J. Edwards, and Jon E. Schoonover. 2015. "Soil Erosion in Humid Regions: A Review." *Journal of Contemporary Water Research & Education* 154(1):48–59.
- Housková, Dagmar. 2008. "ÚROVEŇ DIGITALIZACE ČESKÝCH MAPOVÝCH ARCHIVŮ." CZECH TECHNICAL UNIVERSITY IN PRAGUE.
- Huang, Xin. 2023. "Introduction to Programming in Python." *Land Carbon Cycle Modeling* 343–51.
- Iserloh, T., W. Fister, M. Seeger, H. Willger, and J. B. Ries. 2012. "A Small Portable Rainfall Simulator for

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země

Reproducible Experiments on Soil Erosion." *Soil and Tillage Research* 124:131–37.

Jajodia, Tushar and Pankaj Garg. 2019. "Image Classification-Cat and Dog Images." *International Research Journal of Engineering and Technology* 6(12):570–72.

Janeček, M. 2012. *Ochrana Zemědělské Půdy Před Erozí*. 1st ed. Prague: Powerprint Prague.

Jester, Werner and Andreas Klik. 2005. "Soil Surface Roughness Measurement - Methods, Applicability, and Surface Representation." *Catena* 64(2–3):174–92.

Jetten, Victor, Gerard Govers, and Rudi Hessel. 2003. "Erosion Models: Quality of Spatial Predictions." *Hydrological Processes* 17(5):887–900.

Kalibová, J., L. Jačka, and J. Petru. 2016. "The Effectiveness of Jute and Coir Blankets for Erosion Control in Different Field and Laboratory Conditions." *Solid Earth* 7(2):469–79.

Kavka, P., T. Davidová, B. Janotová, M. Bauer, and T. Dostál. 2015. "Mobilní Dešť'ový Simulátor." *Geophysical Research Abstracts* 17:2015–10579.

Kavka, P., Martin Neumann, T. Laburda, A. Tejkl, and D. Zumr. 2019. "Rainfall Simulations on Extreme Artificial Slopes." 21:2030428.

Kinnell, P. I. A. 2016. "A Review of the Design and Operation of Runoff and Soil Loss Plots." *CATENA* 145:257–65.

Koláčková, J. 2005. *Stanovení Erodovatelnosti Půdy Experimentálními Metodami*.

Krása, Josef. 2021. *Průběžná Zpráva z Projektu Využití Dat Dálkového Průzkumu Země pro Posouzení Negativních Dopadů Příkladových Srážek 2021*.

Krása, Josef, A. Tejkl, and Jakub Stašek. 2019. "Určení Rozsahu Půdy Nechráněné Vegetací v Období Příkladových Srážek Za Účelem Posouzení Erozního Rizika." 39–45.

KU Leuven. 2024. "Research Portal - THE IMPACT OF DEPOPULATION ON ECOSYSTEM SERVICES IN EUROPE. A PILOT STUDY IN FRANCE, CZECH REPUBLIC AND POLAND." Retrieved (<https://research.kuleuven.be/portal/en/project/3E220627>).

Laburda, Tomáš, Josef Krása, David Zumr, Jan Devátý, Michal Vrána, Nives Zambon, Lisbeth Lolk Johannsen, Andreas Klik, Peter Strauss, and Tomáš Dostál. 2021. "SfM-MVS Photogrammetry for Splash Erosion Monitoring under Natural Rainfall." *Earth Surface Processes and Landforms* 46(5):1067–82.

Lal, R. 1994. "Soil Erosion Research Methods - Soil and Water Conservation Society (U. S.), R. Lal - Google Books." Retrieved February 10, 2022 (https://books.google.cz/books?hl=en&lr=&id=1TK7dEOIM4gC&oi=fnd&pg=PR5&dq=lal+1994&ots=jYKdTvHc_J&sig=sToIO13R3TCR_Lknlc7aMG4MDHg&redir_esc=y#v=onepage&q=lal+1994&f=false).

Malinowski, Radek, Goswin Heckrath, Marcin Rybicki, and Anette Eltner. 2023. "Mapping Rill Soil Erosion in Agricultural Fields with UAV-borne Remote Sensing Data." *Earth Surface Processes and Landforms* 48(3):596–612.

Mandlbürger, Gottfried, Martin Pfennigbauer, Roland Schwarz, Sebastian Flöry, and Lukas Nussbaumer. 2020. "Concept and Performance Evaluation of a Novel." *Remote Sensing* 12(986):28pp.

Merritt, Jason and Seppe Kuehn. 2016. "Quantitative High-Throughput Population Dynamics in Continuous-Culture by Automated Microscopy." *Scientific Reports* 6(1):33173.

Nearing, Mark A. and P. B. Hairsine. 2010. "The Future of Soil Erosion Modelling." Pp. 387–97 in *Handbook of Erosion Modelling*. John Wiley & Sons, Ltd.

NIED. 2023. "Large-Scale Rainfall Simulator | Experimental Facilities | The National Research Institute for Earth Science and Disaster Resilience (NIED)." Retrieved (<https://www.bosai.go.jp/e/facilities/rainfall.html>).

Nouwakpo, Sayjro Kossi, Mark A. Weltz, and Kenneth McGwire. 2016. "Assessing the Performance of Structure-from-Motion Photogrammetry and Terrestrial LiDAR for Reconstructing Soil Surface Microtopography of

Naturally Vegetated Plots." *Earth Surface Processes and Landforms* 41(3):308–22.

Novák, Pavel, Jan Vopravil, and Jitka Lagová. 2010. "Assessment of the Soil Quality as a Complex of Productive and Environmental Soil Function Potentials." *Soil and Water Research* 5(3):113–19.

Novotný, Ivan, Vladimír Papaj, Jana Podhrázská, Jiří Kapička, Jan Vopravil, Hana Kristenová, Martin Mistr, Daniel Žížala, David Kincl, Jan Srbek, Michal Pochop, Tomáš Dostál, Josef Krása, and Václav Kadlec. 2017. "Příručka Ochrany Proti Erozi Zemědělské Půdy, 3. Aktualizované Vydání." 86.

Padarian, Jose, Budiman Minasny, and Alex B. McBratney. 2020. "Machine Learning and Soil Sciences: A Review Aided by Machine Learning Tools." *Soil* 6(1):35–52.

