

UNIVERZITA PARDUBICE
FAKULTA EKONOMICKO SPRÁVNÍ

DIPLOMOVÁ PRÁCE

2025

Bc. Jakub Ešpandr

Univerzita Pardubice
Fakulta ekonomicko-správní

Klasifikace UAV obrazových dat v rámci vybraných území

Diplomová práce

2025

Bc. Jakub Ešpandr

Univerzita Pardubice
Fakulta ekonomicko-správní
Akademický rok: 2024/2025

ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení:	Bc. Jakub Ešpandr
Osobní číslo:	E23039
Studijní program:	N0613A140041 Aplikovaná informatika – Data Science pro business
Téma práce:	Klasifikace UAV obrazových dat v rámci vybraných území
Zadávající katedra:	Ústav systémového inženýrství a informatiky

Zásady pro vypracování

Cílem práce je analyzovat a porovnat metody řízené a neřízené klasifikace pro zpracování reálných obrazových dat s velmi vysokým prostorovým rozlišením získaných pomocí UAV. Práce se zaměřuje na proces zahrnující od přípravy letu, sběr dat, až po jejich zpracování a interpretaci. Součástí práce bude praktické ověření vybraných metod na reálném datovém souboru pro potřeby vnitřní analýzy podniku.

Osnova:

- Úvod
- Dálkový průzkum a klasifikace obrazových dat
- Současný stav ve směru práce
- Proces získávání obrazových dat z dálkového průzkumu
- Definování vybraného zájmového území
- Klasifikace zájmového území
- Interpretace a zhodnocení výsledků
- Závěr

Rozsah pracovní zprávy: **cca 50 stran**
Rozsah grafických prací:
Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam doporučené literatury:

AGGARWAL, Charu C. Neural networks and deep learning: a textbook. Cham, Switzerland: Springer, 2018. ISBN 978-3-319-94462-3.
GOODFELLOW, Ian; BENGIO, Yoshua a COURVILLE, Aaron. Deep learning. Adaptive computation and machine learning. Cambridge, Massachusetts: The MIT Press, 2016. ISBN 978-0-262-03561-3.
LILLESAND, Thomas M.; KIEFER, Ralph W. a CHIPMAN, Jonathan W. Remote sensing and image interpretation. 6th ed. Hoboken: Wiley, c2008. ISBN 978-0-470-05245-7.
LONGLEY, Paul. Geographic information systems & science. 3rd ed. Hoboken: John Wiley, c2011. ISBN 978-0-470-72144-5.
PRATT, William K. Digital image processing: PIKS Inside. 3rd ed. New York: John Wiley, c2001. ISBN 0-471-37407-5.
RUSS, John C. The image processing handbook. 6th ed. Boca Raton: CRC Press, c2011. ISBN 978-1-4398-4045-0.

Vedoucí diplomové práce: **Ing. Jakub Jech, Ph.D.**
Ústav systémového inženýrství a informatiky

Datum zadání diplomové práce: **1. září 2024**
Termín odevzdání diplomové práce: **30. dubna 2025**

prof. Ing. Jan Stejskal, Ph.D. v.r.
děkan

L.S.

prof. Ing. Petr Hájek, Ph.D. v.r.
garant studijního programu

V Pardubicích dne 1. září 2024

PROHLÁŠENÍ AUTORA

Prohlašuji:

Práci s názvem Klasifikace UAV obrazových dat v rámci vybraných území jsem vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

Byl jsem seznámen s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 7/2019 Pravidla pro odevzdávání, zveřejňování a formální úpravu závěrečných prací, ve znění pozdějších dodatků, bude práce zveřejněna prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 25. 07. 2025

Bc. Jakub Ešpandr v.r.

PODĚKOVÁNÍ

Rád bych vyjádřil poděkování Ing. Jakubu Jechovi, Ph.D., za vedení této diplomové práce, jeho odborné konzultace, podněty a věnovaný čas. Dále děkuji své rodině a přátelům za podporu při vlastní tvůrčí práci a během studia.

ABSTRAKT

Diplomová práce se zabývá klasifikací obrazových dat ve velmi vysokém prostorovém rozlišení získaných bezpilotními leteckými systémy (UAV) na vybraných územích s důrazem na analýzu vegetačního pokryvu a detekci environmentálních změn. Cílem bylo otestovat metody pro zpracování a klasifikaci UAV snímků s využitím řízených i neřízených klasifikačních přístupů, včetně metod hlubokého učení. Využity byly spektrální indexy, včetně autorem navržených SNDGR, GBRWI a MGLI2, pro zvýraznění specifických povrchových charakteristik, jako jsou spálené plochy, zaplavené oblasti či poškozená vegetace.

V rámci šesti případových studií zaměřených na klasifikaci výše zmíněných disturbancí a jedné věnované inventarizaci sadu byly testovány různé klasifikační algoritmy. Pro všechny případy byla využita pouze RGB data s případným spektrálním zvýrazněním, přičemž mezi zkoumané klasifikátory patřily například U-Net, Random Trees, SVM a ISO Cluster. Výsledky ukazují, že metody hlubokého učení dosahují vysoké přesnosti, například při klasifikaci zaplavených a vlhkých ploch či poškození úrody, a překonávají konvenční algoritmy, i když jejich trénování a ladění je časově náročné. Navržené indexy zlepšily klasifikaci vegetačních tříd a přechodových zón, přičemž SNDGR se ukázal jako robustní nástroj pro analýzu spálených porostů. V neřízené klasifikaci ISO Cluster došlo díky spektrálním indexům k výraznému zlepšení přesnosti, díky čemuž se výkon neřízeného přístupu přiblížil úrovni řízených metod. Tím se umožnila rychlejší detekce i kvantifikace zasažených oblastí bez nutnosti trénovacích dat.

Práce také představuje soubor vlastních softwarových nástrojů v jazyce Python (GeoShrink, FCC MS Image Processor, MetriCalc, Image Meta Locator, UAV Area Calc, Orthophoto Tool), které usnadňují zpracování UAV dat a tvorbu a zpracování ortofotosnímku. Výsledky potvrzují potenciál UAV dat pro operativní monitorování krajiny, zejména v (precizním) zemědělství a environmentálním managementu.

KLÍČOVÁ SLOVA

dálkový průzkum Země, bezpilotní letecké systémy, neřízená a řízená klasifikace obrazových dat, hluboké učení, RGB data, spektrální indexy, ortofotosnímky

TITLE

Classification of UAV Image Data within Selected Areas

ABSTRACT

This Master's thesis focuses on classifying very high spatial resolution UAV imagery over selected areas, with an emphasis on vegetation cover analysis and environmental change detection. The objective was to test methods for processing and classifying UAV imagery using both supervised and unsupervised classification approaches, including deep learning techniques. Spectral indices, including the author's proposed SNDGR, GBRWI, and MGLI2, were used to enhance specific surface features such as burnt areas, flooded areas, and damaged vegetation.

Various classification algorithms were tested within six case studies focused on classifying the aforementioned disturbances and one dedicated to orchard inventory. Only RGB data, occasionally enhanced with spectral indices, were used across all cases. The tested classifiers included, among others, U-Net, Random Trees, SVM, and ISO Cluster. The results show that Deep Learning methods achieve high accuracy, for example in the classification of flooded and wet areas or crop damage, and outperform conventional algorithms, even though their training and fine-tuning is time-consuming. The proposed indices improved the classification of vegetation classes and transition zones, with SNDGR proving to be a robust tool for analysing burnt vegetation. In unsupervised ISO Cluster classification, there was a significant improvement in accuracy, bringing the performance of the unsupervised approach closer to that of supervised methods. This brought the performance of the unsupervised approach closer to that of supervised methods, enabling faster detection and quantification of affected areas without the need for training data.

The thesis also introduces a set of custom software tools developed in Python – GeoShrink, FCC MS Image Processor, MetriCalc, Image Meta Locator, UAV Area Calc and Orthophoto Tool – that facilitate UAV data processing and orthophotograph creation. The results confirm the potential of UAV data for operational landscape monitoring, particularly in (precision) agriculture and environmental management.

KEYWORDS

Remote Sensing, Unmanned Aerial Systems, Unsupervised and Supervised Image Data Classification, Deep Learning, RGB Data, Spectral Indices, Orthophotograph

OBSAH

SEZNAM OBRÁZKŮ	11
SEZNAM TABULEK.....	13
SEZNAM QR KÓDŮ.....	14
SEZNAM ZKRATEK A ZNAČEK	15
ÚVOD	18
1 DÁLKOVÝ PRŮZKUM ZEMĚ.....	19
1.1 Elektromagnetické spektrum v DPZ	19
1.1.1 Ultrafialové záření.....	20
1.1.2 Viditelné spektrum.....	21
1.1.3 Blízké infračervené pásmo (NIR)	21
1.1.4 Střední infračervené a termální infračervené pásmo (SWIR a TIR)	22
1.1.5 Mikrovlnné pásmo	23
1.2 Platformy DPZ.....	23
1.2.1 Družicové systémy	24
1.2.1.1 Nízkooběžné polární-orbitální systémy (LEO)	24
1.2.1.2 Geostacionární systémy (GEO)	24
1.2.1.3 Komerční systémy	25
1.2.1.4 Ostatní družicové systémy.....	25
1.2.2 Pilotované letecké systémy	25
1.2.3 Bezpilotní letecké systémy.....	26
1.2.3.1 Vícerotorové systémy	26
1.2.3.2 Systémy s pevným křídlem.....	27
1.2.4 Pozemní / mobilní platformy	27
1.3 Druhy senzorů a datových výstupů.....	27
1.3.1 Pasivní optické senzory.....	28
1.3.1.1 RGB kamery.....	28
1.3.1.2 Multispektrální senzory	28
1.3.1.3 Hyperspektrální scannery	29
1.3.1.4 Termální IR kamery	30
1.3.2 Aktivní senzory.....	30
1.3.2.1 Radarové systémy (SAR, InSAR)	31
1.3.2.2 Lidarové systémy.....	31
1.3.2.3 Sonarové systémy.....	32
2 DIGITÁLNÍ ZPRACOVÁNÍ OBRAZOVÝCH DAT.....	33
2.1 Záznam a georeferencování UAV dat.....	33
2.2 Předzpracování	34
2.3 Zvýraznění	35
2.3.1 Bodové (radiometrické) zvýraznění	35
2.3.2 Prostorové (lokální) zvýraznění	35
2.3.3 Spektrální zvýraznění.....	36
2.4 Klasifikace	36
2.4.1 Neřízené metody	36
2.4.2 Řízené metody.....	37
2.4.2.1 Konvenční statistické přístupy.....	37
2.4.2.2 Neuronové sítě a Deep Learning	38

2.5	Postklasifikační úpravy.....	39
2.6	Reklasifikace spektrálních tříd	40
2.7	Hodnocení přesnosti.....	40
3	SOUČASNÝ STAV VE SMĚRU PRÁCE	42
3.1	Potenciál a limity RGB senzorů	42
3.2	Porovnání klasifikačních přístupů a jejich aplikací.....	44
3.2.1	Neřízená vs. řízená klasifikace.....	44
3.2.2	Pixelová vs. objektově orientovaná klasifikace (OBIA)	45
3.2.3	Hluboké učení (Deep Learning) a jeho výzvy.....	46
3.3	Aplikace v odlišných oblastech	46
3.4	Hlavní konsenzus napříč literaturou	47
3.5	Identifikované mezery ve výzkumu a hlavní výzvy	48
4	ZPRACOVÁNÍ UAV DAT A KLASIFIKACE VYBRANÝCH ZÁJMOVÝCH ÚZEMÍ.....	49
4.1	Použité bezpilotní letouny	49
4.2	Definice zájmových území.....	50
4.2.1	Kritéria výběru lokalit.....	50
4.2.2	Charakteristika jednotlivých území.....	51
4.3	Postup zpracování obrazových dat	52
4.3.1	Přípravná fáze sběru obrazových dat.....	52
4.3.2	Letové plánování a akvizice dat	53
4.3.3	Zpracování ortofotosnímků	54
4.3.4	Příprava dat a spektrální zvýraznění	56
4.3.5	Výběr trénovacích ploch	60
4.3.6	Trénování klasifikačních modelů	61
4.3.7	Testování Deep Learning modelu	63
4.3.8	Reklasifikace pro neřízenou klasifikaci ISO Cluster.....	63
4.3.9	Příprava dat pro ověření přesnosti.....	64
4.3.10	Vyhodnocení přesnosti klasifikace pomocí konfuzní matice	65
4.3.11	Extrakce polohy a nadmořské výšky ze snímků.....	67
4.3.12	Extrakce metadat ortofotosnímku pro tvorbu tiráže	68
4.3.13	Výpočet rozlohy analyzovaného a celkového území	68
5	PŘÍPADOVÉ STUDIE – INTERPRETACE A ZHODNOCENÍ VÝSLEDKŮ	70
5.1	Případová studie: klasifikace vegetace – Vraclav	71
5.2	Případová studie: klasifikace spáleného porostu – Albánie.....	80
5.3	Případová studie: klasifikace poškození obilnin – Loučky	89
5.4	Případová studie: klasifikace vegetačních složek – Hrádek.....	98
5.5	Případová studie: klasifikace zaplavené plochy – Čestice	104
5.6	Případová studie: porovnání klasifikačních modelů – Čestice (II)	113
5.7	Případová studie: detekce objektů – sad Trpík	123
	ZÁVĚR	129
	POUŽITÁ LITERATURA	133
	POUŽITÉ OBRÁZKY.....	137
	SEZNAM PŘÍLOH.....	138

SEZNAM OBRÁZKŮ

OBRÁZEK 1:	SPEKTRUM ELEKTROMAGNETICKÉHO ZÁŘENÍ.....	20
OBRÁZEK 2:	MULTISPEKTRÁLNÍ KAMERY PRO LETECKÉ SNÍMKOVÁNÍ.....	29
OBRÁZEK 3:	KONVOLUČNÍ NEURONOVÁ SÍŤ	39
OBRÁZEK 4:	VLIV PŘELETŮ NA PROVOZNÍ DOBU MISE	54
OBRÁZEK 5:	KVALITA ORTOFOTOSNÍMKŮ – FAST-ORTHOPHOTO ZAP./VYP.....	56
OBRÁZEK 6:	ROZHRANÍ APLIKACE GEOSHRINK	57
OBRÁZEK 7:	ROZHRANÍ APLIKACE FCC MULTISPECTRAL IMAGE PROCESSOR.....	57
OBRÁZEK 8:	TVORBA VRSTVY ZÚ V PROSTŘEDÍ ARCGIS PRO	58
OBRÁZEK 9:	OŘEZ ORTOFOTOSNÍMKU DLE POLYGONU ZÚ	58
OBRÁZEK 10:	SEPARACE RASTU A VÝPOČET SPEKTRÁLNÍHO INDEXU	59
OBRÁZEK 11:	TRÉNOVACÍ TŘÍDY – TRAINING SAMPLES MANAGER	60
OBRÁZEK 12:	TRÉNINK DL MODELU – ARCGIS	62
OBRÁZEK 13:	SJEDNOCENÍ TŘÍD NEŘÍZENÉ KLASIFIKACE – RECLASSIFY	64
OBRÁZEK 14:	VALIDAČNÍ BODY – CREATE ACCURACY ASSESSMENT POINTS	65
OBRÁZEK 15:	ROZHRANÍ APLIKACE METRICALC	66
OBRÁZEK 16:	VÝSTUP METRIK Z APLIKACE METRICALC.....	66
OBRÁZEK 17:	APLIKACE IMAGE META LOCATOR.....	67
OBRÁZEK 18:	APLIKACE ORTHOPHOTO TOOL	68
OBRÁZEK 19:	APLIKACE UAV AREA CALCULATOR.....	69
OBRÁZEK 20:	TEMATICKÝ SNÍMEK – PŘÍADOVÁ STUDIE VRACLAV	72
OBRÁZEK 21:	ROZLOHA CÚ A ZÚ – PŘÍADOVÁ STUDIE VRACLAV	72
OBRÁZEK 22:	F1-SKÓRE – PŘÍADOVÁ STUDIE VRACLAV	74
OBRÁZEK 23:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE VRACLAV.....	75
OBRÁZEK 24:	KAPPA INDEX – PŘÍADOVÁ STUDIE VRACLAV	76
OBRÁZEK 25:	POROVNÁNÍ METOD KLASIFIKACE – PŘÍADOVÁ STUDIE VRACLAV	78
OBRÁZEK 26:	SPEKTRÁLNÍ INDEXY – ISO – PŘÍADOVÁ STUDIE VRACLAV.....	79
OBRÁZEK 27:	TEMATICKÝ SNÍMEK – PŘÍADOVÁ STUDIE ALBÁNIE.....	81
OBRÁZEK 28:	ROZLOHA CÚ A ZÚ – PŘÍADOVÁ STUDIE ALBÁNIE.....	81
OBRÁZEK 29:	SPEKTRÁLNÍ INDEXY – ISO – PŘÍADOVÁ STUDIE ALBÁNIE	85
OBRÁZEK 30:	SPEKTRÁLNÍ INDEXY – KNN – PŘÍADOVÁ STUDIE ALBÁNIE	85
OBRÁZEK 31:	SPEKTRÁLNÍ INDEXY – ML – PŘÍADOVÁ STUDIE ALBÁNIE.....	86
OBRÁZEK 32:	SPEKTRÁLNÍ INDEXY – RT – PŘÍADOVÁ STUDIE ALBÁNIE.....	86
OBRÁZEK 33:	SPEKTRÁLNÍ INDEXY – SVM – PŘÍADOVÁ STUDIE ALBÁNIE	87
OBRÁZEK 34:	SPEKTRÁLNÍ INDEXY – DL – PŘÍADOVÁ STUDIE ALBÁNIE.....	87
OBRÁZEK 35:	TEMATICKÝ SNÍMEK – PŘÍADOVÁ STUDIE LOUČKY.....	90
OBRÁZEK 36:	ROZLOHA CÚ A ZÚ – PŘÍADOVÁ STUDIE LOUČKY.....	90
OBRÁZEK 37:	KAPPA INDEX – PŘÍADOVÁ STUDIE LOUČKY	92
OBRÁZEK 38:	SPEKTRÁLNÍ INDEXY – ISO – PŘÍADOVÁ STUDIE LOUČKY	94
OBRÁZEK 39:	SPEKTRÁLNÍ INDEXY – KNN – PŘÍADOVÁ STUDIE LOUČKY	95
OBRÁZEK 40:	SPEKTRÁLNÍ INDEXY – ML – PŘÍADOVÁ STUDIE LOUČKY	95
OBRÁZEK 41:	SPEKTRÁLNÍ INDEXY – RT – PŘÍADOVÁ STUDIE LOUČKY.....	96
OBRÁZEK 42:	SPEKTRÁLNÍ INDEXY – SVM – PŘÍADOVÁ STUDIE LOUČKY	96
OBRÁZEK 43:	SPEKTRÁLNÍ INDEXY – DL – PŘÍADOVÁ STUDIE LOUČKY	97
OBRÁZEK 44:	TEMATICKÝ SNÍMEK – PŘÍADOVÁ STUDIE HRÁDEK.....	99