Pan, Chengzhong, Lan Ma, and Zhouping Shangguan. 2010. "Effectiveness of Grass Strips in Trapping Suspended Sediments from Runoff." *Earth Surface Processes and Landforms* 35(9):1006–13.

Pickering, Jeffrey, Alexandra Tyukavina, André Lima, Ahmad Khan, Peter Potapov, Bernard Adusei, and Matthew C. Hansen. 2021. "Using Multi-Resolution Satellite Data to Quantify Land Dynamics: Applications of PlanetScope Imagery for Cropland and Tree-Cover Loss Area Estimation." *Remote Sensing* 13(11).

Právělie, Remus, Cristian Patriche, Pasquale Borrelli, Panos Panagos, Bogdan Roșca, Monica Dumitrașcu, Ion Andrei Nita, Ionuț Săvulescu, Marius Victor Birsan, and Georgeta Bandoc. 2021. "Arable Lands under the Pressure of Multiple Land Degradation Processes. A Global Perspective." *Environmental Research* 194(September 2020).

PTC. 2024. "Example: Grayscale and Color in Images." Retrieved (https://support.ptc.com/help/mathcad/r9.0/en/index.html#page/PTC_Mathcad_Help/example_grayscale_and_color_in_images.html).

Ramchandani, Monica, Hrishikesh Khandare, Priyanshi Singh, Prince Rajak, Nidhi Suryawanshi, Anjali Sagar Jangde, Laxmi Arya, Prithviraj Kumar, and Mridu Sahu. 2022. "Survey: Tensorflow in Machine Learning." *Journal of Physics: Conference Series* 2273(1):0–11.

Rasam, Abdul Rauf Abdul. 2021. "Towards Automated Digitization of Cartographic Hardcopy Maps: Reviews of Issues, Challenges and Potentials in Malaysia Library Archives." *Malaysian Journal of Remote Sensing & GIS* 10(10:1):43–51.

Renard, K. G., G. R. Foster, G. A. Weesies, D. K. McCool, and D. C. Yoder. 1997. *PREDICTING SOIL EROSION BY WATER: A GUIDE TO CONSERVATION PLANNING WITH THE REVISED UNIVERSAL SOIL LOSS EQUATION (RUSLE)*. Washington DC.

Le Roux, J. J., T. L. Morgenthal, J. Malherbe, D. J. Pretorius, and P. D. Sumner. 2008. "Water Erosion Prediction at a National Scale for South Africa." *Water SA* 34(3):305–14.

Roy, David P., Haiyan Huang, Rasmus Houborg, and Vitor S. Martins. 2021. "A Global Analysis of the Temporal Availability of PlanetScope High Spatial Resolution Multi-Spectral Imagery." *Remote Sensing of Environment* 264(April):112586.

Roy, Paramita, Rabin Chakraborty, Indrajit Chowdhuri, Sadhan Malik, Biswajit Das, and Subodh Chandra Pal. 2020. "Development of Different Machine Learning Ensemble Classifier for Gully Erosion Susceptibility in Gandheswari Watershed of West Bengal, India." Pp. 1–26 in *Machine Learning for Intelligent Decision Science*, edited by J. K. Rout, M. Rout, and H. Das. Singapore: Springer Singapore.

Sah, Bert Ram, Kasia Owczarczyk, Musib Siddique, Gary J. R. Cook, Vicky Goh, Zhenyu Shu, Songhua Fang, Zhongxiang Ding, Dewang Mao, Rui Cai, Yuanjun Chen, Daniel F. Aguirre-reyes, Julio A. Sotelo, Juan P. Arab, Marco Arrese, Rodrigo Tejos, Pablo Irarrazaval, Cristian Tejos, Sergio A. Uribe, Marcelo E. Andia, Ke Kun Wang, Xue Lu, Hui Zhou, Yongyan Gao, Junjiong Jian Zheng, Minghui Tong, Changjun Q. Wu, Changzhu Changchun Chuan Liu, Liping Liyu Huang, Tian Jiang, Fankun Meng, Yongping Yao Lu, Hong Ai, Xiao-yan Xie, Li-ping Yin, Ping Liang, Jie Tian, Avnish Kumar Ahmed Hosny Id, Chintan Parmar, Thibaud P. Coroller, Patrick Grossmann Id, Roman Zeleznik, Avnish Kumar Ahmed Hosny Id, Johan Bussink, Robert J. Gillies Id, H. Mak, Hugo J. W. L. Aerts Id, Data Science, Path Forward, André Diamant, Avishek Chatterjee, Martin Vallières, George Shenouda, Jan Seuntjens, Gu-wei Ji, Fei-peng Zhu, Yu-dong Zhang, Xi-sheng Liu, Fei-yun Wu, Ke Kun Wang, Yong-xiang Xia, Fanny Orhac, Frédérique Frouin, Christophe Nioche, Nicholas Ayache, Irène Buvat, Lifeng Yang, Jingbo Q.

Jinzhong Yang, Xiaobo Xuezhi Zhou, Liping Liyu Huang, Chun-qiang Lu, Yuan-cheng Yen-po Wang, Xiang-pan Meng, Hai-tong Zhao, Chu-hui Zeng, Weiwei Xu, Peter Steiger, Rohit Sood, A. Phantom Study, Lifei Lu-lu Zhang, Mengping Meng-yao Huang, Yan Yong Li, Jin-hui Liang, Tian-sheng Gao, Bin Deng, Ji-jin Yao, Li Lin, Fo-ping Chen, Xiao-dan Huang, Jia Kou, Chao-feng Li, Chuan-miao Xie, Yongping Yao Lu, Ying Sun, Ping Yin, Ning Mao, Chao Zhao, Jiangfen Jaw-ching Wu, Chao Sun, Lei Chen, Nan Hong, Wenya Linda Bi, Ahmed Hosny, Matthew B. Schabath, Maryellen L. Giger, Nicolai J. Birkbak, Alireza Mehrdash, Tavis Allison, Omar Arnaout, Christopher Abbosh, Ian F. Dunn, Raymond H. Mak, Rulla M. Tamimi, Clare M. Tempany, Charles Swanton, Udo Hoffmann, Zaiyi Zhenyu Liu, Shuo Wang, Di Dong, Jingwei Wei, Cheng Fang, Xiaobo Xuezhi Zhou, Kai Sun, Keith J. Dreyer, J. Raymond Geis, Garry Choy, Anthony E. Samir, James A. Brink, Philippe Lambin, Ralph T. H. Leijenaar, Timo M. Deist, Jurgen Peerlings, Emmanuel Rios-velazquez, Ralph T. H. Leijenaar, Sara Carvalho, Patrick Granton, Catharina M. L. Zegers, Robert J. Gillies, Ronald Boellard, Lee Moffitt, Laurence E. Court, Xenia Fave, Dennis Mackin, Joonsang Lee, Jingbo Q. Jinzhong Yang, Lifei Lu-lu Zhang, Ahmed Hosny, Chintan Parmar, John Quackenbush, Lawrence H. Schwartz, Hugo J. W. L. Aerts, Computational Biology, New York, Presbyterian Hospital, Luke Oakden-rayner, Gustavo Carneiro, Taryn Bessen, Jacinto C. Nascimento, P. Andrew, Lyle J. Palmer, Tien Dong, Amir Kalani, Elizabeth Aby, Long Le, Kayti Luu, Meg Hauer, Rahul Kamath, Keith Lindor, James Tabibian, Robert J. Gillies, Paul E. Kinahan, Hedvig Hricak, Marija Marcan, Denis Pavliha, Maja Marolt Music, Igor Fuckan, Ratko Magjarevic, Yoshinobu Sato, Shin Nakajima, Nobuyuki Shiraga, Hideki Atsumi, Riccardo Sartoris, Olivier Soubrane, Yuan-cheng Yen-po Wang, I-fang Hsin, Tsung-chieh Yang, Han-chieh Lin, Fa-yauh Lee, Jiangfen Jaw-ching Wu, D. Ph, Jingbo Q. Jinzhong Yang, R. Zeng, J. M. Cao, Changjun Q. Wu, T. W. Chen, R. Li, X. M. Zhang, J. Ou, H. J. Li, Q. W. Mu, World J. Gastroenterol, Ji Eun Park, Ho Sung Kim, Seo Young Park, Soo Jung Nam, Sung Min Chun, Youngheun Jo, Jeong Hoon Kim, E. J. Limkin, R. Sun, L. Derclé, E. I. Zacharaki, C. Robert, S. Reuzé, A. Schernberg, N. Paragios, E. Deutsch, C. Ferte, Utaroh Motosugi, Xiaolong Qi, Changzhu Changchun Chuan Liu, Baogang Peng, Jie Tian, Xun Xu, Hai-long Zhang, Qiu-ping Liu, Shu-wen Sun, Jing Zhang, Fei-peng Zhu, Guang Yang, Xu Yan, Yu-dong Zhang, Xi-sheng Liu, Andrew D. Smith, Cody R. Branch, Kevin Zand, Katherine Thaggard, Richard Hosch, Jason Bryan, Michael Griswold, Yujen Tseng, Lili Ma, Shupan Shaobo Li, Tiancheng Luo, Jianjun Luo, Wen Zhang, Jian Wang, Shiyao Chen, Fuquan Liu, Zhenyuan Ning, Yanna Liu, Dengxiang Liu, Jie Tian, Hongwu Luo, Weimin An, Yifei Huang, Jialiang Zou, Changzhu Changchun Chuan Liu, Changzhu Changchun Chuan Liu, Lei Wang, Zaiyi Zhenyu Liu, Ruizhao Qi, Changzeng Zuo, Yao Yongping Yang, Jinlin Hou, Jiahong Dong, Zhiwei Li, Huiguo Ding, Yu-dong Zhang, Xiaolong Qi, Junjiong Jian Zheng, Jianqiu Kong, Shaoxu Wu, Yan Yong Li, Jinhua Cai, Hao Yu, Dennis L. Shung, Benjamin Au, Richard Andrew Taylor, J. Kenneth Tay, Stig B. Laursen, Adrian J. Stanley, Harry R. Dalton, Jeffrey Ngu, Michael Schultz, Loren Laine, Chunmei Yang, Mengping Meng-yao Huang, Shupan Shaobo Li, Jianqiang Chen, Yao Yongping Yang, Na Qin, Deqing Huang, and Jian Shu. 2019. "Development of a Radiomics Nomogram Based on the 2D and 3D CT Features to Predict the Survival of Non-Small Cell Lung Cancer Patients." *European Radiology* 470(2):1–10.

Sartori, Martina, George Philippidis, Emanuele Ferrari, Pasquale Borrelli, Emanuele Lugato, Luca Montanarella, and Panos Panagos. 2019. "A Linkage between the Biophysical and the Economic: Assessing the Global Market Impacts of Soil Erosion." *Land Use Policy* 86(March):299–312.

Senanayake, Sumudu, Biswajeet Pradhan, Alfredo Huete, and Jane Brennan. 2020. "A Review on Assessing and Mapping Soil Erosion Hazard Using Geo-Informatics Technology for Farming System Management." *Remote Sensing* 12(24):1–25.

Sepuru, Terrence Koena and Timothy Dube. 2018. "An Appraisal on the Progress of Remote Sensing Applications in Soil Erosion Mapping and Monitoring." *Remote Sensing Applications: Society and Environment* 9(August 2017):1–9.

Sermanet, Pierre, David Eigen, Xiang Zhang, Michael Mathieu, Rob Fergus, and Yann LeCun. 2013. "OverFeat: Integrated Recognition, Localization and Detection Using Convolutional Networks." *2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings* (February 2015).

Seutloali, Khoboso E., Timothy Dube, and Onesimo Mutanga. 2017. "Assessing and Mapping the Severity of Soil Erosion Using the 30-m Landsat Multispectral Satellite Data in the Former South African Homelands of Transkei." *Physics and Chemistry of the Earth, Parts A/B/C* 100:296–304.

Tejkl, Adam and Petr Kavka. 2021. "Automated Low Investment Cost Evaporimeters (ALICES)." *Applied Sciences (Switzerland)* 11(11).

de Vente, Joris, Jean Poesen, Gerard Govers, and Carolina Boix-Fayos. 2009. "The Implications of Data Selection

for Regional Erosion and Sediment Yield Modelling." *Earth Surface Processes and Landforms* 34(15):1994–2007.

van der Walt, Stéfan, Johannes L. Schönberger, Juan Nunez-Iglesias, François Boulogne, Joshua D. Warner, Neil Yager, Emmanuelle Gouillart, Tony Yu, and the scikit-image contributors. 2014. "Scikit-Image: Image Processing in Python." *PeerJ* 2:e453.