OBRÁZEK 45:	ROZLOHA CÚ A ZÚ – PŘÍADOVÁ STUDIE HRÁDEK.....	99
OBRÁZEK 46:	POROVNÁNÍ METOD KLASIFIKACE – PŘÍADOVÁ STUDIE HRÁDEK.....	103
OBRÁZEK 47:	TEMATICKÝ SNÍMEK – PŘÍADOVÁ STUDIE ČESTICE.....	105
OBRÁZEK 48:	ROZLOHA CÚ A ZÚ – PŘÍADOVÁ STUDIE ČESTICE.....	105
OBRÁZEK 49:	SPEKTRÁLNÍ INDEXY – ISO – PŘÍADOVÁ STUDIE ČESTICE.....	109
OBRÁZEK 50:	SPEKTRÁLNÍ INDEXY – KNN – PŘÍADOVÁ STUDIE ČESTICE.....	110
OBRÁZEK 51:	SPEKTRÁLNÍ INDEXY – ML – PŘÍADOVÁ STUDIE ČESTICE	110
OBRÁZEK 52:	SPEKTRÁLNÍ INDEXY – RT – PŘÍADOVÁ STUDIE ČESTICE	111
OBRÁZEK 53:	SPEKTRÁLNÍ INDEXY – SVM – PŘÍADOVÁ STUDIE ČESTICE.....	111
OBRÁZEK 54:	SPEKTRÁLNÍ INDEXY – DL – PŘÍADOVÁ STUDIE ČESTICE.....	112
OBRÁZEK 55:	TEMATICKÝ SNÍMEK – PŘÍADOVÁ STUDIE ČESTICE II	114
OBRÁZEK 56:	ROZLOHA CÚ A ZÚ – PŘÍADOVÁ STUDIE ČESTICE II	114
OBRÁZEK 57:	KLASIFIKACE – KONVENČNÍ METODY – PŘÍADOVÁ STUDIE ČESTICE II	120
OBRÁZEK 58:	KLASIFIKACE – DL METODY – PŘÍADOVÁ STUDIE ČESTICE II.....	121
OBRÁZEK 59:	RGB SNÍMEK S VÝŘEZEM – PŘÍADOVÁ STUDIE ČESTICE II.....	122
OBRÁZEK 60:	TEMATICKÝ SNÍMEK – PŘÍADOVÁ STUDIE TRPÍK.....	124
OBRÁZEK 61:	ROZLOHA CÚ A ZÚ – PŘÍADOVÁ STUDIE TRPÍK.....	124
OBRÁZEK 62:	METRIKY DETEKCE OBJEKTŮ – PŘÍADOVÁ STUDIE TRPÍK	125
OBRÁZEK 63:	ROZLOŽENÍ VÝSTUPŮ DETEKCE OBJEKTŮ – PŘÍADOVÁ STUDIE TRPÍK	126
OBRÁZEK 64:	DETEKCE OBJEKTŮ – DL – PŘÍADOVÁ STUDIE TRPÍK	128
OBRÁZEK 65:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE VRACLAV	140
OBRÁZEK 66:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE VRACLAV	141
OBRÁZEK 67:	F1-SKÓRE – PŘÍADOVÁ STUDIE ALBÁNIE.....	142
OBRÁZEK 68:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE ALBÁNIE	143
OBRÁZEK 69:	KAPPA INDEX – PŘÍADOVÁ STUDIE ALBÁNIE.....	144
OBRÁZEK 70:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE ALBÁNIE	145
OBRÁZEK 71:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE ALBÁNIE	146
OBRÁZEK 72:	F1-SKÓRE – PŘÍADOVÁ STUDIE LOUČKY.....	147
OBRÁZEK 73:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE LOUČKY	148
OBRÁZEK 74:	KAPPA INDEX – PŘÍADOVÁ STUDIE LOUČKY.....	149
OBRÁZEK 75:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE LOUČKY	150
OBRÁZEK 76:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE LOUČKY	151
OBRÁZEK 77:	F1-SKÓRE – PŘÍADOVÁ STUDIE HRÁDEK.....	152
OBRÁZEK 78:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE HRÁDEK	152
OBRÁZEK 79:	KAPPA INDEX – PŘÍADOVÁ STUDIE HRÁDEK.....	152
OBRÁZEK 80:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE HRÁDEK.....	153
OBRÁZEK 81:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE HRÁDEK.....	153
OBRÁZEK 82:	F1-SKÓRE – PŘÍADOVÁ STUDIE ČESTICE	155
OBRÁZEK 83:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE.....	156
OBRÁZEK 84:	KAPPA INDEX – PŘÍADOVÁ STUDIE ČESTICE	157
OBRÁZEK 85:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE	158
OBRÁZEK 86:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE	159
OBRÁZEK 87:	F1-SKÓRE – PŘÍADOVÁ STUDIE ČESTICE II	160
OBRÁZEK 88:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE II	160
OBRÁZEK 89:	KAPPA INDEX – PŘÍADOVÁ STUDIE ČESTICE II.....	161
OBRÁZEK 90:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE II.....	161

OBRÁZEK 91:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE II.....	162
OBRÁZEK 92:	TERÉNNÍ PRŮZKUM ZÚ – VRACLAV.....	186
OBRÁZEK 93:	TERÉNNÍ PRŮZKUM ZÚ – ALBÁNIE	186
OBRÁZEK 94:	TERÉNNÍ PRŮZKUM ZÚ – LOUČKY	187
OBRÁZEK 95:	LETECKÝ PRŮZKUM ZÚ (DJI MINI 3 PRO) – ČESTICE.....	187
OBRÁZEK 96:	DJI PHANTOM 4 PRO V MISI	188

SEZNAM TABULEK

TABULKA 1:	SROVNÁNÍ SNÍMACÍCH SYSTÉMŮ PHANTOM 4 VS. PHANTOM 4 PRO	49
TABULKA 2:	KONFUZNÍ MATICE KLASIFIKACE – NEZPRACOVANÝ EXPORT DO CSV.....	65
TABULKA 3:	F1-SKÓRE – PŘÍADOVÁ STUDIE VRACLAV	74
TABULKA 4:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE VRACLAV.....	75
TABULKA 5:	KAPPA INDEX – PŘÍADOVÁ STUDIE VRACLAV	76
TABULKA 6:	F1-SKÓRE – PŘÍADOVÁ STUDIE ALBÁNIE.....	83
TABULKA 7:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE ALBÁNIE	83
TABULKA 8:	KAPPA INDEX – PŘÍADOVÁ STUDIE ALBÁNIE.....	83
TABULKA 9:	F1-SKÓRE – PŘÍADOVÁ STUDIE LOUČKY.....	92
TABULKA 10:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE LOUČKY	92
TABULKA 11:	KAPPA INDEX – PŘÍADOVÁ STUDIE LOUČKY.....	93
TABULKA 12:	F1-SKÓRE – PŘÍADOVÁ STUDIE HRÁDEK.....	101
TABULKA 13:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE HRÁDEK	101
TABULKA 14:	KAPPA INDEX – PŘÍADOVÁ STUDIE HRÁDEK.....	102
TABULKA 15:	F1-SKÓRE – PŘÍADOVÁ STUDIE ČESTICE	107
TABULKA 16:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE.....	107
TABULKA 17:	KAPPA INDEX – PŘÍADOVÁ STUDIE ČESTICE	107
TABULKA 18:	F1-SKÓRE – PŘÍADOVÁ STUDIE ČESTICE II	117
TABULKA 19:	CELKOVÁ PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE II	117
TABULKA 20:	KAPPA INDEX – PŘÍADOVÁ STUDIE ČESTICE II.....	118
TABULKA 21:	METRIKY DETEKCE OBJEKTŮ – PŘÍADOVÁ STUDIE TRPÍK	126
TABULKA 22:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE VRACLAV	140
TABULKA 23:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE VRACLAV	141
TABULKA 24:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE ALBÁNIE	145
TABULKA 25:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE ALBÁNIE	146
TABULKA 26:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE LOUČKY	150
TABULKA 27:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE LOUČKY	151
TABULKA 28:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE HRÁDEK.....	153
TABULKA 29:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE HRÁDEK.....	154
TABULKA 30:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE	158
TABULKA 31:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE	159
TABULKA 32:	UŽIVATELSKÁ PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE II.....	162
TABULKA 33:	PRODUCENTOVA PŘESNOST – PŘÍADOVÁ STUDIE ČESTICE II.....	163

SEZNAM QR KÓDŮ

QR KÓD 1:	INTERAKTIVNÍ VÝSTUP – KLASIFIKACE VEGETACE VRACLAV	71
QR KÓD 2:	INTERAKTIVNÍ VÝSTUP – KLASIFIKACE SPÁLENÉHO POROSTU ALBÁNIE.....	80
QR KÓD 3:	INTERAKTIVNÍ VÝSTUP – KLASIFIKACE POŠKOZENÍ OBILNIN LOUČKY.....	89
QR KÓD 4:	INTERAKTIVNÍ VÝSTUP – KLASIFIKACE VEGETAČNÍCH SLOŽEK HRÁDEK.....	98
QR KÓD 5:	INTERAKTIVNÍ VÝSTUP – KLASIFIKACE ZAPLAVENÉ PLOCHY ČESTICE	104
QR KÓD 6:	INTERAKTIVNÍ VÝSTUP – POROVNÁNÍ KLASIFIKAČNÍCH MODELŮ ČESTICE.....	113
QR KÓD 7:	INTERAKTIVNÍ VÝSTUP – DETEKCE OBJEKTŮ, SAD TRPÍK	123

SEZNAM ZKRATEK A ZNAČEK

AGL	Above Ground Level (Výška nad terénem)
API	Application Programming Interface (Rozhraní pro komunikaci mezi softwarovými komponentami)
Back Bone	Páteří model hlubokého učení (Základní architektura v modelu hlubokého učení)
CIELab	Commission Internationale de l'Éclairage L*a*b* (Barevná prostorová reprezentace)
CIR	Color Infrared (Barevné infračervené snímky využívané pro analýzu vegetace)
CMCA	Conventional Multi Classifier Approach (Metoda kombinující více klasifikačních algoritmů)
CNN	Convolutional Neural Network (Konvoluční neuronová síť pro analýzu obrazů)
CPU	Central Processing Unit (Centrální procesorová jednotka)
CRS	Coordinate Reference System (Souřadnicový referenční systém pro určení polohy na Zemi)
CSV	Comma Separated Values (Formát souboru pro ukládání tabulkových dat)
CÚ	Celkové území (Celková oblast, která byla snímána)
DeepLab V3	Pokročilá architektura hlubokého učení pro sémantickou segmentaci obrazu
DL	Deep Learning (Hluboké učení založené na vícevrstvých neuronových sítích)
DMT	Digital Model Terrain (Digitální reprezentace terénu bez objektů)
DN	Digital Number (Číslíková hodnota pixelu v digitálním obrazu představující jas)
DPZ	Dálkový průzkum Země (Metoda sběru dat o Zemi z dálky)
DSM	Digital Surface Model (Digitální model povrchu včetně terénu a nadzemních objektů)
DSPSIFT	Deep Structured Prediction SIFT (Rozšířená detekce klíčových bodů pomocí hlubokého učení)
EM	Elektromagnetický (Vztahující se k elektromagnetickému záření)
EPSG	European Petroleum Survey Group (Systém kódů pro geodetické referenční systémy)
ExGI	Excess Green Index (Index nadměrné zeleně využívaný k detekci vegetace)
F1-skóre	Harmonický průměr mezi Precision a Recall (Hodnocení rovnováhy klasifikačního modelu)
FCC	False Color Composite (Falešná barevná kompozice pro zvýraznění prvků)
FCN	Fully Convolutional Network (Plně konvoluční síť pro sémantickou segmentaci)
FN	False Negatives (Chybně klasifikované instance jako negativní)
FP	False Positives (Chybně klasifikované instance jako pozitivní)
GAN	Generative Adversarial Network (Generativní síť pro tvorbu realistických dat)
GBRWI	Green-Blue-Red Water Index (Index vody využívající zelenou, modrou a červenou složku)
GCC	Green Chromatic Coordinate (Index zelené chromatické souřadnice, míra zeleně v obraze)
GCP	Ground Control Point (Bod kontroly na zemi se známými údaji)
GEO	Geostacionární dráha (Oběžná dráha, kde satelit setrvává nad stejným místem na Zemi)
GeoTIFF	Georeferenced Tagged Image File Format (Obrazový formát s georeferencí)
GLI	Green Leaf Index (Index zelených listů pro hodnocení vegetace)
GLI2	Green Leaf Index 2 (Modifikovaný index zelených listů pro detekci vegetace)
GNSS	Global Navigation Satellite System (Globální navigační satelitní systém)
GOES	Geostationary Operational Environmental Satellite (Geostacionární environmentální satelit)
GPS	Global Positioning System (Globální satelitní navigační systém pro určení polohy)

GPU.....	Graphics Processing Unit (Grafický procesor pro paralelní výpočty a grafické operace)
GSD.....	Ground Sampling Distance (Vzdálenost vzorkování, udává prostorové rozlišení)
GUI.....	Graphical User Interface (Grafické uživatelské rozhraní pro práci se softwarem)
GVI.....	Green Vegetation Index (Index zelené vegetace pro hodnocení přítomnosti vegetace)
HEO	High Elliptical Orbit (Vysoká eliptická dráha se zvýšenou excentricitou))
HSR.....	High Spatial Resolution (Vysoké prostorové rozlišení s malým GSD)
HSV.....	Hue, Saturation, Value (Barevný model založený na odstínu, sytosti a jasu)
CHM.....	Canopy Height Model (Model výšky vegetace nad terénem)
IMU	Inertial Measurement Unit (Inerciální měřicí jednotka pro sledování pohybu a orientace)
InSAR.....	Interferometric SAR (Interferometrická radarová technika pro měření deformací povrchu)
IR.....	Infrared (Infračervené záření používané v dálkovém průzkumu)
ISO	ISO-Cluster (Neřízený klasifikační algoritmus pro automatické seskupování pixelů)
Kappa	Cohenova Kappa (Míra shody predikcí se skutečností s korekcí na náhodu)
KNN	K-Nearest Neighbor (Algoritmus k-nejbližších sousedů pro klasifikaci a regresi)
LAI.....	Leaf Area Index (Index listové plochy vyjadřující hustotu vegetace)
LEO	Low Earth Orbit (Nízká oběžná dráha používaná pro většinu průzkumných satelitů)
Mask R-CNN	Mask Region-based CNN (Síť pro detekci a segmentaci objektů v obraze)
MEO.....	Medium Earth Orbit (Střední oběžná dráha, mezi LEO a GEO)
MGLI	Modified Green Leaf Index 2 (Modifikovaný index zelených listů pro lepší detekci vegetace)
ML.....	Maximum Likelihood (Statistická metoda odhadu maximální pravděpodobnosti)
MLC.....	Maximum Likelihood Classifier (Klasifikátor maximální pravděpodobnosti)
MMS	Mobile Mapping Systém (Mobilní systém pro sběr geoprostorových dat)
MS.....	Multispectral (Multispektrální (snímky) s více spektrálními pásmy)
MSAVI	Modified Soil Adjusted Vegetation Index (Modifikovaný index s potlačením vlivu půdy)
MTOM	Maximum Take-off Mass (maximální vzletová hmotnost při startu)
MWIR	Mid-Wave Infrared (Střední infračervené záření používané pro tepelné snímky)
N/A.....	Not Applicable (Nepoužitelné; označení chybějících nebo nerelevantních dat)
NBR	Normalized Burn Ratio (Normalizovaný index spálení pro detekci požárů)
NCPL	Non-Commercial Public License (NCPL v1.0 – autorova licence pro GitHub projekty)
NDVI.....	Normalized Difference Vegetation Index (Index pro hodnocení vegetace)
NGBDI.....	Normalized Green-Blue Difference Index (Index pro detekci vody či vegetace)
NGRDI.....	Normalized Green-Red Difference Index (Index pro RGB vegetační analýzu)
NIR.....	Near Infrared (Blízké infračervené záření pro analýzu vegetace a půdy)
NMS.....	Non Maximum Suppression (Potlačení nemaximálních hodnot při detekci objektů)
OA.....	Overall Accuracy (Celková přesnost klasifikace)
OBIA.....	Object-Based Image Analysis (Objektově orientovaná analýza založená na segmentech obrazu)
ODM	OpenDroneMap (Software pro zpracování dat z dronů)
P4	DJI Phantom 4 (Model dronu od DJI)
P4 Pro.....	DJI Phantom 4 Pro (Model dronu od DJI)

PAN.....	Panchromatic (Panchromatický snímek v širokém spektrálním pásmu)
PointRend.....	Technika pro zlepšení hranic segmentace objektů v obraze
PPK	Post-Processed Kinematic (Metoda dodatečného zpracování GNSS pro přesné určení polohy)
Precision.....	Přesnost / Uživatelská přesnost (Míra správnosti pozitivních predikcí modelu)
PSPNet	Pyramid Scene Parsing Network (Síť pro sémantickou segmentaci kontextu)
Recall	Citlivost / Producentova přesnost (Schopnost modelu najít všechny relevantní instance)
ResNet.....	Residual Network (Reziduální síť s propojeními)
RGB	Red Green Blue (Barevný model používaný pro digitální obrazy)
RGBVI	Red Green Blue Vegetation Index (Index z RGB obrazu pro hodnocení vegetace bez NIR)
ROI.....	Region of Interest (Oblast zájmu pro specifickou analýzu)
RT.....	Random Trees (Algoritmus náhodných stromů pro klasifikaci a regresi)
RTF	Ready to Flight (Sestava dronu připravená k okamžitému použití)
RTK.....	Real-Time Kinematic (Metoda přesného určování polohy pomocí GNSS v reálném čase)
SAR.....	System Aperture Radar (Radarová technika pro tvorbu obrazů Země nezávisle na počasí)
SAVI	Soil Adjusted Vegetation Index (Vegetační index s úpravou pro potlačení vlivu půdy)
SIFT	Scale-Invariant Feature Transform (Algoritmus pro detekci měřítkově invariantních bodů)
SNDR	Stabilized Normalized Difference Green-Red (Index rozdílu zelené a červené)
SVM.....	Support Vector Machine (Algoritmus pro klasifikaci a regresi založený na podpůrných vektorech)
SWIR.....	Short-wave Infrared (Krátkovlnné infračervené záření pro analýzu minerálů a vlhkosti)
TGI.....	Triangular Greenness Index (Index zeleně pro hodnocení chlorofylu)
TIFF	Tagged Image File Format (Formát pro rastrové obrázky)
TIR	Thermal Infrared (Termální infračervené záření pro měření teploty povrchu)
TLS.....	Terrestrial Laser Scanning (Terestrické laserové skenování pro sběr detailních 3D dat)
TP	True Positives (Správně klasifikované pozitivní instance)
U-Net.....	Convolutional Network for Biomedical Image Segmentation (Konvoluční síť pro segmentaci)
UAS.....	Unmanned Aerial System (Bezposádkový letecký systém včetně ovládacích prvků)
UAV	Unmanned Aerial Vehicle (Bezposádkové letecké vozidlo, dron)
UTM.....	Universal Transverse Mercator (Souřadnicový systém)
UV	Ultraviolet (Ultrafialové záření)
VARI.....	Visible Atmospherically Resistant Index (Index odolný vůči atmosférickým vlivům)
vCPU	Virtual Central Processing Unit (Virtuální procesor v cloud computingu)
VGG-16.....	Visual Geometry Group 16 (16vrstvá hluboká síť, často používaná jako páteř)
VHSR	Very High Spatial Resolution (Velmi vysoké prostorové rozlišení, např. pod 0,5 m GSD)
VIS	Visible Spectrum (Viditelné spektrum elektromagnetického záření)
VTOL	Vertical Take-Off and Landing (Schopnost vertikálního vzletu a přistání)
WGS 84.....	World Geodetic System 1984 (Referenční systém pro GPS a globální mapování)
ZÚ	Zájmové území (Specifická oblast pro studium nebo mapování)

ÚVOD

V posledních desetiletích se bezpilotní letouny (UAV) staly klíčovým nástrojem v oblasti dálkového průzkumu Země díky schopnosti sbírat obrazová data s vysokým rozlišením rychle, flexibilně a s nízkými náklady. Využití UAV v environmentálním monitoringu, zemědělství, urbanismu a dalších oborech přináší nové možnosti pro detailní analýzu a správu území. Tato diplomová práce, nazvaná Klasifikace UAV obrazových dat v rámci vybraných území, se zaměřuje na využití obrazových dat získaných z UAV pro klasifikaci různých typů krajinného pokryvu a detekci specifických jevů a objektů. Mezi zkoumané jevy patří poškození vegetace a zaplavení oblasti, zatímco detekce objektů se věnuje inventarizaci sadu.