Wischmeier, W. H. and D. D. Smith. 1978. "Predicting Rainfall Erosion Losses - a Guide to Conservation Planning." *Predicting Rainfall Erosion Losses - a Guide to Conservation Planning*.

Zambon, Nives, Lisbeth Lolk Johannsen, Peter Strauss, Tomas Dostal, David Zumr, Thomas A. Cochrane, and Andreas Klik. 2021. "Splash Erosion Affected by Initial Soil Moisture and Surface Conditions under Simulated Rainfall." *Catena* 196(August 2020):104827.

Zatelli, Paolo, Nicola Gabellieri, and Angelo Besana. 2022. "Digitalization and Classification of Cesare Battisti's Atlas of 1915." *ISPRS International Journal of Geo-Information* 11(4):238.

Zhang, X. C. 2019. "Determining and Modeling Dominant Processes of Interrill Soil Erosion." *Water Resources Research* 55(1):4–20.

Zhuang, Yanhua, Chao Du, Liang Zhang, Yun Du, and Sisi Li. 2015. "Research Trends and Hotspots in Soil Erosion from 1932 to 2013: A Literature Review." *Scientometrics* 105(2):743–58.

Žížala, Daniel, Anna Juřicová, Tereza Zádorová, Kateřina Zelenková, and Robert Minařík. 2019. "Mapping Soil Degradation Using Remote Sensing Data and Ancillary Data: South-East Moravia, Czech Republic." *European Journal of Remote Sensing* 52(sup1):108–22.

10.2 Seznam publikací autora

Následující seznam byl vygenerován z aplikace V3S ke dni 19.2.2024 a obsahuje všechny publikace, na kterých se autor osobně podílel.

TEJKL, A. a P. KAVKA. Automated Low Investment Cost Evaporimeters (ALICE). Applied Sciences. 2021, 2021(11), ISSN 2076-3417. DOI 10.3390/app11114986

KAVKA, P. et al. Water sources for Irrigation in headwater catchment over the Czech Republic in changing climate. In: Abstracts of the ICA. 31st International Cartographic Conference, Cape Town, 2023-08-13/2023- 09-18. Cape Town: International Cartographic Association, 2023. sv. 6. ISSN 2570-2106.

KAVKA, P. et al. The Influence of Climate Change on Runoff from Headwater Catchments. In: EGU General Assembly 2023. European Geosciences Union General Assembly 2023, Vienna, 2023-04-23/2023-05-28. Göttingen: Copernicus Publications, 2023.

TEJKL, A. a P. KAVKA. Digitalisation of irrigation systems from Water Management Maps. In: TEJKL, A., P. KAVKA a M. BÁČOVÁ, eds. Sborník z konference Hydrologie, GIS a životní prostředí 2023. Hydrologie, GIS a životní prostředí 2023, Lány - Bechnerův statek, 2023-06-14/2023-06-15. Praha: ČVUT, Fakulta stavební, Katedra hydromeliorací a krajinného inženýrství, 2023. 1. ISBN 978-80-01-07207-3. Dostupné z: https://storm.fsv.cvut.cz/data/files/Konference/GISZP/2023_HyGIZP_sbornik.pdf

TEJKL, A. a J. KRÁSA. Digitalization of Imperial Obligatory Imprints of the Stable Cadastre. In: TEJKL, A., P. KAVKA a M. BÁČOVÁ, eds. Sborník z konference Hydrologie, GIS a životní prostředí 2023. Hydrologie, GIS a životní prostředí 2023, Lány - Bechnerův statek, 2023-06-14/2023-06-15. Praha: ČVUT, Fakulta stavební, Katedra hydromeliorací a krajinného inženýrství, 2023. 1. ISBN 978-80-01-07207-3. Dostupné z: https://storm.fsv.cvut.cz/data/files/Konference/GISZP/2023_HyGIZP_sbornik.pdf

TEJKL, A., P. KAVKA a M. BÁČOVÁ, eds. Sborník z konference Hydrologie, GIS a životní prostředí 2023. Lány - Bechnerův statek, 2023-06-14/2023-06-15. Praha: ČVUT, Fakulta stavební, Katedra hydromeliorací a krajinného inženýrství, 2023. 1. ISBN 978-80-01-07207-3. Dostupné z: https://storm.fsv.cvut.cz/data/files/Konference/GISZP/2023_HyGIZP_sbornik.pdf

NEUMANN, M. et al. Influence of soil cover on surface runoff, infiltration, and percolation. In: EGU General Assembly 2023. European Geosciences Union General Assembly 2023, Vienna, 2023-04-23/2023-05-28. Göttingen: Copernicus Publications, 2023.

KAVKA, P. et al. Using the Rainfall Simulators to Test Rolled Erosion Control Products and Other Applications. In: DE LIMA, M.I., J.L.M.P. DE LIMA a J.M.G.P. ISIDORO, eds. 2nd Rainfall Simulation Workshop. Coimbra, 2023-05-22/2023-05-24. Faculty of Sciences and Technology of the University of Coimbra, 2023. s. 25. ISBN 978-989-33-4703-4.

KRÁSA, J. et al. Evaluations of rill and interrill erosion using rainfall simulators, SfM and mini-JET. In: DE LIMA, M.I., J.L.M.P. DE LIMA a J.M.G.P. ISIDORO, eds. 2nd Rainfall Simulation Workshop. Coimbra, 2023-05-22/2023-05-24. Faculty of Sciences and Technology of the University of Coimbra, 2023. s. 24. ISBN 978-989-33-4703-4.

TEJKL, A. et al. Irrigation decision support unit. In: EGU General Assembly 2023. European Geosciences Union General Assembly 2023, Vienna, 2023-04-23/2023-05-28. Göttingen: Copernicus Publications, 2023. DOI 10.5194/egusphere-egu23-6072

DAVID, V. et al. Shrnutí poznatků z využití dat DPZ různého původu k popisu malých vodních nádrží. [Výzkumná zpráva] Praha: ČVUT. Fakulta stavební, 2022.