Hlavním cílem, v rámci několika případových studií, je prozkoumat a prakticky otestovat různé klasifikační metody, od tradičních statistických přístupů po moderní techniky hlubokého učení. Dále práce představuje vlastní softwarové nástroje vyvinuté v jazyce Python pro automatizaci a zefektivnění procesu analýzy UAV dat a dále specifické spektrální indexy pro zvýraznění spáleného porostu, zaplavených oblastí a poškozené vegetace.

Práce kombinuje teoretické poznatky z dálkového průzkumu Země a digitálního zpracování obrazových dat s vlastními praktickými experimenty. Data byla sbírána pomocí UAV vybavených RGB senzory a následně zpracována do ortofotosnímků. Pro klasifikaci jsou použity jak řízené, tak neřízené klasifikační algoritmy, včetně hlubokého učení s využitím sítí jako U-Net, VGG16 a ResNet-50. Přesnost výsledků je hodnocena pomocí standardních metrik, jako jsou F1-skóre, Kappa index a Celková přesnost, vypočítaných z matic záměn.

Text je strukturován do několika kapitol, které postupně vedou čtenáře od teoretických základů k praktickým aplikacím. Úvodem jsou představeny klíčové koncepty a technologie dálkového průzkumu Země. Následující kapitola se zaměřuje na digitální zpracování obrazových dat, včetně metod předzpracování a klasifikace. Dále jsou zmíněny studie reflektující současný stav v daném oboru a jeho výzvy. Praktická část obsahuje detailní metodiku pracovního postupu zpracování UAV dat a klasifikace vybraných zájmových území prezentovaných na případových studiích, včetně jejich interpretace a zhodnocení. Práce je zakončena přílohami s doplňujícími informacemi a výstupy. Poznatky práce mohou najít uplatnění v zemědělství, environmentálním managementu sledujícím vegetaci a změny krajinného pokryvu, pojišťovnictví, správě pozemků, či interních analýzách podniku.

1 DÁLKOVÝ PRŮZKUM ZEMĚ

Dálkový průzkum Země, zkráceně DPZ, představuje vědecko-technický obor, který bezkontaktně získává informace o objektech a jevech na zemském povrchu (Lillesand et al., 2015, s. 1). Základním principem je detekce a záznam energie odražené či emitované povrchem specializovanými senzory. Hlavním zdrojem je odražené sluneční elektromagnetické (EM) záření.

Proces DPZ zahrnuje dvě navazující fáze zahrnující akvizici dat ze satelitních, leteckých, UAV či pozemních platforem a poté jejich geometrické i radiometrické korekce, fúze, klasifikace a interpretace pro tvorbu prostorově explicitních informací (Lillesand et al., 2015, s. 2, 485). Senzory jsou pasivní (zaznamenávají přirozené záření) nebo aktivní, např. SAR či LiDAR, jež vysílají vlastní signál a jsou téměř nezávislé na denní době ani počasí.


Platformy pro DPZ jsou rozlišovány na družice (Sentinel, Landsat), pilotované lety pomocí leteckých misí a bezpilotní prostředky (UAV). Ty se liší rozlišením, záběrem i flexibilitou (Lillesand et al., 2015, s. 30–33). Kvalitu dat určují prostorové, časové a radiometrické rozlišení a doba opakovaného snímání.

Podle Koláře (1990, s. 7–10) lze celý systém DPZ chápat jako sled tří navazujících bloků: 1) krajinu a atmosféru, které představují zdroj měřeného signálu, 2) měřicí aparaturu včetně palubního předzpracování a záznamu dat a 3) pozemní zpracování dat, při němž se naměřené veličiny převádějí do informací využitelných pro praxi. Kolář (1990) dále zdůrazňuje, že DPZ nabývá smyslu teprve tehdy, když se takto získaná informace stane podkladem pro rozhodování a řízení lidských aktivit v krajině. DPZ slouží kartografii, geologii, hydrologii, zemědělství, lesnictví, krizovému managementu, monitoringu katastrof, urbanismu a sledování klimatických dopadů (Lillesand et al., 2015, s. 609). Propojení s GIS a strojovým učením umožňuje téměř v reálném čase poskytovat globální data s metrovou až centimetrovou přesností (Lillesand et al., 2015, s. 573, 591–597).

1.1 Elektromagnetické spektrum v DPZ

Rychlost šíření světla v prostředí se řídí vztahem $v = c/n$, kde v [m/s] je rychlost světla v prostředí, c [m/s] rychlost světla ve vakuu ($\approx 3 \times 10^8$ m/s) a n index lomu daného prostředí (např. pro vzduch $n \approx 1,0003$). Základními parametry jsou vlnová délka a frekvence určené vztahem $v = \lambda \times \nu$. Vlnová délka (λ) je vzdálenost mezi vrcholy vlny [m] a frekvence (ν) počet cyklů za jednotku času [Hz] (Campbell & Wynne, 2011, s. 33). Tyto veličiny jsou mezi sebou nepřímo úměrné (Lillesand et al., 2015, s. 4–6; Gonzalez & Woods, 2018, s. 55). EM spektrum zahrnuje celý rozsah možných vlnových délek, viz obrázek 1, avšak DPZ využívá pouze jeho část. Atmosféra část absorbuje nebo rozptyluje, takže nedorazí k povrchu ani k senzoru. Tyto

oblasti spektra, pro které je atmosféra propustná, se označují jako atmosférická okna a mají pro DPZ klíčový význam (Longley et al., 2015 str.176–177; Lillesand et al., 2015, s. 9–16 a 250–252). Senzory na družicích a letadlech pracují právě v těchto oknech a pokrývají UV, viditelné, IR i mikrovlnné záření (Kolář 1990, s. 38–44; Campbell & Wynne, 2011, s. 47). Následná analýza rozdílů v odražené nebo emitované energii různými typy povrchů, jako je vegetace, voda, půda nebo zástavba, umožňuje odvodit jejich fyzikální a biochemické vlastnosti.



Obrázek 1: Spektrum elektromagnetického záření

Zdroj: [Indutivload, b.r.]

1.1.1 Ultrafialové záření

Ultrafialová (UV) část spektra ($\sim 0,01\text{--}0,4\ \mu\text{m}$) se pro účely DPZ využívá jen omezeně (Lillesand et al., 2015, s. 5, 9–11; Kolář 1990, s. 16). Hlavním důvodem jsou interakce UV záření se zemskou atmosférou (Campbell & Wynne, 2011, s. 34). UV záření je silně pohlcováno stratosférickou ozonovou vrstvou a intenzivně rozptylováno molekulárním Rayleighovým rozptylem.

Na zemský povrch tak dopadá jen zanedbatelná část původního UV záření, a ještě menší množství se odrazí zpět k senzoru na oběžné dráze (Dobrovolný, 1998; Kolář, 1990, s. 32–33; Lillesand et al., 2015, s. 9–10). Snímkování odraženého UV je tudíž nepraktické, neboť atmosférický rozptyl přehluší signál povrchu. Výjimkou je geologický průzkum využívající jev fluorescence – některé horniny a minerály po osvětlení UV zářením emitují sekundární záření o delších, obvykle viditelných vlnových délkách. Senzory poté tuto emisi zachytí a usnadní mapování geologických materiálů. Aplikace této metody je však zpravidla omezena na průzkum z nízkých letových výšek s využitím aktivního zdroje UV záření (Lillesand et al., 2015, s. 108, 218–219). Mimo DPZ se UV snímkování využívá v průmyslové inspekci, mikroskopii, biologii či astronomii (Gonzalez a Woods, 2018, s. 9–10).

1.1.2 Viditelné spektrum

Viditelné spektrum zahrnuje oblast EM záření, na kterou je citlivé lidské oko. Pokrývá $\lambda \approx 0,4\text{--}0,7\ \mu\text{m}$ (Lillesand et al., 2015, s. 5–6; Kolář 1990, s. 16; Campbell & Wynne 2011, s. 35). Přestože jde o relativně úzký výsek celého EM spektra, jeho význam pro dálkový průzkum je zásadní. Data z tohoto pásma umožňují tvorbu snímků, jež lidský pozorovatel intuitivně chápe a snadno interpretuje (Gonzalez a Woods, 2018, s. 56; Pratt, 2001, s. 47). Dělí se na modrou ($\sim 0,4\text{--}0,5\ \mu\text{m}$), zelenou ($\sim 0,5\text{--}0,6\ \mu\text{m}$) a červenou ($\sim 0,6\text{--}0,7\ \mu\text{m}$) složku (Lillesand et al., 2015, s. 5; Gonzalez & Woods 2018, s. 401).

Barva jakéhokoliv objektu na zemském povrchu závisí na poměru absorpce a odrazu v těchto třech pásmech. Senzory DPZ fungují na analogickém principu, kdy kvantifikují intenzitu odraženého záření v jednotlivých spektrálních kanálech (Lillesand et al., 2015, s. 32; Dobrovolný, 1998). Chlorofyl ve zdravých rostlinách silně absorbuje energii v modré a červené části spektra, zatímco zelenou složku odráží, a proto se rostliny jeví zeleně.

DPZ senzory tak v zeleném pásmu zaznamenávají u vegetace vysokou hodnotu odrazivosti (Lillesand et al., 2015, s. 16, 32; Kolář, 1990, s. 100–101). Vodní plochy naopak absorbují většinu viditelného záření, a proto se jeví tmavě. Přítomnost nerozpuštěných sedimentů ve vodě zvyšuje její odrazivost, což vede ke světlejším, často modrozeleným odstínům (Lillesand et al., 2015, s. 19–20; Kolář, 1990, s. 103–107).

Spojením třech pásem vzniká tzv. pravobarevný kompozit (True Color Composite), kde červené, zelené a modré pásmo tvoří odpovídající kanály (Lillesand 2015, s. 33, 532). Výsledný obraz tak věrně kopíruje lidské vnímání barev (Gonzalez & Woods 2018, s. 420; Russ & Neal 2018, s. 42).

1.1.3 Blízké infračervené pásmo (NIR)

Blízké infračervené pásmo ($\sim 0,7\text{--}1,3\ \mu\text{m}$) navazuje na viditelné spektrum, je oku skryté, ale DPZ senzory jej spolehlivě registrují jako odražené sluneční záření, nikoli tepelné emise (Lillesand et al., 2015, s. 5, 8; Campbell & Wynne 2011, s. 36). NIR má klíčovou hodnotu pro analýzu vegetace, neboť zdravá rostlinná biomasa odráží v NIR pásmu až 40–50 % dopadající energie. Tento jev souvisí s houbovitou strukturou mezofylu rozptylující NIR záření.

Míra této odrazivosti přímo koreluje s vitalitou a zdravotním stavem rostliny. Při stresu (sucho, choroby) se buněčná struktura rozpadá a odrazivost v NIR prudce klesá. Z tohoto důvodu se NIR využívá k monitorování lesů i plodin (Lillesand et al., 2015, s. 16–17, 229, 518–520; Dobrovolný 1998). Dalším významným využitím je mapování vody, která v kapalném skupenství toto záření

absorbuje. Řeky, jezera i moře proto vypadají velmi tmavě a ostře kontrastují se souší, což usnadňuje jejich vymezení (Lillesand et al., 2015, s. 19; Kolář 1990, s. 18–21; Dobrovolný 1998).

Vzhledem k vysokému informačnímu obsahu NIR pásma se v praxi často vytvářejí nepravobarevné kompozity FCC/CIR (False Color Composite, Color Infrared) (Lillesand et al., 2015, s. 33, 532), kde se NIR přiřadí červenému kanálu, R zelenému a G modrému (Lillesand et al., 2015, s. 33, 532). Na výsledném kompozitu se zdravá vegetace zobrazuje sytě červeně, zatímco městské oblasti, holá půda a silnice přecházejí do modrozelených odstínů a voda se jeví tmavě modrá až černá. Tato vizualizace usnadňuje rozlišení vegetace, její kondice i identifikaci vody (Lillesand et al., 2015, s. 427–428).

1.1.4 Střední infračervené a termální infračervené pásmo (SWIR a TIR)

Tato část spektra se od viditelného a blízkého infračerveného (NIR) pásma zásadně liší povahou měřeného záření. Zatímco NIR ($\sim 0,7\text{--}1,3\ \mu\text{m}$) zaznamenává odražené sluneční záření, SWIR (střední infračervené) ($\sim 1,3\text{--}3,0\ \mu\text{m}$) a především TIR (termální infračervené) ($\sim 8\text{--}14\ \mu\text{m}$) registrují energii, kterou povrch sám vyzařuje (Lillesand et al., 2015, s. 5, 8; Gonzalez a Woods, 2018, s. 30; Campbell & Wynne, 2011, s. 36).

Každé těleso teplejší než 0 K vyzařuje tepelné záření, jehož množství i spektrální charakter je určen teplotou a emisivitou povrchu. Emisivita je materiálová vlastnost, která popisuje, jak efektivně daný povrch vyzařuje energii v porovnání s ideálním „absolutně černým tělesem“. Proto senzory v TIR neměří odraz, ale přímo radiační teplotu povrchu. Tato vlastnost umožňuje satelitům, jako je například Landsat, pořizovat termální data i během noci (Lillesand et al., 2015, s. 6–7; Gonzalez a Woods, 2018, s. 45).

Pro termální DPZ jsou klíčová atmosférická okna MWIR ($3\text{--}5\ \mu\text{m}$) a TIR ($8\text{--}14\ \mu\text{m}$). Ostatní délky jsou absorbovány vodní párou a CO_2 (Lillesand et al., 2015, s. 10, 243, 251; Russ & Neal 2016, s. 304). TIR se využívá ke sledování mořských proudů, tepelných ostrovů, sopek, požárů, tepelné setrvačnosti hornin, vývěrů podzemní vody i tepelných ztrát budov (Lillesand et al., 2015, s. 244, 260–262, 374, 652). V zemědělství a hydrologii slouží k detekci vodního stresu plodin – nedostatečně zavlažené porosty jsou teplejší, protože omezují transpiraci, což je proces uvolňování vodní páry z rostlin do atmosféry, který je primárně zodpovědný za jejich ochlazování. Radiační teplota, kterou TIR senzor snímá závisí i na emisivitě, tudíž voda ($\varepsilon \approx 1$) vykazuje reálnou radiační teplotu, ale lesklý kov s nízkou emisivitou působí opticky chladněji (Lillesand et al., 2015, s. 252–253, 258).

1.1.5 Mikrovlnné pásmo

Mikrovlnné pásmo zahrnuje nejdelší vlnové délky běžně využívané v DPZ (~ 1 mm–1 m) (Campbell & Wynne, 2011, s. 36, 204) a využívá princip aktivního senzoru viz kapitola 1.3.2. Ve zkratce to tedy znamená, že senzor vysílá mikrovlnné signály a měří jejich zpětný dopad. Tomuto principu se říká RADAR (Radio Detection and Ranging) (Lillesand et al., 2015, s. 385–386). Jelikož využívá vlastní generaci energie, funguje ve dne, v noci i skrze mraky, déšť a mlhu (Lillesand et al., 2015, s. 385–386, 441; Sabins 2007, s. 360–365).

Jev zpětného rozptylu tzv. backscatter u radaru ovlivňují tři vlastnosti:

- **Drsnost:** hladké povrchy (např. klidná voda) odrážejí energii mimo senzor a jsou tmavé; drsné povrchy (zorané pole, koruny stromů) rozptylují signál všemi směry a jsou světlé (Lillesand et al., 2015, s. 418–419; Dobrovolný, 1998).
- **Orientace:** povrchy kolmé k paprsku se jeví světlé; odvrácené svahy leží v radarovém stínu a jsou černé (Lillesand et al., 2015, s. 417–418; Dobrovolný, 1998).
- **Dielektrické vlastnosti:** u nich rozhoduje především obsah vody: vlhké půdy a vegetace s vyšší dielektrickou konstantou odrážejí silněji a jsou světlejší (Lillesand et al., 2015, s. 420–421, 425–427; Dobrovolný, 1998).

Radar se proto uplatňuje při mapování záplav a vlhkosti půdy, sledování mořského ledu či ropných skvrn a tvorbě digitálních modelů terénu (DMT) pomocí radarové interferometrie (InSAR). Ta využívá fázový rozdíl signálů ke generování velmi přesných výškových modelů terénu (DEM) (Lillesand et al., 2015, s. 435–458). Delší vlny (např. L pásmo) pronikají korunou stromů, což usnadňuje monitorování odlesňování a ilegální těžby (Lillesand et al., 2015, s. 425–427).

1.2 Platformy DPZ

Platforma DPZ nese senzory pořizující data o povrchu Země. Volba platformy určuje prostorové a časové rozlišení i pokrytí. Dělíme je na pozemní, letecké a kosmické. Pozemní měření slouží hlavně k lokální kalibraci, zatímco systematická data jsou poskytována leteckými a družicovými platformami (Lillesand et al., 2015, s. 39, 46–47). Letecké platformy (letadla, vrtulníky, UAV) jsou flexibilní a pořizují data s velmi vysokým (centimetrovým až decimetrovým) detailem (Lillesand et al., 2015, s. 46–47). Nevýhodou je omezení na menší území. Naopak kosmické platformy (umělé družice) tvoří páteř globálního DPZ (Lillesand et al., 2015, s. 283; Kolář, 1990, s. 84). Poskytují opakovaná globální pozorování pro sledování změn využití půdy, odlesňování a úbytku ledovců (Lillesand et al., 2015, s. 284–285; Longley et al., 2015, s. 175–179).

1.2.1 Družicové systémy

Družicové systémy představují nejrozšířenější kosmickou platformu DPZ (Lillesand et al., 2015, s. 283; Kolář 1990, s. 84). Jedná se o umělá tělesa (družice), obíhající planetu po pevných oběžných drahách (orbitách), která jsou vybavena specializovanými senzory pro sběr dat o zemském povrchu, oceánech a atmosféře. Výška a sklon dráhy určují záběr, rozlišení a revisit, tedy interval přeletu nad stejným územím. (Lillesand et al., 2015, s. 284–285). Oproti letadlům poskytují družice konzistentní, opakované pokrytí rozsáhlých území, proto jsou klíčové pro sledování klimatických změn, odlesňování či stavu plodin v národním i kontinentálním měřítku (Lillesand et al., 2015, s. 283; Longley et al., 2015, s. 177).

Typ orbity určuje využití družic. Hlavními kategoriemi jsou nízké polární a geostacionární dráhy (Lillesand et al., 2015, s. 286–288).

1.2.1.1 Nízkodráhové polárně-orbitální systémy (LEO)

Nízkodráhový systém, LEO (Low Earth Orbit) je nejčastější orbita určená pro detailní pozorování Země. Leží ve výšce ~ 200–2 000 km (Lillesand et al., 2015, s. 287, 383). Klíčovou podkategorií jsou polární a téměř polární dráhy, kdy družice obíhají s vysokým sklonem vůči rovníku, což umožňuje postupné pokrytí celého povrchu včetně pólů díky rotaci Země během oběhů (Lillesand et al., 2015, s. 286; Longley et al., 2015, s. 286).

Většina je navržena jako slunečně-synchronní (sun-synchronous). Jedná se o specifický typ orbit, jejichž rovina se precesí (postupný posun roviny oběžné dráhy způsobený nerovnoměrným gravitačním polem Země) otáčí tak, aby družice přeletěla nad libovolným místem v konstantní místní sluneční čas. Tato vlastnost zaručuje konzistentní osvětlení a úhel dopadu slunečních paprsků, což umožňuje spolehlivé porovnávání snímků z různých dnů či let bez zkreslení proměnlivými stíny (Lillesand et al., 2015, s. 286, 289; Longley et al., 2015, s. 180). Nízká výška umožňuje vysoké až velmi vysoké rozlišení. Typickými platformami jsou Landsat, Sentinel 2, SPOT a komerční VHR družice.

1.2.1.2 Geostacionární systémy (GEO)

Geostacionární dráha je kruhová rovníková orbita klíčová pro DPZ i telekomunikace. Nachází se ve výšce necelých 36 000 km nad rovníkem a její oběžná perioda je shodná se siderálním dnem (tj. dobou jedné otočky Země vůči vzdáleným hvězdám, přibližně 23 h 56 min 4 s), což učiní družici zdánlivě nehybnou vůči povrchu (Lillesand et al., 2015, s. 286–288; Kolář, 1990, s. 87). Tímto pokrývají z jediné pozice ~ 42 % Země a poskytují nepřetržitá data. Uplatňují se hlavně v meteorologii (GOES – Geostationary Operational Environmental Satellite a Meteosat) a v televizních / datových přenosech (Lillesand et al., 2015, s. 365–366; Sabins 2007, s. 361–365).

Jejich velká vzdálenost omezuje prostorové rozlišení oproti LEO, proto pro detailní mapování volíme LEO, avšak GEO dominuje tam, kde je klíčové vysoké časové, nikoli prostorové rozlišení (Lillesand et al., 2015, s. 289, 359; Kolář 1990, s. 87).

1.2.1.3 Komerční systémy

Zatímco rané fáze dálkového průzkumu Země byly doménou státem financovaných programů, jako byl americký Landsat, od 90. let 20. století se zahájil dynamický rozvoj komerčního sektoru. Změna legislativy USA dovolila firmám provozovat a prodávat data z vlastních družic (Longley et al., 2015, s. 175–177; Lillesand et al., 2015, s. 352–353). Průkopnická byla družice IKONOS (1999) s 1 m PAN a 4 m MS daty (Lillesand et al., 2015, s. 349–351; Longley et al., 2015, s. 23). Komerční družice nabízejí HSR / VHRS data (metr – desítky cm). Operují na slunečně synchronních LEO drahách a data komerčně prodávají. Mnohé systémy umožňují rychlé a flexibilní nasměrování senzorů na vyžádání (Lillesand et al., 2015, s. 349–352; Longley et al., 2015, s. 175–177). Data slouží územnímu plánování, monitoringu zemědělství / lesů, infrastruktury, pojišťovnictví i zpravodajství. Vznik trhu rozšířil dostupnost a aplikace DPZ (Longley et al., 2015, s. 23), proto mezi nejznámější komerční systémy patří NextView, WorldView, GeoEye, QuickBird a Pléiades (Longley et al., 2015, s. 23, 386, 414; Lillesand et al., 2015, s. 349–353).

1.2.1.4 Ostatní družicové systémy

Mimo snímkovací družice existují navigační a telekomunikační systémy na jiných drahách. Patří sem střední (MEO) a vysoce eliptické dráhy (HEO). Nejznámější MEO systémy tvoří globální navigační satelitní systémy (GNSS), jako GPS či Galileo, jejichž účelem je poskytovat přesné informace o poloze a čase, nikoli obrazová data (Lillesand et al., 2015, s. 43–44). HEO slouží telekomunikacím ve vysokých zeměpisných šířkách, kam GEO nedosáhne. Ačkoliv tyto technologie mají význam pro DPZ z pohledu určení polohy, pro záznam obrazu se nevyužívají (Ilcev, 2010; Editors, 2025).

1.2.2 Pilotované letecké systémy

Pilotované letecké systémy (letadla, vrtulníky) jsou tradiční a velmi flexibilní platformou DPZ pro lokální či regionální sběr dat s vysokým detailem a specifickým načasováním (např. povodně, sesuvy půdy) (Lillesand et al., 2015, s. 46–47; Longley et al., 2015, s. 176–177). Letadla operují v relativně nízkých letových hladinách, což je předpokladem pro dosažení velmi vysokého prostorového rozlišení (často v řádu centimetrů) (Lillesand et al., 2015, s. 29). To je nezbytné pro aplikace jako je tvorba detailních ortofotomap, pasportizace městské zeleně, detailní mapování liniových staveb nebo archeologického průzkumu. Navíc mohou nést širokou škálu senzorů, od klasických velkoformátových kamer pro leteckou fotogrammetrii, multispektrální a hyperspektrální skenery až po systémy LiDAR (Lillesand et al., 2015, s. 121–

127). Nevýhodou je závislost na počasí, vyšší náklady na jednotku plochy a nutnost pokročilých geometrických korekcí kvůli nestabilitě letu (Lillesand et al., 2015, s. 47, 209–210; Kolář, 1990, s. 84–86).

1.2.3 Bezpilotní letecké systémy

Bezpilotní systémy (UAS, drony) se v posledním desetiletí staly dynamicky rozvíjející se platformou DPZ (Longley et al., 2015, s. 406, 448; Lillesand et al., 2015, s. 46–49). Tyto systémy jsou tvořeny bezpilotním letounem (UAV), pozemní stanicí a datovým spojením. Vyplňují mezeru mezi pozemním měřením a leteckými či družicovými daty (Lillesand et al., 2015, s. 46–49; Boon et al., 2017).

Jejich hlavní předností je vysoká flexibilita, nízké náklady, okamžité a časté sběry pro malé lokální projekty. Díky schopnosti operovat ve velmi nízkých letových hladinách (desítky až stovky metrů) poskytují extrémně vysoké prostorové rozlišení (řád jednotek centimetrů), což je výhodné pro aplikace vyžadující maximální detail (Boon et al., 2017), navíc provoz pod oblačností eliminuje limity satelitů a letadel (Lillesand et al., 2015, s. 46–49).

Data se zpracovávají fotogrammetrickou metodou SfM (Structure from Motion) pro ortofotosnímky a DMT (Lillesand et al., 2015, s. 191, 201–205; Chiabrando, 2015, s. 2–3). SfM rekonstruuje trajektorii kamery i 3D geometrii scény z překrývajících se snímků (např. algoritmus SIFT) a vytváří detailní 3D modely a ortofotomozaiky (Chiabrando, 2015, s. 2–4). Navzdory nutnosti kontrolních bodů GCP pro přesnost (Chiabrando, 2015, s. 4–8) se UAS staly standardem pro mnoho odvětví: precizní zemědělství, lesnictví, archeologie, kulturní dědictví, těžba a inspekce infrastruktury.

1.2.3.1 Víceroťorové systémy

Víceroťorové systémy (multirotory) jsou charakteristické schopností vertikálního vzletu a přistání (VTOL), snadnou pilotáží a možností vznášet se na místě. Díky tomu jsou vhodné pro operace ve stísněných prostorech a detailní inspekce objektů. Jejich hlavní výhodou je schopnost pořizovat stabilní záběry, často podpořenou gimbalem (mechanicky stabilizovaným závěsem kamery), což přispívá k vyšší geometrické přesnosti výsledných dat a lepšímu prokreslení detailů, například vegetace. Upřednostňují se při požadavku maximální přesnosti pro detailní environmentální plánování. Mezi jejich hlavní nevýhody patří kratší výdrž a menší plošný výkon, což snižuje efektivitu při rozsáhlejší mapování (Boon et al., 2017, s. 1–3; Lillesand et al., 2015, 46–47).

1.2.3.2 Systémy s pevným křídlem

Systémy s pevným křídlem se konstrukčně podobají klasickým letadlům a jejich hlavní předností je vysoká efektivita letu vycházející z principu aerodynamického vztlaku pro výrazně delší letovou výdrž, která umožní pokrýt větší území za jeden let. Jsou úspornější z hlediska provozních nákladů, údržby i celkového času letu, a proto se hodí pro plošné mapování rozsáhlých teritorií. Nevýhodami jsou vyšší nároky na prostor pro vzlet a zejména přistání, které vyžadují určitou dovednost pilota. Ačkoliv kvalita dat ze systémů s pevnými křídly je pro většinu environmentálních mapovacích úkolů dostačující, může vykazovat nižší celkovou přesnost, zejména ve vertikální složce, a obrazy mohou být náchylnější k deformacím vlivem vyšší letové rychlosti (Boon et al., 2017, s. 1–3, 5; Lillesand et al., 2015, s. 46–49).

1.2.4 Pozemní / mobilní platformy

Tyto platformy operují přímo na zemském povrchu a slouží ke sběru dat s extrémně vysokým detailem na velmi malých plochách. Jejich hlavní využití spočívá v přesných referenčních měřeních pro kalibraci a validaci dat pořízených z letadel či družic, například pomocí ručních spektrometrů (Lillesand et al., 2015, s. 40). Další klíčovou oblastí je mobilní mapování, kde jsou skenovací systémy (typicky LiDAR) a kamery umístěovány na jedoucí vozidla (Mobile Mapping Systems – MMS) za účelem rychlého a detailního sběru 3D dat o prostranství ulic, fasádách budov a dopravní infrastruktúře. Využívají se rovněž stacionární pozemní skenery (Terrestrial Laser Scanning – TLS) pro tvorbu detailních 3D modelů jednotlivých objektů, jako jsou budovy, památky nebo skalní útvary (Lillesand et al., 2015, s. 481; Longley et al., 2015, s. 148–149).

1.3 Druhy senzorů a datových výstupů

Senzor je v DPZ zařízení, které detekuje, zaznamenává a zpracovává EM energii odraženou nebo emitovanou z pozorovaného objektu či povrchu bez přímého kontaktu (Longley et al., 2015, s. 177). Volba senzoru určuje typ zaznamenané informace a výsledný produkt. Dělíme je na pasivní a aktivní podle zdroje energie (Lillesand et al., 2015, s. 45).

Pasivní senzory snímají odražené sluneční záření (ve dne) či tepelnou emisi (ve dne i v noci) (Kolář, 1990, s. 90). Patří sem fotoaparáty, multi/hyperspektrální skenery a termální kamery (Longley et al., 2015, s. 178; Lillesand et al., 2015, s. 243).

Aktivní senzory vysílají vlastní signál a měří jeho odraz od povrchu či překážky (Kolář, 1990, s. 90). Výhodou je nezávislost na slunečním svitu a schopnosti pronikat oblačností (Lillesand et al., 2015, s. 385). Typickými příklady jsou LiDAR a radarové systémy, např. SAR.

Rozdílné principy přinášejí odlišné produkty a aplikace, které budou dále popsány.

1.3.1 Pasivní optické senzory

Pasivní optické senzory jsou nejrozšířenější skupinou v DPZ. Snímají sluneční záření odražené povrchem. Tím, že nemají vlastní zdroj energie, jsou omezené na snímání za denního světla v případě viditelného spektra (Lillesand et al., 2015, s. 44–45), nebo fungují ve dne i v noci pro termální pásmo díky oknům 3–5 μm a 8–14 μm (Lillesand et al., 2015, s. 250–251), přičemž jsou citlivé na přítomnost husté oblačnosti, která brání průchodu záření (Lillesand et al., 2015, s. 10–11). Rozlišují pásma od VIS přes NIR až po TIR. Dělí se na RGB, multispektrální a hyperspektrální systémy (dle počtu pásem) (Lillesand et al., 2015, s. 279–281). Výstupem je digitální obraz, pixel vyjadřuje reflektanci povrchu v daném pásmu.

1.3.1.1 RGB kamery

RGB kamery, běžně označované jako kamery pro viditelné spektrum, jsou nejběžnějším typem pasivního optického senzoru. Princip fungování je analogický lidskému oku – senzory snímají viditelné záření ve třech pásmech, odpovídajících červené (Red), zelené (Green) a modré (Blue) barvě (Gonzalez a Woods, 2018, s. 64–65, 406–407; Campbell & Wynne, 2011, s. 79). Kanály vytvářejí pravobarevný kompozit s intuitivní interpretací pro člověka (Russ & Neal 2016, s. 22). Nízká cena a jednoduchost z nich činí standardní výbavu dronů i letadel (Boon et al., 2017, s. 1).

Jejich hlavní využití je pro tvorbu ortofotomapy – geometricky korigovaného snímku, umožňujícího přesné měření vzdáleností a ploch. Z překryvných snímků lze z těchto snímačů generovat i 3D bodová mračna (point cloud) a DSM (digitální modely povrchu) (Boon et al., 2017, s. 4). Přestože neposkytují spektrální data mimo viditelné spektrum, vysoké prostorové rozlišení činí RGB kamery nepostradatelnými pro vizuální interpretaci, základní mapování, monitoring krajiny a urbanistické analýzy (Boon et al., 2017, s. 4–5).

1.3.1.2 Multispektrální senzory

Multispektrální senzory jsou pokročilou technologií umožňující záznam odražené energie v diskrétních spektrálních pásmech (typicky 3–15), které sahají od viditelného spektra přes NIR až po pásmo Red Edge (Lillesand et al., 2015, s. 347–349; Campbell & Wynne, 2011, s. 115). Data mimo VIS odhalují vlastnosti skryté oku. Nejvýznamnější aplikací je analýza vegetace. Zdravá vegetace pohlcuje červené a silně odráží NIR světlo (Lillesand et al., 2015, s. 16–17). Tento kontrast mezi absorpcí v červeném pásmu a odrazivostí v NIR pásmu je základem pro výpočet tzv. vegetačních indexů.

Nejznámějším a nejrozšířenějším z nich je Normalizovaný diferenční vegetační index (NDVI), který slouží jako robustní indikátor množství biomasy, vitality a případného stresu vegetace (Longley et al., 2015; Lillesand et al., 2015, s. 362, 520–521). Dále slouží k mapování vody, půd, hornin

a povrchu (Lillesand et al., 2015, s. 19–20). Výstupem těchto snímačů jsou multispektrální snímky pro tematické a indexové mapy. Senzory tohoto typu jsou standardní výbavou družicových systémů jako Landsat, Sentinel-2 nebo SPOT 6 a jsou dostupné i pro letecké a bezpilotní platformy (Lillesand et al., 2015, s. 314; Longley et al., 2015, s. 177).

Pro multispektrální analýzu dat pomocí dronů existují komerční řešení zahrnující RTF UAV, například DJI Mavic 3 Multispectral, nebo dedikované kamery, jako MicaSense, které lze montovat na pilotované i bezpilotní platformy. Kromě těchto existují i jiná komerční či alternativně i vlastní řešení, například autorem navržená a zkonstruovaná kamera FlyCamCzech multiSPECTRALcamera, která snímá NIR, RedEdge a RGB data s rozlišením 12 Mpx ve všech pásmech. Oba zmíněné senzory jsou zobrazeny na obrázku 2 níže.



Obrázek 2: Multispektrální kamery pro letecké snímkování

Zdroj: [vlastní zpracování; MicaSense, b.r.]

1.3.1.3 Hyperspektrální scannery

Hyperspektrální skenery, známé jako zobrazující spektrometry, představují technologickou špičku v oblasti pasivních optických senzorů. Na rozdíl od multispektrálních, zaznamenávají stovky úzkých, na sebe navazujících pásem (Lillesand et al., 2015, s. 270–271). Tímto způsobem pro každý pixel v obraze nezískávají pouze několik samostatných hodnot, ale kompletní, souvislou spektrální křivku (spektrální podpis) odražené energie v daném rozsahu vlnových délek (Lillesand et al., 2015, s. 270; Longley et al., 2015, s. 177–178). Výsledný datový produkt je znám jako hyperspektrální datová kostka (hypercube), kde dvě dimenze reprezentují prostorové souřadnice (x, y) a třetí spektrální informaci (vlnovou délku) (Lillesand et al., 2015, s. 275–276; Campbell & Wynne, 2011, s. 430–431). Tento detailní spektrální záznam umožňuje přejít od pouhé klasifikace povrchů k jejich přímé identifikaci. jemné rozdíly, absorpční pásy a specifické rysy

ve spektrální křivce umožňují rozlišit nejen mezi základními kategoriemi (např. vegetace vs. půda), ale i mezi jednotlivými druhy rostlin, různými typy minerálů nebo detekovat environmentální stres vegetace a kontaminaci půdy či vody (Longley et al., 2015; Lillesand et al., 2015, s. 271).

Hlavní aplikační oblasti zahrnují geologii a mineralogický průzkum, precizní zemědělství (detekci chorob, monitorování obsahu živin), lesnictví (identifikaci druhové skladby) a monitorování kvality vody (Lillesand et al., 2015, s. 272). Jejich nevýhodou je obrovský objem pořizovaných dat a vysoká výpočetní náročnost samotného zpracování a analýzy (Lillesand et al., 2015, s. 355, 598). Hyperspektrální senzory jsou nejčastěji nasazovány na leteckých platformách (např. systém AVIRIS) (Lillesand et al., 2015, s. 280–281).

1.3.1.4 Termální IR kamery

Termální (tepelné) infračervené kamery jsou specifickým typem pasivního senzoru, který se od ostatních optických systémů zásadně liší principem funkce, místo odraženého světla zachycují tepelné emise povrchu. Operují v termální části infračerveného spektra, nejčastěji v atmosférickém okně v rozsahu vlnových délek 8 až 14 μm . Jelikož měří vlastní emisi objektů, jsou nezávislé na slunečním svitu a mohou pořizovat data ve dne i v noci (Lillesand et al., 2015, s. 242–243; Russ & Neal, 2016, s. 304). Výstupem je termogram s povrchovou radiační teplotou (Lillesand et al., 2015, s. 234). Tato teplota je ovlivněna nejen skutečnou teplotou objektu, ale i jeho emisivitou. Různé materiály se stejnou teplotou tak mohou na termálním snímku vypadat odlišně (Lillesand et al., 2015, s. 244, 253; Kolář, 1990, s. 64).

Aplikace jsou rozmanité, využívají se k monitorování městských tepelných ostrovů, detekci a sledování lesních požárů, mapování sopečné aktivity nebo identifikaci tepelných ztrát z budov a potrubí (Lillesand et al., 2015, s. 262, 652). V zemědělství a hydrologii pomáhají odhalovat vodní stres plodin (Lillesand et al., 2015, s. 630), protože rostliny s nedostatkem vláhy se hůře ochlazují transpirací a jejich teplota stoupá. Dále umožňují sledovat teplotu vodních ploch, což je důležité pro studium mořských proudů nebo tepelného znečištění řek (Lillesand et al., 2015).

1.3.2 Aktivní senzory

Na rozdíl od pasivních senzorů, které jsou závislé na externím zdroji energie, jako je Slunce, aktivní senzory disponují vlastním zdrojem EM záření. Princip jejich činnosti spočívá ve vyslání přesně definovaného signálu (pulzu) směrem k zemskému povrchu a následné detekci a analýze části signálu, která se odrazí zpět k senzoru (Lillesand et al., 2015, s. 471). Díky tomu mohou snímat ve dne i v noci, a radary s delší vlnovou délkou proniknou oblačností, mlhou i lehkým deštěm (Lillesand et al., 2015, s. 385–386; Kolář, 1990, s. 90).

Aktivní senzory tak neměří spektrální odrazivost, ale fyzikální vlastnosti povrchu. Ze zpětného signálu lze odvodit vzdálenost, drsnost či vlhkost povrchu (Lillesand et al., 2015, s. 409–410). Nejrozšířenějšími technologiemi jsou systémy LiDAR (Light Detection and Ranging) a radarové systémy (SAR), jejichž principy a využití popisují následující kapitoly.