TEJKL, A., M. BÁČOVÁ a P. KAVKA, eds. Sborník z konference Hydrologie, GIS a životní prostředí 2022. Krušné hory - Nové Hamry 13, 2022-06-06/2022-06-07. Praha: ČVUT, Fakulta stavební, Katedra hydromeliorací a krajinného hospodářství, 2022. 1. ISBN 978-80-01-07030-7. Dostupné z: https://storm.fsv.cvut.cz/data/files/Konference/GISZP/2022_HyGISZP_sbornik.pdf

KRÁSA, J. et al. Using Planetscope for Identification of Erosion by Water in Agricultural Landscapes. In: Proceedings of the 39th IAHR World Congress. 39th IAHR World Congress, Granada, Spain, 2022-06-19/2022-06-24. Granada: Universidad de Granada, 2022. s. 861-868. ISSN 2521-7119. DOI 10.3850/IAHR-39WC2521711920221444

TEJKL, A. a P. KAVKA. Identification of erosion rills via machine learning. In: EGU General Assembly 2022. European Geosciences Union General Assembly 2022, Vídeň, online, 2022-05-23/2022-05-27. Göttingen: Copernicus Publications, 2022. DOI 10.5194/egusphere-egu22-7850

Hydrologie, GIS a životní prostředí 2022. [Pořádání konference] 2022.

TEJKL, A. a P. KAVKA. Identification of erosion rills via machine learning. In: KAVKA, P., M. BÁČOVÁ a A. TEJKL, eds. SBORNÍK ABSTRAKTŮ KONFERENCE HYDROLOGIE, GIS A ŽIVOTNÍ PROSTŘEDÍ 2022. Praha: České vysoké učení technické v Praze, 2022. s. 12-13. 1. ISBN 978-80-01-07030-7. Dostupné z: https://storm.fsv.cvut.cz/data/files/Konference/GISZP/2022_HyGISZP_sbornik.pdf

NEUMANN, M. et al. Effect of plot size and precipitation magnitudes on the activation of soil erosion processes using simulated rainfall experiments in vineyards. *Frontiers in Environmental Science*. 2022, ISSN 2296-665X. DOI 10.3389/fenvs.2022.949774

KAVKA, P., M. BÁČOVÁ a A. TEJKL, eds. SBORNÍK ABSTRAKTŮ KONFERENCE HYDROLOGIE, GIS A ŽIVOTNÍ PROSTŘEDÍ 2022. Praha: České vysoké učení technické v Praze, 2022. 1. ISBN 978-80-01-07030-7. Dostupné z: http://storm.fsv.cvut.cz/data/files/Konference/GISZP/2019_HyGISZP_sbornik_final.pdf

NEUMANN, M. et al. Rainfall Simulators – how plot scale affects results. In: EGU General Assembly 2022. European Geosciences Union General Assembly 2022, Vídeň, online, 2022-05-23/2022-05-27. Göttingen: Copernicus Publications, 2022. DOI 10.5194/egusphere-egu22-4947

TEJKL, A. a P. KAVKA. Advancements in machine learning in rill analysis. In: ZUMR, D., J. JEŘÁBEK a M. NEUMANN, eds. 3rd Workshop on soil physics and landscape hydrology. Desná, 2021-10-06/2021-10-08. Praha: ČVUT. Fakulta stavební, 2021.

NEUMANN, M. et al. Laboratorní měření eroze na strmých svazích. In: *Hydrologie, GIS a životní prostředí 2021*. Horní Polubné, 2021-06-23/2021-06-24. Praha: ČVUT. Fakulta stavební, 2021.

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země

NEUMANN, M. et al. Rainfall simulation experiments in vineyards comparing two different plot scales. In: EGU General Assembly 2021. European Geosciences Union General Assembly 2021, online, 2021-04-19/2021-04-30. Göttingen: Copernicus Publications, 2021. DOI 10.5194/egusphere-egu21-5031

TEJKL, A. a P. KAVKA. Next generation of Automated Low Investment Cost Evaporimeters (ALICE). In: EGU General Assembly 2021. European Geosciences Union General Assembly 2021, online, 2021-04-19/2021-04-30. Göttingen: Copernicus Publications, 2021. DOI 10.5194/egusphere-egu21-7236

České vysoké učení technické v Praze, Praha 6, Dejvice, CZ. Hladinoměr pro měření výparu z vodní hladiny. Původci: A. TEJKL a P. KAVKA. Česko. Užitečný vzor CZ 35197. 2021-06-24. Dostupné z: <https://isdv.upv.cz/webapp/lresdb.pta.frm>

KAVKA, P. et al. Ochrana umělých svahů před erozí a stabilizace povrchové vrstvy. [Uplatněná metodika certifikovaná (do RIV)] 2021.

KAVKA, P. et al. ZÁVĚREČNÁ ODBORNÁ ZPRÁVA Z PROJEKTU O POSTUPU PRACÍ A DOSAŽENÝCH VÝSLEDKŮ ZA PROJEKT Č. TH02030428. [Výroční zpráva] 2020.

KRÁSA, J. et al. Recent trends in crop rotation in the Czech Republic and associated soil erosion risks. In: EGU General Assembly 2020. European Geosciences Union General Assembly 2020, online, 2020-05-04/2020-05-08. Göttingen: Copernicus Publications, 2020. Dostupné z: <https://meetingorganizer.copernicus.org/EGU2020/EGU2020-10964.html?pdf>

NEUMANN, M. et al. Swiping/pulse portable nozzle rainfall simulator. In: EGU General Assembly 2020. European Geosciences Union General Assembly 2020, online, 2020-05-04/2020-05-08. Göttingen: Copernicus Publications, 2020.

NEUMANN, M. et al. Efficiency of geotextile soil surface cover against soil erosion on the steep slopes. In: ZUMR, D. et al., eds. 2nd Workshop on soil physics and landscape hydrology. Praha - Dejvice, 2020-12-01. Praha: ČVUT FSv. Katedra hydromeliorací a krajinného inženýrství, 2020.

TEJKL, A., P. KAVKA a T. LABURDA. Identifikace erozních rýh pomocí machine learning. In: TEJKL, A., M. BÁČOVÁ a P. KAVKA, eds. Sborník Hydrologie, GIS a životní prostředí 2020. Hydrologie, GIS a životní prostředí 2020, online, 2020-12-09. Praha: České vysoké učení technické v Praze, 2020. ISBN 978-80-01-06800-7.