1.3.2.1 Radarové systémy (SAR, InSAR)

Radar (Radio Detection and Ranging) je druhý klíčový typ aktivního senzoru. Na rozdíl od LiDARu, jenž používá laserové impulzy, radar využívá podstatně delší mikrovlnné vlnové délky (~ centimetry–desítky centimetrů) (Lillesand et al., 2015, s. 409). Díky tomu dokáže pronikat oblačností, mlhou a lehkým deštěm, takže spolehlivě sbírá data bez ohledu na počasí. Stejně jako LiDAR vysílá pulz a měří zpětný rozptyl (backscatter) (Lillesand et al., 2015, s. 391, 434). Intenzita zpětného rozptylu nezávisí na barvě ani teplotě povrchu, ale primárně na jeho geometrické drsnosti (hladké povrchy jako klidná voda se jeví tmavě, drsné povrchy jako les nebo zástavba světla) a na dielektrických vlastnostech, které jsou silně ovlivněny obsahem vody (Lillesand et al., 2015, s. 420–421). Je citlivý na vlhkost půdy a vegetace.

Většina moderních radarových systémů využívá technologii SAR (Synthetic Aperture Radar). Ta pomocí sofistikovaného zpracování signálu syntetizuje z pohybu platformy (družice, letadla) virtuální, velmi dlouhou anténu, což umožňuje dosáhnout vysokého prostorového rozlišení, které by jinak s fyzicky malou anténou nebylo možné (Lillesand et al., 2015, s. 398–399; Kolář, 1990, s. 90).

Pokročilou technikou je interferometrický SAR (InSAR), jenž využívá dvou či více SAR snímků téhož území pořízených z mírně odlišných trajektorií. Porovnáním fázového rozdílu dokáže s milimetrovou přesností měřit drobné změny topografie (Lillesand et al. 2015, s. 435–436). Používá se pro DMT a monitorování povrchových deformací (poklesy, tektonické zlomy, sesuvy či sopky) (Lillesand et al., 2015, s. 439).

1.3.2.2 Lidarové systémy

LiDAR (Light Detection and Ranging) je aktivní technologie pro přesné měření vzdáleností a detailní 3D modely terénu i objektů. Vysílá laserové pulzy a měří dobu letu odrazu (Lillesand et al., 2015, s. 471; Longley et al., 2015, s. 180; Campbell & Wynne 2011, s. 243). Ze znalosti tohoto času a rychlosti záření lze s centimetrovou přesností vypočítat vzdálenost (Lillesand et al., 2015, s. 475; Longley et al., 2015, s. 180). Současným záznamem polohy (GNSS) a orientace IMU (inerciální jednotky) platformy je možné každému odraženému bodu přiřadit přesnou 3D souřadnici (Lillesand et al., 2015, s. 471–472). Výstupem je 3D point cloud s miliony bodů s polohou XYZ a intenzitou odrazu (Lillesand et al., 2015, s. 475). Zásadní výhodou LiDARu oproti pasivním optickým senzorům je jeho schopnost částečně pronikat vegetačním pokryvem. Jeden vyslaný

laserový pulz se může odrazit vícekrát – poprvé například od koruny stromu, dále od větvi a listů, a nakonec od skutečného zemského povrchu. Analýzou těchto vícenásobných odrazů (multiple returns) dokáže LiDAR „vidět“ skrze vegetaci (Lillesand et al., 2015, s. 473–474).

Z point cloudu vznikají hlavní produkty (výstupy):

- **Digitální model povrchu (DSM)** – výška terénu včetně objektů (budov, vegetace).
- **Digitální model terénu (DMT)** – „holý“ povrch po odfiltrování vegetace a staveb.

Rozdíl DSM – DMT, označovaný jako model výšky korun vegetace (Canopy Height Model, CHM), umožňuje např. stanovit výšku vegetace či budov. Díky tomu se LiDAR využívá v lesnictví (odhad zásob dřeva), hydrologii (záplavové modely), archeologii (odhalení struktur pod vegetací) a dalších oborech (Lillesand et al., 2015, s. 477–479).

1.3.2.3 Sonarové systémy

Sonar (Sound Navigation and Ranging) je aktivní akustický ekvivalent radaru. Místo elektromagnetických vln používá ultrazvukové pulzy (Lillesand et al., 2015, s. 1–2). Princip spočívá ve vyslání zvukového „pingu“ a měření času, který uplyne, než se odražený signál (echo) vrátí k senzoru. Z doby letu a rychlosti zvuku se vypočítá vzdálenost. Jelikož voda silně absorbuje EM vlnění, je SONAR klíčovou technologií pro mapování a průzkum podvodního prostředí (Lurton et al., 2015, s. 25–26).

Hlavním využitím je batymetrie – mapování topografie mořského a říčního dna (NOAA, b.r.; Lurton et al., 2015, s. 26). Moderní systémy, jako je více paprskový sonar (multibeam sonar) vysílají vějíř stovek úzkých paprsků, takže v jednom přeletu pokryjí široký pás dna a vytvoří detailní 3D model reliéfu (Lurton et al., 2015, s. 14, 157). Side scan sonar naopak neposkytuje přesnou výšku, ale vytváří akustický „fotografický“ obraz dna se zvýrazněnou texturou a drobnějšími objekty (Lurton et al., 2015, s. 8). Hodí se k identifikaci vraků, potrubí, geologických tvarů a sedimentů. Výstupy jsou především batymetrické mapy, 3D modely dna a akustické mozaiky (Russ & Neal 2016, s. 915; Lurton et al., s. 8). Tyto informace jsou zásadní pro námořní navigaci, podmořskou archeologii, geologický průzkum, pokládání kabelů a potrubí i pro studium mořských ekosystémů (Lurton et al., 2015, s. 7, 8, 10, 26).

2 DIGITÁLNÍ ZPRACOVÁNÍ OBRAZOVÝCH DAT

Digitální zpracování obrazových dat je nedílnou součástí dálkového průzkumu Země. Představuje soubor operací a algoritmů, jejichž cílem je transformovat nezpracovaná data pořízená senzory na interpretovatelné geoprostorové informace. Nezpracovaná obrazová data jsou zřídka kdy v takovém stavu, aby mohla být přímo využita pro kvantitativní analýzu. Ovlivňují je vlastnosti senzorů, atmosférické podmínky, geometrie snímání i osvětlení scény (Lillesand et al., 2015, s. 491). Úkolem digitálního zpracování je tyto nežádoucí vlivy systematicky odstranit či potlačit a z dat následně extrahovat tematickou informaci relevantní pro danou aplikaci (Gonzalez a Woods, 2018, s. 18, 41; Lillesand et al., 2015, s. 485, 488).

Celý proces lze rozdělit do několika logicky navazujících fází:

1. **Předzpracování** (pre-processing) – zahrnuje radiometrické a geometrické korekce k odstranění systematických chyb a zkreslení (Lillesand et al., 2015, s. 488, 495; Gonzalez a Woods, 2018, s. 41).
2. **Zvýraznění obrazu** (image enhancement) – zlepšuje vizuální kvalitu obrazu pro snazší lidskou interpretaci (Lillesand et al., 2015, s. 500; Gonzalez a Woods, 2018, s. 41).
3. **Extrakce informací** – klíčovým krokem je extrakce informací, jež obvykle probíhá klasifikací obrazu (Lillesand et al., 2015, s. 486). Jednotlivé pixely jsou na základě svých spektrálních vlastností přiřazovány do předem definovaných tematických tříd (např. les, voda, zástavba) (Gonzalez a Woods, 2018, s. 904–905).
4. **Postklasifikační úpravy** – výsledky se dále zpřesňují (filtrování šumu, generalizace hranic) (Lillesand et al., 2015, s. 568–569; Russ & Neal, 2016, s. 212–214).
5. **Hodnocení přesnosti** (accuracy assessment) – kvantifikuje přesnost výsledné tematické mapy (Russ & Neal, 2016, s. 522–524; Lillesand et al., 2015, s. 575).

2.1 Záznam a georeferencování UAV dat

Sběr dat bezpilotním letounem (UAV) začíná pečlivě naplánovanou misí. Pomocí specializovaného softwaru (např. Mission Planner) se vymezí oblast zájmu a naplánují letové dráhy tak, aby bylo zajištěno alespoň 60–80 % podélného a 40–60 % příčného překryvu snímků. Vysoký překryv je nezbytný pro následné fotogrammetrické zpracování a tvorbu 3D modelů (Lillesand et al., 2015, s. 206, 208, 211; Boon et al., 2017, s. 2–3). Během letu se snímky pořizují automaticky – buď v definovaných časových intervalech, dosažené vzdálenosti nebo konkrétních souřadnicích.

Klíčovým krokem, který nezpracovaným snímkům propůjčuje prostorovou informaci, je georeferencování, tedy přiřazení snímků do konkrétního souřadnicového systému (CRS). Rozlišují se dva přístupy:

- **Přímé georeferencování** (Direct Georeferencing): palubní systém je vybaven přesným GNSS přijímačem (případně RTK/PPK) a IMU. Pro každý snímek se zaznamená poloha (X, Y, Z) a orientace kamery v okamžiku expozice. Tato metoda může výrazně zredukovat nebo i zcela eliminovat potřebu pozemních vlíčovacích bodů, což zefektivňuje práci v terénu (Lillesand et al., 2015, s. 189, 193).
- **Nepřímé georeferencování** (Indirect Georeferencing): častější u nízkonákladových dronů, kdy se spoléhá na vlíčovací body (GCPs). Jsou to fyzické značky rozmístěné v zájmovém území, jejichž souřadnice se s centimetrovou přesností určují geodetickým GNSS. Tyto body slouží v software jako referenční kotvy, které přesně usadí blok snímků do souřadnicového systému (Lillesand et al., 2015, s. 189; Boon et al., 2017, s. 1–3). Výsledná přesnost závisí na počtu, rozmístění a kvalitě zaměření GCPs.

2.2 Předzpracování

Předzpracování (pre-processing) je základní sada operací prováděných na nezpracovaných obrazových datech s cílem odstranit nebo minimalizovat systematické zkreslení a chyby vzniklé při akvizici (Gonzalez & Woods, 2018, s. 41; Russ & Neal, 2016, s. 163). Cílem není získat tematická data, ale připravit scény tak, aby co nejvěrněji reprezentovaly skutečné fyzikální vlastnosti povrchu (Kolář, 1990, s. 147–148). Tím se zajišťuje vzájemná srovnatelnost snímků v čase i prostoru a vytváří spolehlivý základ pro následné analýzy, jako je klasifikace či výpočet vegetačních indexů (Lillesand et al., 2015, s. 485, 488, 495). Předzpracování zahrnuje dvě hlavní složky: radiometrické a geometrické korekce (Dobrovolný, 1998).

Radiometrické kroky upravují jasové hodnoty (DN) snímku (Campbell & Wynne, 2011, s. 305, 311). Korigují zkreslení způsobená senzorem (např. nerovnoměrná citlivost detektorů) a především atmosférou. Ta totiž ovlivňuje záření rozptylem (scattering) (Campbell & Wynne, 2011, s. 39, 305) a absorpcí (absorption) určitých vlnových délek (vodní pára, ozon) (Campbell & Wynne, 2011, s. 44). Cílem je převést DN na radianci či ideálně na spektrální odrazivost (reflektanci), jenž je nezávislá na proměnlivém osvětlení a stavu atmosféry (Gonzalez a Woods, 2018, s. 41, 24–125; Lillesand et al., 2015, s. 488–489, 491–492, 494–495; Kolář, 1990, s. 149–150).

Geometrické korekce řeší prostorové zkreslení. Snímky jsou deformovány perspektivou senzoru, nestabilitou platformy (náklony, směr), zakřivením Země a reliéfem terénu. Proces ortorektifikace využívá párů: informace o vnitřní geometrii kamery, přesné údaje o poloze a orientaci a detailní DMT k odstranění zkreslení. Výsledkem je ortofotosnímek, kde poloha každého pixelu odpovídá jeho skutečné poloze na povrchu (Lillesand et al., 2015, s. 200–204, 495–496; Gonzalez & Woods, 2018, s. 103–105; Kolář, 1990, s. 148–149).

Radiometricky i geometricky korigovaná data mohou být dále normalizována (např. topografická korekce, konverze na bezrozměrné indexy) a připravena pro image enhancement či tematickou klasifikaci.

2.3 Zvýraznění

Zvýraznění obrazu (Image Enhancement) je soubor technik, jejichž cílem je upravit obraz tak, aby byl lépe interpretovatelný a zvýraznil konkrétní rysy a struktury, které jsou v původním obraze skryté nebo nejasné. Na rozdíl od předzpracování, jehož cílem je fyzikální věrnost dat, se metody zvýraznění soustředí na subjektivní vizuální zlepšení. Vhodnost zvolené metody je dána aplikací a tím, jaké informace je potřeba z obrazu získat (Gonzalez a Woods, 2018, s. 119–120, 202–203; Lillesand et al., 2015, s. 500–501; Kolář, 1990, s. 150). Tyto techniky lze rozdělit do tří kategorií: bodové, prostorové a spektrální.

2.3.1 Bodové (radiometrické) zvýraznění

Bodové operace jsou nejzákladnějším typem zvýraznění. Pracují s každým pixelem izolovaně a mění globální radiometrické vlastnosti obrazu, nejčastěji jasový rozsah, pomocí úprav histogramu. Ten konkrétně zobrazuje četnost jasových úrovní a naznačuje kontrast (Pratt, 2001; Gonzalez & Woods, 2018, s. 119; Dobrovolný, 1998; Kolář, 1990, s. 151).

Nejběžnější technikou je lineární roztažení kontrastu (Lillesand et al., 2015, s. 502–503). Roztažení přemapuje úzký jasový rozsah na celou škálu (např. 0–255), čímž obraz zvýrazní detaily (Campbell & Wynne, 2011, s. 117–119). Pokročilejší metodou je ekvalizace histogramu (Campbell & Wynne, 2011, s. 120), která redistribuuje jasové úrovně a odhaluje detaily v tmavých či světlých oblastech (Lillesand et al., 2015, s. 500; Russ & Neal, 2016, s. 244; Gonzalez & Woods, 2018, s. 119–120).

2.3.2 Prostorové (lokální) zvýraznění

Prostorové operace berou v úvahu i okolní pixely. Hodnota výstupního pixelu je odvozena z konvoluce v okně (např. 3×3 nebo 5×5) (Lillesand et al., 2015, s. 508–509; Pratt, 2001, s. 262–263). Tento přístup zvýrazňuje nebo potlačuje určité prostorové frekvence (Gonzalez & Woods, 2018).

Nejčastěji se využívají filtry pro zvýraznění hran (edge enhancement). Tyto filtry, známé jako horní propusti (high-pass filters), zvýrazňují oblasti s rychlou změnou jasu, tedy hrany, linie a drobné textury. Obraz se tak stává ostřejším a jsou v něm lépe patrné detaily, jako jsou silnice, hranice pozemků nebo zástavba. Opačným typem jsou vyhlazovací filtry (smoothing filters), známé jako dolní propusti (low-pass filters). Ty naopak potlačují vysokofrekvenční složky a slouží k odstranění šumu a zjemnění obrazu tím, že průměrují hodnoty pixelů v daném okolí (Lillesand et al., 2015, s. 506–507; Russ & Neal, 2016, 184–185, 265–266; Kolář, 1990, str.152).

2.3.3 Spektrální zvýraznění

Spektrální zvýraznění kombinuje více pásy RGB, multispektrálních či hyperspektrálních dat. Nejčastější je aritmetika pásy – sčítání, odčítání, násobení či dělení hodnot mezi pásy (Lillesand et al., 2015, s. 500, 517; Russ & Neal, 2016, s. 303–304) za účelem získání zřetelnějších hran nebo informací.

Typickým příkladem je výpočet spektrálních indexů, jako je například Normalizovaný diferenční vegetační index (NDVI), který poměrem červeného a blízkého infračerveného pásma efektivně zvýrazňuje přítomnost a vitalitu vegetace (Lillesand et al., 2015, s. 518–520). Další pokročilou technikou je analýza hlavních komponent (Principal Component Analysis – PCA) (Lillesand et al., 2015, s. 524, 527–528). Jedná se o statistickou metodu, která transformuje původní, často vysoce korelovaná, spektrální pásma do nového souboru nekorelovaných komponent. První komponenty obvykle obsahují většinu informací a variabilit z původních dat, zatímco poslední obsahují převážně šum. Vizuálním zobrazením prvních tří hlavních komponent lze často dosáhnout silného zvýraznění informace a redukce šumu (Lillesand et al., 2015, s. 524–525; Russ & Neal, 2016, s. 305–306).

2.4 Klasifikace

Klasifikace obrazových dat je klíčovým procesem v dálkovém průzkumu Země, zaměřeným na automatickou extrakci tematické informace z obrazových dat (Campbell & Wynne, 2011, s. 132). Každému pixelu je přiřazena třída (kategorie) podle jeho spektrálních charakteristik. Výsledkem je tematická mapa zobrazující prostorové rozložení tříd, jako jsou například lesy, vodní plochy, orná půda, zástavba, různé typy vegetace (Lillesand et al., 2015, s. 537, 540–541), či autorem definované třídy.

Základní předpoklad spektrální klasifikace spočívá v tom, že různé povrchy mají odlišné spektrální podpisy a různě odrážejí energii v jednotlivých pásmech. Klasifikační algoritmus tyto rozdíly rozpoznává a na jejich základě seskupuje pixely s podobnými spektrálními vlastnostmi do tříd (Gonzalez & Woods, 2018, s. 904–905). Tento proces probíhá ve vícerozměrném prostoru, kde každá osa reprezentuje jedno spektrální pásmo a každý pixel tvoří bod v tomto prostoru. Algoritmus pak tento prostor rozdělí na regiony odpovídající jednotlivým třídám (Russ & Neal, 2016, s. 684–685). Metody klasifikace se dělí do dvou hlavních kategorií: neřízených a řízených.

2.4.1 Neřízené metody

Neřízená klasifikace (unsupervised classification) je metoda, při níž analytik algoritmu nepředává předchozí informace o třídách vyskytujících se ve scéně (Campbell & Wynne, 2011,

s. 339). Algoritmus analyzuje obrazová data výhradně podle jejich statistických vlastností a automaticky vyhledává přirozená seskupení (shluky) pixelů s podobným spektrem. Výstupem je soubor spektrálních tříd, jež zatím postrádají tematický význam (Lillesand et al., 2015, s. 556–557; Kolář, 1990, s. 161–163).

Analytik poté každé spektrální třídě přiřadí odpovídající tematickou třídu (např. spektrální shluk č. 1 voda, shluk č. 2 listnatý les). Tento přístup je výhodný zejména když chybí detailní znalost území, nebo když chceme v datech odhalit přirozeně se vyskytující spektrální kategorie. Mezi nejpoužívanější algoritmy patří ISODATA (Iterative Self-Organizing Data Analysis Technique) a K-means (metoda K-průměrů). Iterativně posouvají středy shluků a přiřazují pixely tak, aby minimalizovaly vnitroshlukovou a maximalizovaly mezishlukovou spektrální vzdálenost (Pratt, 2001, s. 560–561; Lillesand et al., 2015, s. 556–557).

V programu ArcGIS Pro se pro neřízenou klasifikaci používá nástroj ISO Cluster, který interně využívá právě kombinaci algoritmů K-means a ISODATA k automatickému shlukování spektrálně podobných pixelů (Esri, b.r.).

2.4.2 Řízené metody

Řízená klasifikace (supervised classification) představuje dominantní metodu pro získání tematických informací. Proces je založen na supervizi uživatele, který algoritmus nejprve „trénuje“ na referenčních datech. V první fázi analytik v obraze identifikuje reprezentativní vzorky – trénovací plochy (training areas) pro každou třídu, kterou chce mapovat (Lillesand et al., 2015, s. 539, 547; Campbell & Wynne, 2011, s. 349). Tyto polygony pokrývají homogenní, typické oblasti dané třídy (např. pole s pšenicí, vodní hladinu, smrkový les). Ze všech pixelů uvnitř trénovacích ploch se vypočítá statistický model neboli spektrální podpis třídy (Lillesand et al., 2015, s. 548; Gonzalez & Woods, 2018, s. 910–913).

Po natrénování modelu, algoritmus prochází celý obraz pixel po pixelu a přiřazuje je k té třídě, jejímuž modelu se nejvíce podobají (Pratt, 2001, s. 399). K rozhodování se používají jak klasické statistické klasifikátory, tak moderní metody strojového učení (např. hluboké neuronové sítě).

2.4.2.1 Konvenční statistické přístupy

Tyto metody představují tradiční, statisticky založené klasifikátory, které byly po desetiletí standardem v dálkovém průzkumu. Mezi nejznámější patří:

- **Minimum Distance** – rychlý klasifikátor, který každé třídě přiřadí průměrné spektrální hodnoty a pixel přiřadí ke středu, jenž je mu v n-rozměrném prostoru nejbližší (Lillesand et al. 2015, s. 541–542; Gonzalez & Woods, 2018, s. 910–912).

- **Maximum Likelihood Classifier (MLC)** – bere v úvahu průměr, variabilitu i kovarianci spektrálních hodnot; pixel zařazuje do třídy s nejvyšší vypočtenou pravděpodobností (Lillesand et al., 2015, s. 560; Gonzalez & Woods, 2018, s. 927–929).
- **Random (Decision) Trees / Random Forest** – souborová metoda využívající mnoho rozhodovacích stromů (Lillesand et al., 2015, s. 545). Jednotlivé stromy hlasují a výsledná třída je dána většinovým rozhodnutím, což zvyšuje stabilitu a přesnost (Aggarwal, 2023, s. 210–211).
- **Support Vector Machine (SVM)** – vytváří optimální hyperrovinu oddělující třídy v n-rozměrném prostoru a díky jádrovým funkcím zvládá i nelineárně separovatelné případy (Aggarwal, 2023, s. 79–82; Goodfellow et al., 2017, s. 139–141). Často dosahuje velmi vysoké přesnosti i na malém množství trénovacích dat.


V programu ArcGIS Pro se pro řízenou klasifikaci používají nástroje Maximum Likelihood, Random Trees, Support Vector Machine a K-Nearest Neighbors, které po natrénování na uživatelsky definovaných trénovacích plochách automaticky přiřadí každému pixelu nejpravděpodobnější tematickou třídu (Esri, b.r.).

2.4.2.2 Neuronové sítě a Deep Learning

V posledních letech dochází k rychlému rozvoji metod založených na neuronových sítích, které často dosahují vyšší přesnosti než konvenční přístupy, zejména při práci s komplexními a velkoobjemovými daty (Campbell & Wynne, 2011, s. 368). Neuronová síť je výpočetní model inspirovaný strukturou a funkcí lidského mozku (Aggarwal, 2023, s. 1–2, 73–74). Typická architektura je tzv. feed-forward síť (Gonzalez & Woods, 2018, s. 964–966), v níž informace postupuje jedním směrem – od vstupní vrstvy přes jednu či více skrytých vrstev až k výstupní. Každou vrstvu tvoří hustě (plně) propojené neurony, každý neuron přijímá vážený součet výstupů neuronů předchozí vrstvy a aplikuje na něj nelineární aktivační funkci. Síť jako celek je tedy plně určena sadou vah w_{ij} mezi neurony a zvolenou aktivační funkcí (např. ReLU, sigmoid), které společně definují, jaký vzor rozpozná. Síť se „učí“ rozpoznávat vzory v datech postupnou úpravou těchto vah během trénovacího procesu (back-propagation) (Gonzalez & Woods, 2018, s. 945–947; Aggarwal, 2023, s. 1–2).

Deep learning (hluboké učení) je odvětví strojového učení využívající vícevrstvé (hluboké) neuronové sítě (Aggarwal, 2023, s. 305–306). Pro klasifikaci obrazových dat jsou klíčové zejména konvoluční neuronové sítě (Convolutional Neural Networks – CNN), jejichž architektura je navržena pro mřížková data, jako jsou snímky. Princip CNN, spočívá v použití konvolučních filtrů, které se postupně posouvají po obraze a automaticky se učí detekovat hierarchické rysy – od jednoduchých hran a textur v počátečních vrstvách až po složité objekty v hlubších vrstvách (Goodfellow et al., 2016, s. 329–330, 338–340; Aggarwal, 2023, s. 321–322). Příklad struktury

CNN je možné vidět na obrázku 3. Volba tzv. backbone modelu (Aggarwal, 2023, s. 335) (např. ResNet, EfficientNet či U-Net) a vyladění klíčových hyperparametrů – velikosti filtrů, počtu vrstev, learning rate, velikosti batch a počtu epoch mají zásadní vliv na finální přesnost a generalizační schopnost sítě (Aggarwal, 2023, s. 962–963). Díky této schopnosti automaticky extrahovat prostorově-spektrální rysy dosahují CNN modely špičkové přesnosti v úlohách, jako je klasifikace využití půdy, identifikace objektů či sémantická segmentace obrazů z dálkového průzkumu.



Obrázek 3: Konvoluční neuronová síť

Zdroj: [Dabass, 2025]

2.5 Postklasifikační úpravy

Výsledná tematická mapa, která je přímým výstupem pixelově-orientované klasifikace, často obsahuje mnoho chyb a nepřesností, které neodpovídají reálnému stavu krajiny. Typickým jevem je tzv. efekt „pepře a soli“ (salt-and-pepper effect), projevující se výskytem izolovaných pixelů chybně přiřazených jiné třídě než okolí, což vytváří rušivý „kropenatý“ dojem (Lillesand et al., 2015, s. 489, 568). Cílem postklasifikačních úprav je tyto chyby odstranit, výslednou mapu vyhladit a generalizovat tak, aby kartograficky čistěji reprezentovala souvislé plochy reálných objektů.

Nejběžnějším nástrojem pro potlačení efektu „pepře a soli“ je použití majoritního filtru (majority filter) (Lillesand et al., 2015, s. 569; Russ & Neal, 2017, st. 722). Filtrování s posuvným oknem (např. 3×3 či 5×5 pixelů) nahradí hodnotu centrálního pixelu třídou, která má v okně většinové zastoupení (Lillesand et al., 2015, s. 490). Izolované pixely a drobné shluky tak splynou s dominantní třídou svého okolí (Russ & Neal, 2016; Lillesand et al., 2015).

Mezi další postklasifikační úpravy patří „clumping“ (shlukování), který sousedící pixely stejné třídy převádí na souvislé polygony, a „sieving“ (prosévání), jež odstraňuje polygony menší než

uživatelem definovaná minimální plocha (Lillesand et al., 2015, s. 569, 604–605). Tyto kroky zvyšují vizuální koherenci výsledné mapy, avšak musí se aplikovat uvážlivě, aby nedošlo k vymazání reálně existujících, drobných a důležitých prvků krajiny (Lillesand et al., 2015, s. 568–569).

2.6 Reklasifikace spektrálních tříd

Zásadním krokem, který následuje po provedení neřízené klasifikace, je interpretace a reklasifikace spektrálních tříd. Samotný algoritmus totiž vytvoří pouze shluky pixelů s podobnými spektrálními vlastnostmi (spektrální třídy), bez přiřazení reálného tematického významu (Lillesand et al., 2015, s. 555–556; Russ & Neal, 2016, s. 697–698; Gonzalez & Woods, 2018, s. 560–561). Úkolem analytika je proto každé spektrální třídě přiřadit odpovídající informační třídu (např. les, voda, pole) (Lillesand et al., 2015, s. 557). Tento proces se provádí porovnáním výsledné klasifikace s referenčními daty, jako jsou ortofotosnímky s vysokým rozlišením, jiné mapové zdroje nebo znalost získaná terénním průzkumem. Během tohoto kroku je také běžné, že několik různých spektrálních tříd (např. osvětlený a zastíněný svah lesa) je sloučeno do jedné informační třídy (les). Teprve po této interpretaci a reklasifikaci se z výstupu neřízené klasifikace stává plnohodnotná tematická mapa (Lillesand et al., 2015, s. 559).

2.7 Hodnocení přesnosti

Hodnocení přesnosti je závěrečným a zároveň nepostradatelným krokem v procesu klasifikace obrazových dat. Jeho úkolem je kvantitativně posoudit, do jaké míry výsledná tematická mapa odpovídá reálnému stavu terénu (tzv. ground truth) (Longley et al., 2015, s. 114–115). Bez tohoto hodnocení by zůstala spolehlivost mapy neznámá (Lillesand et al., 2015, s. 575–576). Proces je založen na porovnání výsledků klasifikace se sadou nezávislých validačních dat, jejichž skutečná třída je známá s vysokou jistotou (např. z terénního průzkumu nebo z leteckých snímků s velmi vysokým rozlišením) (Lillesand et al., 2015, s. 577, 580–581).

Standardním nástrojem pro hodnocení přesnosti je matice záměn (confusion matrix). Jedná se o tabulku, kde řádky reprezentují třídy zjištěné klasifikací a sloupce představují skutečné třídy z referenčních dat. Prvky na hlavní diagonále udávají počet pixelů klasifikovaných správně, zatímco prvky mimo diagonálu vyjadřují chyby – pixely přiřazené k nesprávné třídě (Longley et al., 2015, s. 114; Campbell & Wynne, 2011, s. 415–421).

Z této matice se odvozují standardní metriky jako (Lillesand et al., 2015, s. 575–579):

- **Celková přesnost** (Overall Accuracy / Overall Precision) – podíl správně klasifikovaných pixelů (diagonála) a celkového počtu testovacích pixelů. Udává rychlý přehled o kvalitě mapy.

- **Uživatelská přesnost** (User's Accuracy / Precision) – pravděpodobnost, že pixel zařazený do třídy skutečně do této třídy patří. Kvantifikuje chyby z přebytku (errors of commission).
- **Producentova přesnost** (Producer's Accuracy / Recall) – podíl skutečných pixelů dané třídy, které byly klasifikovány správně. Vyjadřuje chyby z opomenutí (errors of omission).
- **F1-skóre** (F1-Score) – harmonický průměr precision a recall, vhodný při nevyvážených třídách, protože současně postihuje oba typy chyb.
- **Koeficient Kappa** (Cohen's Kappa) – statistika, která zohledňuje shodu očekávanou s náhodou. Hodnota 1 = perfektní shoda, 0 = shoda náhodná, záporné hodnoty = shoda horší než náhodná.

3 SOUČASNÝ STAV VE SMĚRU PRÁCE

Současné zemědělství musí zajistit dostatek potravin pro populaci 9,8 miliardy lidí do roku 2050 (United Nations, 2017). Růst populace, klimatická změna a ochrana prostředí vyžadují transformaci zemědělských postupů směrem k preciznímu zemědělství. Principem jsou cílené zásahy dle variability porostu, vyžadující včasnou detekci stresů (abiotických – sucho, deficit živin; biotických – choroby, škůdci). Stresy mohou celosvětově snížit výnosy o 20–40 % (Oerke, 2006) a zvyšovat spotřebu agrochemikálií (Gano et al., 2024; Cvetković et al., 2023).

Satelitní platformy (Landsat, Sentinel) poskytují cenná multispektrální data, ale pro toto odvětví mají omezení. Nicméně studie Sedlák et al. (2018) ukázala, že i pomocí dlouhodobých časových řad družicových dat (Landsat, MODIS) lze efektivně monitorovat změny vegetačního pokryvu na úrovni správních celků. Srovnáním různých vegetačních indexů (NDVI, SAVI, MSAVI, GVI) potvrdili autoři stabilitu některých indexů (NDVI, SAVI) napříč časem i senzory, zatímco jiné (GVI) vykazovaly odlišnou citlivost v závislosti na typu krajinného pokryvu. Z tohoto důvodu se hojně využívají bezpilotní letecké prostředky, které nabízejí vyšší prostorové rozlišení. Například ve studiích Komárková & Jech (2020) či Sedlák et al. (2019) při monitoringu vodních ploch z výšky 40 m bylo dosaženo prostorové rozlišení 1,7 cm. Bhandari et al. (2021) při fenotypizaci pšenice z výšky 15–20 m získali snímky s prostorovým rozlišením 0,3–0,5 cm. Pro detekci drobných listových chorob je dokonce možné dosáhnout GSD (Ground Sample Distance), prostorové rozlišení, v řádu milimetrů, jak ukázala studie Görlich et al. (2021) s hodnotou 2 mm/pixel. Tato úroveň detailu umožňuje analýzu na úrovni jednotlivých rostlin, jejich orgánů (listy, klasy, plody) a je zásadní pro detekci nejranějších projevů stresu.

3.1 Potenciál a limity RGB senzorů

Přestože se pro nejpokročilejší agronomické analýzy často nasazují drahé multispektrální nebo hyperspektrální kamery snímající i v blízké NIR oblasti, velký potenciál pro precizní zemědělství a monitoring krajiny leží ve využití standardních nízkonákladových RGB senzorů. Řada studií prokázala, že i tyto běžné kamery, kterými je dnes vybavena většina komerčně dostupných dronů, představují mimořádně silný a efektivní nástroj. Jejich hlavní předností je především nízká pořizovací cena a jednoduchost použití, což je činí dostupnými pro široké spektrum uživatelů od malých farmářů po velké výzkumné instituce.

Pro maximální přínos RGB senzorů je zásadní pokročilé softwarové zpracování obrazu. I bez NIR pásma lze z RGB snímků vypočítat celou škálu vegetačních indexů (např. Excess Green (ExG), Normalized Green Red Difference Index (NGRDI), Visible Atmospherically Resistant Index (VARI)), které využívají poměry a rozdíly mezi červeným, zeleným a modrým kanálem a citlivě odrážejí změny například v obsahu chlorofylu – především Triangular Greenness

Index (TGI) (Komárková et al., 2020; De Swaef et al., 2021). Studie Komárková et al. (2020) například potvrdila, že indexy NGRDI a VARI poskytly nejlepší výsledky pro odlišení vegetace a vodní hladiny. Studie Cvetković et al. (2023) demonstrovala, že metodika založená na porovnávání histogramů indexu ExG mezi zdravým a stresovaným porostem kukuřice dosáhla přesnosti detekce stresu přes 89 %, a to bez potřeby složitých klasifikačních modelů. To ukazuje na sílu přímé spektrální analýzy, je-li k dispozici kvalitní referenční vzorek.

Významným posunem v analýze RGB dat je také jejich převod do alternativních barevných prostorů, jako jsou HSV (Hue, Saturation, Value) nebo CIELab (Commission Internationale de l'Éclairage $L^*a^*b^*$), které lépe odpovídají lidskému vnímání barev a jsou méně citlivé na kolísání osvětlení. Studie Giamerti et al. (2024) jasně prokázala, že převod snímků do prostoru CIELab a následná analýza a^* kanálu (reprezentujícího spektrum od zelené po červenou) výrazně zpřesnila odhad stresu ze sucha u rýže. Koeficient determinace (R^2) mezi barevným projevem a teplotou porostu se po převodu zvýšil z 0,48 na 0,64, což je statisticky významné zlepšení. De Swaef et al. (2021) ve své studii pšicnin identifikovali index H (Hue) z prostoru HSV a NDLab (vytvořený z CIELab) za nejlepší ukazatele odolnosti vůči suchu, které navíc vykazovaly vysokou míru dědičnosti (heritability) a silnou korelaci s vizuálním hodnocením šlechtitele ($r > 0,8$). Podobně i Rufo et al. (2021) zjistili, že index Hue, získaný z pozemních RGB snímků, byl jedním z nejlepších prediktorů pro odhad indexu listové plochy (LAI) u pšenice. To naznačuje, že tyto indexy nejen dobře korelují s vizuálním projevem stresu, ale také spolehlivě odrážejí geneticky podmíněné rozdíly mezi rostlinami, což z nich činí ideální nástroje pro šlechtitelské programy.

I přes tyto pokroky mají RGB senzory své limity. Nejvýznamnějším je saturace signálu v hustých, zaplněných porostech. V pozdějších fázích růstu, kdy index LAI dosahuje vysokých hodnot a koruny se plně zapojí, přestávají vegetační indexy založené pouze na barvě reagovat na další nárůst biomasy a ztrácejí svou predikční schopnost. Tento problém prakticky potvrdila studie Rufo et al. (2021), která ukázala, že odlišná, vyšší a méně uspořádaná struktura porostu u starých krajových odrůd pšenice ve srovnání s moderními kultivary pravděpodobně vedla k dřívější saturaci indexů, což zhoršilo přesnost predikcí agronomických vlastností. V podstatě, z pohledu senzoru, porost vypadá stále stejně „zeleně“, i když jeho biomasa dále narůstá (Maimaitijiang et al., 2020; De Swaef et al., 2021). Elegantním řešením je fúze dat: moderní fotogrammetrie (Structure from Motion) umožňuje z RGB snímků získat nejen 2D ortofotomozaiku, ale také DSM. Z něj lze následně, po odečtení DMT, odvodit výšku porostu (Canopy Height – CH). Kombinace spektrálních informací (z vegetačních indexů) a strukturních informací (z výšky porostu) dokáže problém saturace účinně zmírnit. Studie Maimaitijiang et al. (2020) a Li (2019) shodně ukazují, že přidání výšky porostu jako dalšího

prediktoru do modelu výrazně zvyšuje přesnost odhadu biomasy (Li (2019) našel korelaci až $r = 0,88$ pro suchou biomasu), LAI i obsahu dusíku, a to právě v hustých porostech, kde samotné spektrální indexy selhávají.

3.2 Porovnání klasifikačních přístupů a jejich aplikací

Analýza obrazových dat z dronů pro účely identifikace krajinného pokryvu nebo stavu vegetace je komplexní úloha, k jejímuž řešení bylo navrženo a testováno široké spektrum metod. Tyto metody lze v zásadě rozdělit podle míry interakce s uživatelem, základní jednotky, se kterou pracují, a podle složitosti použitého algoritmu. Výběr správného postupu je klíčový pro dosažení přesných a interpretovatelných výsledků, což potvrzuje řada srovnávacích studií.

3.2.1 Neřízená vs. řízená klasifikace

Základní dělení klasifikačních metod vychází z toho, zda algoritmus pro svou funkci vyžaduje předchozí „trénink“ na datech označených člověkem.

Neřízená klasifikace představuje plně automatizovaný přístup, který je atraktivní svou rychlostí a jednoduchostí. Jeho hlavní výhodou je, že nevyžadují časově náročnou tvorbu trénovacích dat, což minimalizuje možnost lidské chyby v této fázi (Krátký & Komárková, 2023). Jejich praktická využitelnost je však často omezena. Jak ukázaly srovnávací studie, tyto metody často nedokáží spolehlivě odlišit spektrálně podobné třídy (např. různé typy vegetace nebo půdy) a jejich přesnost je systematicky nižší než u řízených přístupů. Přímé srovnání ve studii Komárková et al. (2020) při mapování pobřežní zóny rybníka ukázalo, že neřízená klasifikace ISO Cluster (implementovaná jako K-Means) dosáhla velmi nízké shody s realitou (koeficient Kappa pouze 0,4576), protože nedokázala správně odlišit vodu, vegetaci a přechodovou zónu. Existují však inovativní postupy, které tento nedostatek řeší. Například Boonrang et al. (2024) navrhli metodu, která kombinuje K-Means s následnou automatickou analýzou spektrálních trendů pro označení shluků, a dosáhli tak přesnosti srovnatelné s řízenými metodami (Kappa 0,96), aniž by potřebovali jedinou manuální anotaci.