NEUMANN, M. et al. Erosion experiments on the steep slopes in laboratory. In: TEJKL, A., M. BÁČOVÁ a P. KAVKA, eds. Sborník Hydrologie, GIS a životní prostředí 2020. Hydrologie, GIS a životní prostředí 2020, online, 2020-12-09. Praha: České vysoké učení technické v Praze, 2020. ISBN 978-80-01-06800-7.

LABURDA, T. et al. Photogrammetrically measured sheet and rill erosion on steep slopes. In: EGU General Assembly 2020. European Geosciences Union General Assembly 2020, online, 2020-05-04/2020-05-08. Göttingen: Copernicus Publications, 2020. Dostupné z: <https://meetingorganizer.copernicus.org/EGU2020/EGU2020-17539.html>

TEJKL, A., M. BÁČOVÁ a P. KAVKA, eds. Sborník Hydrologie, GIS a životní prostředí 2020. online, 2020-12-09. Praha: České vysoké učení technické v Praze, 2020. ISBN 978-80-01-06800-7. Dostupné z: <http://storm.fsv.cvut.cz/cinnost-katedry/konference/gis-a-zp/?lang=cz>

TEJKL, A. a P. KAVKA. Low cost Evaporimeters. In: EGU General Assembly 2020. European Geosciences Union General Assembly 2020, online, 2020-05-04/2020-05-08. Göttingen: Copernicus Publications, 2020. DOI 10.5194/egusphere-egu2020-4999

KRÁSA, J. et al. Determination of the extent of soil unprotected by vegetation in the period of erosive rainstorms. In: ZDRULI, P., ed. Soil's contribution to people: from food to life supporting services. Tirana, 2019-09-26/2019-09-28. Brienza: LE Penseur Publisher, 2019. ISBN 978-88-95315-61-4.

LABURDA, T. et al. Protecting Steep Slopes Against Soil Erosion: Geotextiles and its Effectiveness Under Heavy Rainfall. In: AGU100 - Fall Meeting 2019. San Francisco, 2019-12-09/2019-12-13. Baltimore: AGU, 2019.

LABURDA, T. et al. Sledování plošné a rýhové eroze na strmých svazích pomocí fotogrammetrie. In: TEJKL, A., M. BÁČOVÁ a P. KAVKA, eds. SBORNÍK ABSTRAKTŮ KONFERENCE HYDROLOGIE, GIS A ŽIVOTNÍ PROSTŘEDÍ 2019. Praha: České vysoké učení technické v Praze, 2019. s. 8. 1. ISBN 978-80-01-06591-4.

Automatizace komplexního monitoringu zemědělských pozemků pomocí dálkového průzkumu Země

KRÁSA, J., A. TEJKL a J. STAŠEK. Určení rozsahu půdy nechráněné vegetací v období přivalových srážek za účelem posouzení erozního rizika. Vodohospodářské technicko-ekonomické informace. 2019, 61(2), 39-45. ISSN 0322-8916. DOI 10.46555/VTEI.2019.01.005

NEUMANN, M. et al. Soil particle size distribution in surface runoff under artificial rainfall. In: EGU General Assembly 2019. European Geosciences Union General Assembly 2019, Vienna, 2019-04-08/2019-04-12. Vienna: European Geosciences Union, 2019. sv. vol. 21. ISSN 1607-7962. Dostupné z: <https://meetingorganizer.copernicus.org/EGU2019/EGU2019-10961-1.pdf>

TEJKL, A. et al. Research of technical measures for artificial slopes stabilization and soil erosion prevention. In: EGU General Assembly 2019. European Geosciences Union General Assembly 2019, Vienna, 2019-04-08/2019-04-12. Vienna: European Geosciences Union, 2019. sv. vol. 21. ISSN 1607-7962. Dostupné z: <https://meetingorganizer.copernicus.org/EGU2019/EGU2019-17555-2.pdf>

LABURDA, T. et al. Close-range photogrammetric measurement of the splash and rill soil erosion. In: EGU General Assembly 2019. European Geosciences Union General Assembly 2019, Vienna, 2019-04-08/2019-04-12. Vienna: European Geosciences Union, 2019. sv. vol. 21. ISSN 1607-7962. Dostupné z: <https://meetingorganizer.copernicus.org/EGU2019/EGU2019-15246.pdf>

TEJKL, A., M. BÁČOVÁ a P. KAVKA, eds. SBORNÍK ABSTRAKTŮ KONFERENCE HYDROLOGIE, GIS A ŽIVOTNÍ PROSTŘEDÍ 2019. Praha: České vysoké učení technické v Praze, 2019. 1. ISBN 978-80-01-06591-4. Dostupné z: http://storm.fsv.cvut.cz/data/files/Konference/GISZP/2019_HyGISZP_sbornik_final.pdf

TEJKL, A. Využití jednoduchých metod pro posouzení sucha v roce 2015. In: STAŠEK, J. et al. Monitoring of soil erosion by water in multiple scales. In: 17th Biennial Conference ERB2018 - Book of Abstracts. 17th Biennial Conference ERB2018, Darmstadt, 2018-09-11/2018-09-14. Technical University of Darmstadt, 2018. Euromediterranean Network of Experimental and Representative Basins.

TEJKL, A. Využití bezkontaktního monitoringu v ochraně před erozí. In: BÁČOVÁ, M. a P. KAVKA, eds. Sborník abstraktů konference Hydrologie, GIS a životní prostředí 2018. Praha: České vysoké učení technické v Praze, 2018. s. 32. ISBN 978-80-01-06432-0.

KRÁSA, J. a A. TEJKL. Využití dálkového průzkumu Země pro ochranu půdy před erozí technologiemi precizního zemědělství. [Jiná metodika (nesplňující podmínky RIV)] 2018.

SCHWARZOVÁ, P. et al. Úspory vody při automatizované závlaze. In: DAVID, V., T. DAVIDOVÁ a A. VOKURKA, eds. Krajinné inženýrství 2017. Praha, Ministerstvo zemědělství, 2017-10-19. Praha: Česká společnost krajinných inženýrů - ČSKI, 2017. s. 185-196. ISBN 978-80-263-1341-0.