Řízená klasifikace je naopak postavena na znalostech experta, který nejprve v obraze vyznačí referenční plochy (trénovací data) pro každou požadovanou třídu. Algoritmus se na těchto vzorech „naučí“ spektrální charakteristiky jednotlivých tříd a následně je aplikuje na zbytek obrazu. Tento přístup obecně dosahuje výrazně vyšší přesnosti (Krátký & Komárková, 2023; Pádua et al., 2020). Mezi nejpoužívanější a nejlépe ověřené algoritmy patří:

- **Maximum Likelihood (ML):** klasická statistická metoda, která se v mnoha studiích ukázala jako velmi spolehlivá a často poskytuje nejlepší výsledky mezi konvenčními metodami. Například práce Komárková & Jech (2020) na stejné lokalitě jako u neřízené

klasifikace dosáhla s ML vynikající přesnosti (koeficient Kappa až 0,9246), což jasně demonstruje nadřazenost tohoto přístupu.

- **Random Forest (RF) / Random Trees (RT):** tento algoritmus, založený na principu ansámblu rozhodovacích stromů, je v současnosti považován za nejrobustnější a nejspolehlivější klasifikátor. Jeho síla spočívá v odolnosti vůči šumu a schopnosti pracovat s velkým množstvím vstupních proměnných. Ve srovnávací studii na vinohradu (Pádua et al., 2020) jasně překonal ostatní metody s celkovou přesností 87,8 %.
- **Support Vector Machine (SVM):** ačkoliv se jedná o velmi silný algoritmus, jeho výkon může být citlivý na konkrétní data. Studie Pádua et al. (2020) ukázala, že v podmínkách, kde byl nízký vizuální kontrast mezi révou a jejím stínem, SVM zcela selhal s přesností jen 45,3 %, zatímco RF si zachoval vysokou přesnost. To naznačuje, že SVM může mít potíže v případech se složitými nebo špatně oddělitelnými třídami.

Hlavní nevýhodou řízených metod je nutnost vytvoření kvalitních a reprezentativních trénovacích dat, což je časově náročná a subjektivní práce vyžadující znalost dané lokality (Jech et al., 2023; Krátký & Komárková, 2023).

3.2.2 Pixelová vs. objektově orientovaná klasifikace (OBIA)

Snímky z dronů s velmi vysokým rozlišením přinášejí problém známý jako „sůl a pepř“ (viz kapitola 2.5 Postklasifikační úpravy). Proto se pro tato data stále více prosazuje objektově orientovaná analýza obrazu (OBIA). Tento přístup nejprve pomocí segmentace sloučí sousední pixely s podobnými vlastnostmi do smysluplných objektů (např. koruna stromu, plocha plodiny, střecha budovy). Teprve v druhém kroku je klasifikován celý objekt jako jeden celek. To umožňuje využít nejen spektrální informace, ale také tvar, velikost, texturu a kontextové vztahy mezi objekty. Jak ukázala studie Jech et al. (2023) při monitoringu zvířat, objektově orientované metody dosáhly systematicky vyšší přesnosti než jejich pixelové protějšky (např. u SVM se Kappa koeficient zvýšil z 0,713 na 0,739 a u KNN z 0,462 na 0,603), protože lépe zachytily tvary těl zvířat a nebyly tolik ovlivněny drobnými spektrálními odchylkami uvnitř objektu.

Ačkoliv se při zpracování UAV snímků s velmi vysokým rozlišením často doporučuje využití segmentačních metod (OBIA), Sedlák et al. (2019) ukazují, že i bez pokročilé segmentace lze při dostatečně jemném prostorovém rozlišení dosáhnout kvalitní separace hlavních tříd. Při ruční digitální interpretaci byl dobře patrný přechod mezi vodní hladinou, vegetací a přechodovou zónou vodních těles, přičemž výsledky nebyly negativně ovlivněny absencí NIR spektra. To naznačuje, že kvalitní prostorové rozlišení může v některých případech nahradit složité segmentační přístupy.

3.2.3 Hluboké učení (Deep Learning) a jeho výzvy

V posledních letech dominují v oblasti analýzy obrazu metody hlubokého učení, zejména CNN a jejich specializované architektury pro sémantickou segmentaci (např. FCN, DeepLabV3+). Tyto modely dokáží automaticky extrahovat komplexní hierarchické příznaky přímo ze nezpracovaných obrazových dat a dosahují nejvyšší citlivosti, například při detekci drobných symptomů chorob. Görlich et al. (2021) s pomocí FCN (Fully Convolutional Network) dosáhli recall 85 % při detekci cerkosporové skvrnitosti na řepě. Jejich nasazení v praxi však naráží na tři hlavní bariéry:

- **Vysoká datová náročnost:** efektivní trénink CNN vyžaduje stovky, spíše však tisíce, ručně a pečlivě anotovaných snímků. Jejich tvorba je největším „úzkým hrdlem“ celého procesu a je extrémně nákladná a časově náročná (Kerdegari et al., 2019; Khan et al., 2021).
- **Problém doménového posunu (Domain Shift):** model, který byl s vysokou přesností natrénován na datech z jedné lokality, často dramaticky ztrácí výkon, když je aplikován na snímky z jiné oblasti, pořízené v jiný den nebo za jiných světelných podmínek. Studie Görlich et al. (2021) zdokumentovala dramatický pokles citlivosti (recall) z 85 % na trénovací ploše na 67 % při přenosu modelu na novou lokalitu. Tento problém je hlavní překážkou pro vytváření univerzálně použitelných modelů.
- **Výpočetní náročnost:** trénink hlubokých modelů vyžaduje specializovaný a výkonný hardware (GPU), který není vždy dostupný.

Jako cesta k překonání těchto limitů se ukazuje semi-supervizované učení, které kombinuje malé množství anotovaných dat s velkým množstvím neanotovaných. Například Generativní adversariální síť (GAN) mohou být použity k vytvoření realistických syntetických dat, která obohatí trénovací sadu a zvýší robustnost modelu. Tímto přístupem se podařilo dosáhnout přesnosti až 90 % při klasifikaci plevelů, i když bylo k dispozici jen 20 % anotovaných dat (Khan et al., 2021). Dalším slibným směrem je návrh hybridních metod, jako je přístup CMCA (Conventional Multi Classifier Approach) navržený Jechem (2024). Tento přístup využívá kombinaci výstupních dat z více klasifikací do společného výstupního snímku, čímž zvyšuje celkovou přesnost klasifikace. Kombinací více klasifikací tak překonává limity jednotlivých metod a ve vybraných případech dosáhl vyšší přesnosti oproti standardně použitým klasifikátorům.

3.3 Aplikace v odlišných oblastech

Je důležité si uvědomit, že volba nejvhodnějšího postupu je úzce spjata s charakterem sledovaného jevu. Ačkoliv jsou technologické nástroje jako UAV a metody strojového učení univerzální, jejich konkrétní implementace se liší. Příkladem mohou být dvě oblasti, které sice

využívají podobné technologie, ale řeší odlišný typ problému než detekce fyziologického stresu:

- **Hodnocení škod po požáru:** Simes et al. (2024) využili multispektrální a RGB data z dronu ke klasifikaci rozsahu a závažnosti poškození lesa po požáru. Zde jsou spektrální změny dramatické a skokové – přechod od živé vegetace k popelu a spálené půdě. Analýza se soustředí na indexy citlivé na spálenou biomasu, jako je NBR (Normalized Burn Ratio), a klasifikátory (RF a SVM) zde mají za úkol rozlišit mezi různými stupni destrukce, přičemž nejlepší RF model dosáhl přesnosti přes 96 %.
- **Detekce poléhání plodin:** Yang et al. (2022) se ve své studii zaměřili na detekci a kvantifikaci poléhání kukuřice. V tomto případě není primárním znakem změna barvy listů, ale makroskopická strukturní změna. Klíčovou roli zde hraje analýza textury porostu, a především data z výškového modelu (CHM), která odhalí oblasti s polehlými rostlinami. Nejúspěšnější model (ResNet-50) dosáhl přesnosti 96,3 % při použití multispektrálních dat.

3.4 Hlavní konsenzus napříč literaturou

Navzdory různorodosti zkoumaných plodin, prostředí a analytických metod lze z prostudované literatury vyvodit několik shodných závěrů, které tvoří současné paradigma oboru:

- **Schopnost UAV sledovat krátkodobé změny vegetace.** Pro monitoring sezónní dynamiky vegetace se jako výhodná jeví UAV data sbíraná v opakovaných časových horizontech. Sedlák et al. (2019b) na příkladu pobřeží malých vodních ploch dokumentovali změny v poměru vegetace, vodní hladiny a periodicky zaplavovaných zón během vegetační sezóny, přičemž již během několika měsíců došlo k významné přeměně zastoupení sledovaných kategorií. Tyto časové řady demonstrují sílu UAV pro záznam krátkodobých změn prostředí.
- **Vysoké prostorové rozlišení je klíčové.** Všechny analyzované práce se shodují, že schopnost UAV pořizovat snímky s rozlišením v řádu jednotek centimetrů je zásadní výhodou oproti satelitním datům. Takový detail umožňuje analýzy na úrovni jednotlivých rostlin či jejich orgánů a detekci nejranějších projevů stresu, které by jinak byly neviditelné. (Görllich et al., 2021; De Swaef et al., 2021).
- **RGB data jsou překvapivě silným nástrojem.** Ačkoliv multispektrální kamery poskytují cenné informace, řada studií prokázala, že pro mnoho úloh jsou plně dostačující správně zpracovaná RGB data (Rufo et al., 2021). Klíčem k úspěchu je pokročilé softwarové zpracování, zejména využití vegetačních indexů a převod do barevných prostorů (CIELab, HSV), které lépe korelují s fyziologickým stavem rostlin a tlumí vliv světelných podmínek (De Swaef et al., 2021; Giamerti et al., 2024).
- **Řízené klasifikační metody dominují v přesnosti.** Systematická porovnání potvrzují, že řízené metody, pokud jsou natrénovány na kvalitních datech, poskytují spolehlivé

a výrazně přesnější výsledky než jednodušší neřízené přístupy. Jako nejrobustnější a nejspolehlivější se napříč studiemi ukazují algoritmy jako Maximum Likelihood (Komárková & Jech, 2020; Krátký & Komárková, 2023) a Random Forest (Pádua et al., 2020).

3.5 Identifikované mezery ve výzkumu a hlavní výzvy

Navzdory rychlému pokroku zůstává v oblasti několik přetrvávajících výzev, které představují příležitosti pro budoucí výzkum:

- **Standardizace metodik akvizice a zpracování dat.** Jednou z největších překážek pro porovnatelnost a replikaci výsledků je absence jednotných protokolů. Studie používají různé letové výšky (od 15 m do 60 m), různé míry překryvu snímků (od 60 % do 85 %) a různé metody radiometrické kalibrace. To ztěžuje posouzení, do jaké míry jsou rozdíly ve výsledcích způsobeny použitou metodou a do jaké míry samotnými daty (Gano et al., 2024; Shu et al., 2022).
- **Přenositelnost modelů (Domain Shift).** Jak bylo rozebráno v předchozí kapitole, jedná se o zásadní problém moderních metod strojového učení. Schopnost modelů generalizovat a fungovat spolehlivě na datech z nových lokalit či za odlišných podmínek je stále nízká, což brání jejich univerzálnímu nasazení v praxi. (Görlich et al., 2021).
- **Datová a výpočetní náročnost.** Zatímco klasické metody strojového učení si vystačí s desítkami až stovkami trénovacích vzorků, modely hlubokého učení vyžadují tisíce ručně anotovaných snímků. Jejich tvorba je největším „úzkým hrdlem“ celého procesu a je extrémně nákladná a časově náročná, přičemž jejich využití je dále limitováno vysokými nároky na výpočetní výkon počítače, především GPU (Kerdegari et al., 2019; Khan et al., 2021). U UAV dat s RGB senzory je významným praktickým omezením časová náročnost ruční interpretace výstupů. Studie Sedláka et al. (2019 a 2019b) uvádějí, že proces ruční digitální kategorizace (například voda, vegetace a jejich přechodová zóna) je při práci s časovými řadami UAV snímků velmi časově náročný.
- **Potenciál fúze dat.** Ačkoliv studie naznačují obrovský potenciál v kombinování dat z různých zdrojů – například spektrálních dat s výškovým modelem porostu (Maimaitijiang et al., 2020) nebo s termálními daty (De Swaef et al., 2021) – jsou tyto přístupy zatím v počátcích a chybí systematické studie, které by jejich přínosy ověřily pro různé plodiny a typy stresu.

4 ZPRACOVÁNÍ UAV DAT A KLASIFIKACE VYBRANÝCH ZÁJMOVÝCH ÚZEMÍ

Tato kapitola popisuje metodiku zpracování obrazových dat získaných pomocí bezpilotních prostředků u vybraných zájmových území. Postupně jsou zde představeny jednotlivé kroky workflow, od výběru lokalit a zájmových území, přípravy letu a plánování mise, přes samotné pořízení snímků a jejich zpracování do formy ortofotosnímku, až po přípravu dat pro klasifikaci a výpočet spektrálních indexů. Dále je popsán výběr trénovacích ploch, konfigurace klasifikačních algoritmů a proces trénování modelů v prostředí ArcGIS Pro. Kapitola rovněž zahrnuje fáze ověření přesnosti klasifikací a využití vlastních nástrojů, viz přílohy I–VII: GeoShrink (I), FCC MS ImageProcessor (II), MetriCalc (III), ImageMetaLocator (IV), UAVAreaCalc (V), OrthophotoTool (VI), UAVThesisWeb (VII) pro podporu interní analýzy a vizualizací.

4.1 Použité bezpilotní letouny

V praktické části diplomové práce byly nasazeny dva čtyřmotorové bezpilotní letouny řady DJI Phantom 4 – základní Phantom 4 (P4) a pokročilejší Phantom 4 Pro (P4 Pro). Oba stroje sdílejí shodnou drakovou koncepci s tuhým magneziovo-kompozitovým bílým rámem a tříosým stabilizovaným gimbalem, avšak liší se zejména ve snímací soustavě, záznamové elektronice a senzorické redundanci. Tato dvojice plnila hlavní sběr obrazových dat pro všechny klasifikační úlohy. Porovnání jejich vlastností se nachází v tabulce 1.

Pro operativní průzkum zájmových lokalit, rychlé ověření světelných podmínek a předběžné vytyčení vzletových bodů byl navíc využit ultralehký DJI Mini 3 Pro (MTOM < 250 g, kategorie C0). Díky kompaktním rozměrům, délce letu přes 30 min a minimální předletové přípravě bylo možné dron zvednout do vzduchu během několika desítek vteřin, pořídit orientační náhledy terénu, odhalit překážky a následně optimalizovat letový plán Phantomů.

Tabulka 1: Srovnání snímacích systémů Phantom 4 vs. Phantom 4 Pro

Vlastnost / dron	DJI Phantom 4	DJI Phantom 4 Pro
Snímač	1/2,3" CMOS, 12 Mpx	1" CMOS, 20 Mpx
Aktivní plocha	6,3 × 4,7 mm	13,2 × 8,8 mm
Objektiv	ekv. 20 mm, F 2,8	ekv. 24 mm, F 2,8–11
Mechanická závěrka	–	1/2000 s
GSD při 50 m AGL	2,19 cm px ⁻¹	1,36 cm px ⁻¹
Pokrytí 1 ha (80 % F/B)	~ 2 min 06 s	~ 2 min 36 s

Zdroj: [vlastní zpracování dle DJI [b.r.]

Kromě mechanické závěrky, která potlačuje geometrické deformace způsobené rolling-shutter efektem při rychlých nebo šikmých přeletech, nabízí Phantom 4 Pro také proměnnou clonu v rozsahu $f/2,8$ – $f/11$. Přicloučením lze regulovat množství dopadajícího světla a vyrovnat expozici bez nutnosti ND filtrů; zároveň se zvětší hloubka ostrosti, potlačí chromatické vady a vzroste mikrokontrast textur, což usnadňuje práci pro segmentační algoritmy. Takto získané snímky poskytují přesnější radiometrická data a stabilnější geometrii pro tvorbu ortofosnímků a 3D modelů.

S výjimkou jedné případové studie, tvořil Phantom 4 Pro hlavní pracovní platformu díky většímu snímači, variabilní cloně a mechanické závěrce. Jelikož při stejných legislativně omezených výškách (120 m AGL (Above Ground Level), resp. výškový GRID) dosahuje podstatně jemnějšího GSD než základní P4, umožnil zachovat předpisy pro let v kategorii OPEN, a přesto získat vysoce detailní podklady pro supervised i unsupervised klasifikace.

Phantom 4 byl ze zkoumaných lokalit nasazen ve studii Vraclav. Úloha vyžadovala rychlé pokrytí plochy, kdy nezáleželo na nejvyšším rozlišení. Menší datový objem (12 Mpx RAW) urychlil nejen upload do WebODM Lightning, ale i následné zpracování a mozaikování. P4 navíc fungoval jako záložní platforma, připravená převzít misi v případě neočekávaného výpadku P4 Pro. Ačkoliv byl tento dron využit při vícero snímáních v rámci výzkumu, z analyzovaných případových studií byl použit pouze v této lokalitě.

4.2 Definice zájmových území

Kapitola popisuje výběr různorodých území pro testování klasifikačních metod z RGB dat UAV a jejich charakteristiku, zaměřenou na poškození vegetace a krajiny, s cílem ověřit přesnost a robustnost klasifikací.

4.2.1 Kritéria výběru lokalit

Výběr studijních lokalit vycházel ze snahy pokrýt různé typy poškození vegetace a krajinných struktur, které jsou relevantní z hlediska praktické aplikace UAV-klasifikace v různých odvětvích environmentálního monitoringu. Hlavním cílem bylo ověřit účinnost a přesnost metod řízené i neřízené klasifikace ve specifických podmínkách, jež zahrnují jak přirozeně se vyskytující extrém (požáry, povodně), tak zemědělsky významné zásahy, například poškození plodin meteorologickými jevy.

Při výběru zájmových území byla zohledněna následující kritéria:

- Reálné poškození nebo změna pokryvu, kterou lze na základě vizuální i spektrální odlišnosti zaznamenat a dále klasifikovat pomocí RGB snímků.

- Možnost případného opakovaného snímání a provozní podmínky zejména s ohledem na platnou legislativu provozu UAV v dané oblasti a omezení bezletových zón.
- Různorodost scénářů a prostředí – aby bylo možné testovat klasifikace v různých typech vegetačního pokryvu.
- Rovinný a přehledný terén, který minimalizuje zkreslení způsobené výškovými rozdíly a umožňuje přesné plánování letových drah.
- Možnost spektrální diferenciacie tříd, tedy přítomnost kontrastních prvků (např. spálené vs. živé porosty, zdravé vs. poškozené obilí), která usnadňuje trénink klasifikačních modelů.

Lokalit bylo záměrně vybráno více, aby bylo možné provést jak metodické porovnání různých algoritmů, tak ověření robustnosti klasifikací napříč různými typy vegetačního pokryvu, světelných podmínek a strukturou terénu.

4.2.2 Charakteristika jednotlivých území

První Případová studie: klasifikace vegetace – Vraclav se zabývá klasifikací území, na němž došlo k úplné destrukci porostu ozimé řepky vlivem extrémních meteorologických podmínek (krupobití). Zkoumaná scéna poskytla vhodné podmínky pro ověření možností spektrálního zvýraznění plevelné vegetace. Účelem bylo posoudit účinnost jednotlivých RGB indexů při odlišení porostových zbytků a vyhodnotit jejich přínos pro klasifikaci v homogenně narušeném prostředí.

Druhá Případová studie: klasifikace spáleného porostu – Albánie se zaměřuje na území zasažené intenzivním přízemním požárem, v jehož důsledku vznikla výrazná mozaika zcela spálené a neporušené vegetace. Tato kontrastní struktura umožnila ověřit schopnost UAV klasifikace detekovat a prostorově vymezit požárem postižené oblasti. Účelem bylo posoudit účinnost obrazové analýzy v kontextu operativního mapování škod a potenciálního využití pro účely pojišťoven či environmentálního monitoringu.