SCHWARZOVÁ, P. et al. ZTRÁTA ORNÉ PŮDY NA SVAZÍCH PŘI PŘÍVALOVÝCH SRÁŽKÁCH. In: BRDKOVÁ, P. et al., eds. Sborník příspěvků ze Semináře Adolfa Patery 2016. Seminář Adolfa Patery 2016 - Úloha nádrží při zvládnání extrémních hydrologických jevů v povodích, Praha, 2016-11-16. Praha: České vysoké učení technické v Praze, Fakulta stavební, 2016. s. 170-177. ISBN 978-80-01-06048-3.

SCHWARZOVÁ, P. et al. VLIV POČÁTEČNÍCH PODMÍNEK NA EROZNÍ CHARAKTERISTIKY PŮD TESTOVANÝCH NA LABORATORNÍM DEŠŤOVÉM SIMULÁTORU. In: Voda a krajina 2016. ČVUT v Praze, Fakulta stavební, posluchárna C223, 2016-10-13. Praha: České vysoké učení technické v Praze, Fakulta stavební, 2016. s. 205-216. ISBN 978-80-01-06024-7.

SCHWARZOVÁ, P. et al. Erozní charakteristiky půd při proměnlivých počátečních podmínkách experimentálního vzorku. In: ROŽNOVSKÝ, J. a J. VOPRAVIL, eds. PŮDNÍ A ZEMĚDĚLSKÉ SUCHO. Kutná Hora, 2016-04-28/2016-04-29. Praha-Zbraslav: Výzkumný ústav meliorací a ochrany půdy, v.v.i., 2016. s. 364-376. ISBN 978-80-87361-55-9.

SCHWARZOVÁ, P. et al. Ztráta půdy při proměnných intenzitách deště na laboratorním dešťovém simulátoru. In: FOŠUMPAUR, P., P. NEŠVAROVÁ CHVOJKOVÁ a M. ZUKAL, eds. Seminář Adolfa Patery 2015 Extrémní hydrologické jevy v povodích. Praha, 2015-12-16. Praha: Česká vědeckotechnická vodohospodářská společnost, 2015. s. 85-92. Rok 2015. ISBN 978-80-01-05856-5.

LABURDA, T. et al. Měření na laboratorním dešťovém simulátoru s konstantní a proměnnou intenzitou deště. In: DOČKAL, M. et al., eds. Voda a krajina 2015. Praha, 2015-09-23. Praha: ČVUT, Fakulta stavební, Katedra hydromeliorací a krajinného hospodářství, 2015. s. 57-66. ISBN 978-80-01-05794-0.

10.3 Seznam výzkumných projektů

V rámci doktorského studia se doktorand aktivně podílel na řešení následujících výzkumných projektů a v jednom případě jej také **osobně vede**. Díky těmto projektům bylo možné provést a vyhodnotit velké množství experimentů zahrnutých v této disertační práci.

TQ03000408 – Detekce zvýšeného erozního poškození za využití neuronových sítí na kombinaci obrazových dat DPZ a erozně hydrologického modelování, 2024 – 2025 (Ing. Adam Tejkl)

TH02030428 – Navrhování technických opatření pro stabilizaci a ochranu svahů před erozí, 2017 - 2020 (Ing. Petr Kavka, Ph.D.)

SS01020366 – Využití dat dálkového průzkumu Země pro posouzení negativních dopadů přivalových srážek, 2020 - 2024 (doc. Ing. Josef Krása, Ph.D.).

SS01020052 – Potenciál a rizika závlah na území ČR v měnícím se klimatu, 2020 – 2024 (doc. Ing. Petr Kavka, Ph.D., prof. Ing. Martin Hanel Ph.D.)

TJ02000351 – Vývoj metod a přístrojů pro zpřesnění celoroční bilance výparu, 2019 – 2021 (Ing. Filip Strnad)

SGS17/173/OHK1/3T/11 – Experimentální výzkum erozních a transportních procesů v zemědělsky využívané krajině, 2017 – 2019 (Ing. Tomáš Laburda)

SGS23/155/OHK1/3T/11 – Experimentální výzkum a monitoring srážko-odtokových a erozních procesů na zemědělských půdách, 2023 – 2025 (Ing. Michal Vrána)

SGS20/156/OHK1/3T/11, Monitoring, experimentální výzkum a matematické modelování srážko-odtokových a erozních procesů, 2020 – 2022 (Ing. Neumann Martin)

TITSMZP809 - Vliv malých vodních nádrží na hladinu podzemních vod a celkovou hydrologickou bilanci s důrazem na suchá období, 2019 – 2021 (Ing. Václav David, Ph.D.)

10.4 Seznam obrázků

Obr. 1 Časová osa vývoje disertační práce.....	8
Obr. 2 Ukázka GLCM analýzy pro míru Contrast, s velikostí segmentu 5 pixelů a vertikální směr	28
Obr. 3 Detail plochy s plošnou erozí	29
Obr. 4 Ukázka box plotu hodnot GLCM analýzy validačních polygonů pro míru Correlation, s velikostí segmentu 10 pixelů a horizontální směr	31
Obr. 5 Výsledek Ridge filtru metody Hessian.....	31
Obr. 6: Výsledek Blobs filtru DoG10_50_16	32

Obr. 7 Schéma segmentace snímku.....	35
Obr. 8 Mozaiky se vzájemným posunem segmentu	37
Obr. 9 Uspořádání mozaiky.....	37
Obr. 10 Schéma tréninkového skriptu modelu	40
Obr. 11 Schéma klasifikačního skriptu modelu.....	42
Obr. 12 Schéma kompletního segmentačního modelu	44
Obr. 13: Ukázka validační matice. Reálný výsledek pro scény z bezpilotních prostředků – nalevo, ideální výsledek validační matice – napravo.	46
Obr. 14 Scéna Litultovice 22.9.2019 s vyznačenými trénovacími pásy povrchu bez rýh (červené zig-zag linie) a poškozeným povrchem (zelená, žlutá, oranžová). Na světlém půdním bloku ve spodní části snímku je viditelné erozní poškození neoznačeno, to je následně použito pro manuální validaci zatřízeného snímku (vlevo). Zatřízená scéna Litultovice 22.9.2019. Trénovací oblasti nejsou zatřízeny a jsou zcela průhledné, oblast zatřízená jako nepoškozená v odstínech zelené, oblast zatřízená jako poškozená v odstínech červené. Na půdním bloku ve spodní části snímku je vidět částečný zásah erozního poškození modelem (vpravo).	49
Obr. 15 Linie a rastry rýh.....	50
Obr. 16 Schéma kompozitního modelu	51
Obr. 17 Schéma uspořádání mozaiky modelů	52
Obr. 18 Uspořádání mozaik jednotlivých modelů, shora Model_001, Model_002 a Model_003.....	52
Obr. 19 Snímek lokality Bulhary 25. 6. 2020.....	56
Obr. 20 Ukázka scény z bezpilotního prostředku, linie poškození a polygony poškození	57
Obr. 21 Uspořádání mozaiky modelu pro bezpilotní prostředky.....	59
Obr. 22 Snímek plochy 2 lokality Jirkov varianta biomac_c_R2_12_2_03.....	65
Obr. 23 Uspořádání mozaik pro scény z lokality Jirkov	67
Obr. 24 Ukázka výsledků pro lokalitu Jirkov.....	70
Obr. 25 Ukázka polygonů pro Laboratorní dešťový simulátor. Nepoškozený povrch – zelená, plošná eroze – oranžová, rýhy – červená.....	72
Obr. 26 Uspořádání mozaik pro scény z Laboratorního dešťového simulátoru.....	74
Obr. 27 Různá provedení čáry symbolizující závlahové potrubí	84
Obr. 28 Ukázka polygonů jednotlivých klasifikovaných tříd. Červená – závlaha, modrá – čerpací stanice, oranžová – ostatní plocha.....	85
Obr. 29 Klasifikovaný rastr před filtrací (nahore) a po filtraci (dole).	88
Obr. 30 Výsledné polygony, správně zatříděná závlaha – vlevo, přivaděč z ÚV Želivka – uprostřed, odpadní potrubí – vpravo.....	89
Obr. 31 Ukázka map Povinných císařských otisků.....	93

Obr. 32 Kalibrační polygony jednotlivých tříd. Urban – fialová, Arable – hnědá, Forest – zelená, Water – modrá, Meadow – tyrkysová	94
Obr. 33 Rozložení mapy na jednotlivé listy	95
Obr. 34 Ukázka klasifikovaného listu map Povinných císařských otisků	98
Obr. 35 Ukázka tříd a kalibračních polygonů Mapy z 80.tých let. Kalibrační polygony jednotlivých tříd. Od levého horního rohu postupně: Boundaries, Dashed Roads, Meadow, Pasture, Railway, Rest, Roads, Small Roads, Wetland	100
Obr. 36 Rozdělení Mapy z 80. let na jednotlivé listy.....	101
Obr. 37 Světle písková – Roads (Model_001), Písková – Roads (Model_002), Oranžová – Roads (Model_003)	106
Obr. 38 Světle zelená – Pastures (model_001), Tmavě zelená – Pastures (model_002), Světle modrá – Meadows (model_001), Tmavě modrá – Meadows (model_002)	107
Obr. 39 Rozlišení jednotlivých modelů. Zleva – Model_001, Model_002, Model_003.....	107

10.5 Seznam tabulek

Tab. 1 Přehled provedených experimentů.....	10
Tab. 2 Přehled dostupných satelitních scén pro zájmové lokality	48
Tab. 3 Počet vzniklých segmentů a nastavení parametrů modelů pro satelitní scény	54
Tab. 4 Ukázka výsledků modelů pro satelitní scény.....	55
Tab. 5 Přehled dostupných scén pro zájmové lokality z bezpilotních prostředků	56
Tab. 6 Počet vzniklých segmentů a nastavení parametrů modelů pro bezpilotní prostředky	61
Tab. 7 Přehled dostupných scén pro lokalitu Jirkov.....	66
Tab. 8 Počet vzniklých segmentů a nastavení parametrů pro lokalitu Jirkov	68
Tab. 9 Přehled počtu vytvořených segmentů a nastavení parametrů jednotlivých modelů pro Laboratorní dešťový simulátor	77
Tab. 10 Rozdělení skenů map dle kvality	82
Tab. 11 Počet segmentů a jejich zastoupení pro mapy Povinných císařských otisků	95
Tab. 12 Počty trénovacích segmentů pro jednotlivé modely Mapy z 80. let.....	104
Tab. 13 Poměry trénovacích segmentů vzhledem k modelům Mapy z 80. let.....	104

10.6 Seznam grafů

Graf 1 Úspěšnost pro Model_001 pro scény z bezpilotních prostředků	62
Graf 2 Úspěšnost pro Model_002 pro scény z bezpilotních prostředků	62
Graf 3 Úspěšnost pro Model_005 pro scény z bezpilotních prostředků	63
Graf 4 Úspěšnost pro Model_006 pro scény z bezpilotních prostředků	64
Graf 5 Závislost počtu trénovacích segmentů na hodnotě thresholdu	77

Graf 6 Závislost počtu trénovacích segmentů na velikosti segmentu	78
Graf 7 Histogram úspěšnosti pro třídu NoRill (Bez poškození)	78
Graf 8 Histogram úspěšnosti pro třídu Sheet (Plošné poškození)	79
Graf 9 Histogram úspěšnosti pro třídu Rill (Rýhové poškození)	79
Graf 10 Závislost úspěšnosti dle tříd na velikosti segmentu.....	80
Graf 11 Závislost úspěšnosti dle tříd na počtu tréninkových segmentů.....	81
Graf 12 Složení trénovacího datasetu.....	89
Graf 13 Změna počtu polygonů závlahy a příslušné plochy	90
Graf 14 Poměr vytvořených segmentů pro mapy Povinných císařských otisků	96
Graf 15 Zastoupení jednotlivých tříd segmentů pro Model_001	105
Graf 16 Zastoupení jednotlivých tříd segmentů pro Model_002	105
Graf 17 Zastoupení jednotlivých tříd segmentů pro Model_003	105

10.7 Seznam zkratk

DEM – digital elevation model

DoD - Digital Elevation Model of Difference

DPZ – dálkový průzkum Země

DS – dešťový simulátor

GIS – geografické informační systémy

GLCM – Gray Level Coocurence Matrix

SfM-MVS – Structure from Motion – Multi View Stereo