Třetí Případová studie: klasifikace poškození obilnin – Loučky se zabývá klasifikací zemědělského porostu poškozeného extrémními meteorologickými jevy, konkrétně bouřkou s krupobitím. Účelem bylo ověřit možnost rozlišení různých úrovní poškození obilného porostu a identifikace zón s předpokládanou ztrátou výnosu. Pro analýzu byly využity RGB snímky a spektrální index TGI, který zvýrazňuje vitalitu vegetace na základě intenzity zelené složky.

Čtvrtá Případová studie: klasifikace vegetačních složek – Hrádek se soustředí na klasifikaci zemědělského pozemku, kde došlo ke kombinovanému poškození porostu obilnin bouří a krupobitím. Lokalita umožnila testování klasifikace tří odlišných tříd – zdravého porostu, poškozené plodiny a plevele výhradně na základě RGB dat. Účelem bylo ověřit možnosti

jemnější segmentace vegetačního pokryvu a prostorové identifikace doprovodné flóry v rámci kulturní výsadby.

Pátá Případová studie: klasifikace zaplavené plochy – Čestice se zaměřuje na klasifikaci pastviny postižené rozlivem řeky po intenzivních deštích. Účelem bylo ověřit, zda lze pomocí UAV dat rozlišit zaplavené a nezaplavené plochy i za ztížených světelných podmínek. Pro zpracování byla využita RGB složka a vodní index GBRWI, který umožňuje spolehlivější detekci vodních ploch i při přítomnosti odlesků.

Šestá Případová studie: porovnání klasifikačních modelů – Čestice (II) navazuje na předchozí UAV mapování povodňové lokality a zaměřuje se na systematické porovnání různých přístupů ke klasifikaci zaplavených a vlhkých ploch. Důraz byl kladen na posouzení přesnosti klasifikace při použití tradičních algoritmů i metod hlubokého učení, a to výhradně na základě RGB obrazových dat. Testovány byly různé architektury a varianty nastavení modelů s cílem zjistit, jak volba metodiky a parametrů ovlivňuje prostorovou přesnost klasifikace vodních reziduí. Výsledky přispěly k určení nejvhodnějšího přístupu pro operativní UAV mapování rozlivu v homogenním, rovinném prostředí.

Sedmá Případová studie: detekce objektů – sad Trpík se zaměřuje na inventarizaci semenného sadu na základě RGB dat z UAV. Lokalita s pravidelně rozmístěnými stromy a prázdnými místy poskytla vhodné podmínky pro ověření detekčních schopností metod hlubokého učení při rozpoznávání jednotlivě stojících stromů. Účelem bylo otestovat přesnost automatizovaného počítání objektů a identifikaci chybějících stromů v pravidelně strukturovaném porostu.

4.3 Postup zpracování obrazových dat

Tato část shrnuje kompletní workflow od prvotního průzkumu terénu až po kvantitativní způsob ověření přesnosti klasifikace, které bylo aplikováno na výše uvedené případové studie. Poskytuje tak jednotný metodický rámec, který zajišťuje reprodukovatelnost výsledků a umožňuje porovnání výkonnosti různých klasifikačních přístupů napříč studovanými lokalitami.

4.3.1 Přípravná fáze sběru obrazových dat

V počáteční fázi zpracování dat bylo nezbytné provést předběžné zkoumání terénu vybrané lokality, zahrnující pozemní prohlídku a leteckou analýzu, aby bylo vytyčeno vhodné zájmové území pro podrobnou segmentaci. Pozemní část zahrnovala vizuální obhlídku pozemku, základní zmapování překážek a předběžné určení tříd pro následné zpracování, přičemž tato činnost je zdokumentována v příloze na obrázcích 92–95. Pokud lokalita splňovala požadavky, byl nasazen ultralehký dron DJI Mini 3 Pro k detailnímu průzkumu z výšky. Díky nízké

hmotnosti a snadné ovladatelnosti byl ideální pro rychlé posouzení a identifikaci klíčových oblastí (viz příloha, obrázek 95).

Let s dronem DJI Mini 3 Pro byl realizován manuálně, přičemž byl proveden oblet celého vybraného území podél jeho obvodu. Během tohoto letu byly pořízeny snímky, které sloužily k orientačnímu vymezení hranic zájmového území. Tyto vizuálně stanovené hranice byly následně přeneseny a upraveny v prostředí aplikace PIX4Dcapture Pro.

V aplikaci PIX4Dcapture Pro byly na základě pořízených snímků a GPS dat vytvořeny přesné letové plány pro hlavní sběr dat, který byl proveden výkonnějším dronem s lepší záznamovou videotechnikou a vyšším rozlišením. Orientační okraje definované během prvotního průzkumu tak sloužily jako vstup pro finální automatizovaný let, jehož cílem bylo pořízení kvalitních a přesně navázaných dat pro následné zpracování ortofotosnímku a objektovou detekci.

4.3.2 Letové plánování a akvizice dat

Pro detailní pořízení snímků byl využit dron DJI Phantom 4 Pro nebo DJI Phantom 4. V aplikaci PIX4Dcapture Pro byl zvolen plán typu Single 2D Grid. Pro zajištění kvalitního překrytí snímků byl nastaven podélný překryv 80 % a příčný překryv 75 %. Úhel kamery byl nastaven na 90 °, tedy kolmý pohled dolů vůči zemi, což je ideální konfigurace pro tvorbu ortofotosnímků. Na koláži obrázku 96 v přílohách je nejprve nahoře zobrazen dron DJI Phantom 4 Pro připravený k misi, čekající na fixaci signálu GNSS satelitů, a dále dole je zachycen při manuálním vzletu za účelem automatického nasnímání dat pro ortofotomozaiku.

V případě, že se zájmové území nacházelo ve svažitém terénu, byla aktivována funkce Terrain Awareness. Tato funkce na základě staženého digitálního výškového modelu automaticky upravovala výšku letu tak, aby byla zachována konstantní vzdálenost mezi senzorem a povrchem terénu. Výsledkem bylo co nejvíce planární pokrytí snímků napříč celým územím.

Letová výška byla vždy volena tak, aby bylo dosaženo co nejnižší hodnoty GSD, tedy maximálního prostorového rozlišení. S ohledem na efektivitu letu byl rovněž upraven směr trajektorie přeletů tak, aby předpokládaná délka celé mise nepřesáhla stanovený časový limit 20 minut, který zahrnoval rezervu na vzlet, přistání a případné korekce dráhy. Tyto úpravy vycházely z odhadu doby letu generovaného přímo v rozhraní plánovací aplikace PIX4Dcapture Pro. Ukázka optimalizace trajektorie je zachycena na ilustračním obrázku 4 níže.



Obrázek 4: Vliv přeletů na provozní dobu mise

Zdroj: [vlastní zpracování z aplikace PIX4Dcapture PRO]

Na ilustračním snímku je patrné porovnání tří různých směrů trajektorie pro shodné území, které měly přímý vliv na odhadovanou dobu letu. Zatímco při původním směru přeletů činil předpokládaný čas mise přibližně 14 minut a 27 sekund, po optimalizaci byl zkrácen nejprve na 12 minut a 47 sekund a nakonec na 11 minut a 28 sekund. Tato úprava ukazuje význam správné orientace tras přeletů nejen z hlediska efektivity času, ale i provozní bezpečnosti a šetření kapacity akumulátoru UAV.

4.3.3 Zpracování ortofotosnímků

Po nasnímání dat byly jednotlivé obrazové soubory importovány do prostředí WebODM Lightning – cloudové implementace open-source nástroje OpenDroneMap (ODM), který umožňuje automatizované zpracování snímků pořízených UAV. Před samotným spuštěním

výpočtu bylo upraveno výchozí nastavení parametru orthophoto-resolution, z hodnoty 2,0 na 1,0. Tento krok byl proveden na základě analýzy GSD, kdy snímky vykazovaly prostorové rozlišení výrazně vyšší (tedy GSD nižší než 2 cm/px), a tudíž by výchozí hodnota zbytečně omezila maximální potenciál výsledného ortofotosnímku. Parametr orthophoto-resolution v prostředí ODM slouží jako omezující hranice pro finální rozlišení výstupního ortofota. Pokud z vložených snímků systém detekuje, že jejich GSD umožňuje vyšší výstupní rozlišení, zadaná hodnota definuje maximální možnou úroveň detailu.


Součástí procesu bylo v některých případech aktivování volby fast-orthophoto, která umožňuje výrazné zrychlení výpočtu výstupních ortofotosnímků. Tento mód se nejlépe uplatní v relativně rovinných oblastech, typicky například na zemědělských pozemcích, kde výškové rozdíly nemají významný vliv na přesnost ortorektifikace. Principem tohoto režimu je vynechání výpočetně náročného kroku v podobě tvorby hustého mračna bodů (dense point cloud), čímž se celý výpočetní proces značně zrychlí, a zároveň je redukována paměťová náročnost.

Z praktického testování vyplynulo, že režim fast-orthophoto poskytuje vizuálně realistický a konzistentní výstup zejména v oblastech s homogenním nebo mírně členitým reliéfem. Výhodou tohoto režimu je, že jednotlivé snímky jsou zarovnány přímo v rovině, čímž se eliminuje riziko artefaktů, které mohou vznikat při následném výpočtu 3D modelu. V porovnání s výstupy generovanými metodou využívající husté mračno bodů se v řadě případů ukázalo, že právě použití pointcloudu vede k nežádoucím deformacím – například k ořezům korunních partií stromů, nepřírozeným přechodům mezi objekty nebo k nepřesným obrysům vegetace.

Tyto nedostatky mohou být zásadní překážkou při analýzách, které kladou důraz na geometrickou věrnost a přesné zobrazení vegetačních struktur. Zejména při pokusu o rekonstrukci korun stromů nebo při detailní segmentaci vegetace se u 3D modelu vytvořeného z mračna bodů opakovaně objevovala zkreslení, deformace tvarů, nekompletní objemy a nepřesné obrysy vegetačních prvků. Výsledný výstup pak byl mnohdy méně použitelný než jednodušší ortofotosnímek, který tyto artefakty neobsahoval a zachovával optickou konzistenci.

Tento problém se výrazně projevil například u případové studie zaměřené na detekci požárem zasažené vegetace vyobrazené na obrázku 5, kde byl kladen důraz na co nejpresnější vizualizaci vertikální struktury porostu a jeho integrity. Zatímco klasický ortofotosnímek umožnil spolehlivě rozlišit narušené oblasti vegetace na základě barevného a texturního kontrastu, výstupy založené na dense point cloudu byly zatíženy geometrickým šumem, který interpretaci

výrazně komplikoval. Na základě těchto zjištění bylo ve většině případů upřednostněno použití režimu fast-orthophoto.



Obrázek 5: Kvalita ortofotosnímků – fast-orthophoto zap./vyp.

Zdroj: [vlastní zpracování z WebODM]


WebODM Lightning umožňuje také volbu algoritmu pro extrakci obrazových rysů (features). Ve většině případů byl použit výchozí algoritmus SIFT (Scale-Invariant Feature Transform), který je rychlejší a vhodný pro obecné případy. Pokud se však na mapovaných snímcích vyskytovaly problematické nebo opakovaně nepropojené oblasti, byl zvolen alternativní algoritmus DSPSIFT (Deep Structured Prediction SIFT). Ten je sice pomalejší, ale poskytuje stabilnější a přesnější výsledky v oblastech s vegetací nebo s nižším překryvem snímků a je lépe odolný vůči variabilitě měřítka či struktury.

Tato přizpůsobení zpracování vedla k efektivnějšímu a kvalitnějšímu výstupu ortofotosnímků, které sloužily jako podklad pro další klasifikační a detekční analýzy.

4.3.4 Příprava dat a spektrální zvýraznění


¹ Než byly spektrální indexy vypočteny přímo v prostředí ArcGIS Pro, byly nejprve otestovány a vizuálně ověřeny pomocí vlastní webové aplikace FCC MS Image Processor. Tato aplikace umožňuje po nahrání snímku a výběru spektrálního indexu okamžité zobrazení výsledku, včetně možnosti změny barevného podání. Díky tomu je vhodná k rychlému testování, zda daný index skutečně odhaluje očekávané vzory a rozdíly v datech, a tedy bude funkční i při klasifikaci.

¹ Veškeré kroky zpracování dat, od přípravy a spektrálního zvýraznění přes tvorbu tematických snímků až po klasifikaci a zhodnocení, probíhaly během studijního pobytu na Taiwanu, proto je v tiráži tematických snímků uvedeno místo vzniku Taipei.



Obrázek 6: Rozhraní aplikace GeoShrink

Zdroj: [vlastní zpracování]




Obrázek 7: Rozhraní aplikace FCC MultiSpectral Image Processor

Zdroj: [vlastní zpracování]


Jelikož aplikace běží na vzdáleném serveru s omezenými prostředky (2 vCPU a 8 GB RAM), bylo nutné pro rychlé zpracování snížit velikost vstupních dat. K tomuto účelu byla využita také druhá vlastní aplikace GeoShrink, která slouží k rychlému přeskálování a zmenšení ortofotosnímku při zachování potřebné informační hodnoty, viz obrázek 6. Díky tomuto postupu probíhá vizualizace ve FCC MS Image Processor téměř okamžitě, což výrazně urychlilo testovací a ověřovací fázi, viz obrázek 7.

V této fázi následně byly připraveny vstupní podklady pro klasifikaci a výpočty spektrálních indexů. Nejprve byla v prostředí ArcGIS Pro pomocí nástroje Create Feature Class vytvořena polygonová vrstva definující hranice zájmového území. Tato vrstva sloužila jako základ pro oříznutí původního ortofotosnímku prostřednictvím nástroje Extract by Mask, čímž byla pracovní podoba mapy omezena pouze na analyzované území. Zmíněné kroky jsou zobrazeny na obrázcích 8 a 9.



Obrázek 8: Tvorba vrstvy ZÚ v prostředí ArcGIS Pro


Zdroj: [vlastní zpracování v ArcGIS Pro]



Obrázek 9: Ořez ortofotosnímku dle polygonu ZÚ

Zdroj: [vlastní zpracování v ArcGIS Pro]

Dále byl pomocí nástroje Make Raster Layer rozdělen původní vícepásmový rastr na jednotlivé barevné spektrální kanály (červený, zelený, modrý), postup je vidět na obrázku 10. Výsledné vrstvy pak mohly být využívány samostatně nebo kombinovány dle potřeby v dalších výpočetních operacích. Následně byl využit nástroj Raster Calculator, který umožňuje výpočty spektrálních indexů na základě matematických operací mezi jednotlivými kanály.



Obrázek 10: Separace rastu a výpočet spektrálního indexu

Zdroj: [vlastní zpracování v ArcGIS Pro]

Jako příklad byl zvolen spektrální index VARI (Visible Atmospherically Resistant Index), který dobře reaguje na vegetační pokryv v RGB datech. Výpočet proběhl podle následujícího vzorce:

$$\text{VARI} = (\text{Green} - \text{Red}) / (\text{Green} + \text{Red} - \text{Blue}) \quad (4.1)$$

Zdroj: [Gitelson et al., 2002]

Výsledný rastrový soubor byl uložen ve formátu GeoDatabase pro další využití v klasifikačních algoritmech. Podobným způsobem byly následně spočteny i další spektrální indexy využívané v jednotlivých případových studiích. Níže jsou uvedeny jejich matematické vzorce:

$$\text{SNDGR} = [\text{Green} - (2 \times \text{Red})] / [\text{Green} + (2 \times \text{Red}) + 0,5] \quad (4.2)$$

Zdroj: [vlastní spektrální index]

$$\text{TGI} = -0,5 \times [190 \times (\text{Red} - \text{Green}) - 120 \times (\text{Red} - \text{Blue})] \quad (4.3)$$

Zdroj: [Hunt et al., 2013]

$$\text{GBRWI} = [(1,2 \times \text{Green}) + (0,8 \times \text{Blue}) - \text{Red}] / [(1,2 \times \text{Green}) + (0,8 \times \text{Blue}) + \text{Red} + 0,5] \quad (4.4)$$

Zdroj: [vlastní spektrální index]

$$\text{RGBVI} = (\text{Green}^2 - \text{Red} \times \text{Blue}) / (\text{Green}^2 + \text{Red} \times \text{Blue}) \quad (4.5)$$

Zdroj: [Bendig et al., 2015]

$$\text{ExGI} = 2 \times \text{Green} - \text{Red} - \text{Blue} \quad (4.6)$$

Zdroj: [Woebbecke et al., 1995]

$$\text{GCC} = \text{Green} / (\text{Red} + \text{Green} + \text{Blue}) \quad (4.7)$$

Zdroj: [Gillespie et al., 1987]

$$\text{GLI} = (2 \times \text{Green} - \text{Red} - \text{Blue}) / (2 \times \text{Green} + \text{Red} + \text{Blue}) \quad (4.8)$$

Zdroj: [Gobron et al., 2000]

$$\text{MGLI2} = [1,6 \times (\text{Green} - \text{Red}) + 0,9 \times (\text{Green} - \text{Blue}) - 0,4 \times \text{Red}] / (1,6 \times \text{Green} + 0,5 \times \text{Red} + 2,5 \times \text{Blue}) \quad (4.9)$$

Zdroj: [vlastní spektrální index]


$$\text{NGRDI} = (\text{Green} - \text{Red}) / (\text{Green} + \text{Red}) \quad (4.10)$$

Zdroj: [Tucker, 1979]

4.3.5 Výběr trénovacích ploch

Pro vytvoření trénovacích dat bylo v prostředí ArcGIS Pro využito rozhraní Training Samples Manager, které slouží k definici vzorových tříd pro řízenou klasifikaci. Nejprve bylo vytvořeno schéma tříd – tedy systém kategorií, z nichž každá byla barevně i hodnotově odlišena a reprezentovala konkrétní typ povrchu, vegetace nebo jiný tematický objekt. Třídy byly následně vizuálně verifikovány a přiřazeny k relevantním oblastem na ortofotosnímku.

Výběr trénovacích ploch probíhal ručně, a to formou digitálního kreslení polygonů přímo na rastrovou podkladovou vrstvu. Každý polygon pokrýval vizuálně jednotnou oblast dané třídy, například části pole s poškozenou, nebo nepoškozenou, úrodou a tvořil tak trénovací vzorek. Důraz byl kladen na jejich dostatečný počet, reprezentativní rozložení po ploše a pokrytí všech definovaných tříd. Příklad trénovacích ploch je zobrazen na obrázku 11.



Obrázek 11: Trénovací třídy – Training Samples Manager

Zdroj: [vlastní zpracování v ArcGIS Pro]


Pro potřeby hlubokého učení byla stejná vstupní data převedena do podoby využitelné v nástrojích ArcGIS Deep Learning. K tomu byl použit nástroj Label Objects for Deep Learning, který umožnil export dat do formátu Classified Tiles. Tento formát zahrnuje mozaikovitě rozdělené dlaždice a přidružené masky klasifikovaných tříd, přičemž je vhodný jak pro klasifikaci pixelů, tak pro objektové detekce. Takto připravený datový soubor byl následně využit pro trénink různých architektur neuronových sítí včetně U-Net, DeepLabV3 nebo PSPNet. Tímto způsobem byla zajištěna konzistence mezi vstupy pro klasické klasifikace i pokročilé modely hlubokého učení, což umožnilo objektivní porovnání jejich výkonnosti na shodných datech.

4.3.6 Trénování klasifikačních modelů

Po výběru a přípravě trénovacích dat následovalo samotné trénování klasifikačních modelů. V rámci této fáze byly použity jak klasické algoritmy strojového učení s učitelem a bez učitele, tak i pokročilé architektury hlubokého učení. Pro řízené klasifikace byly využity algoritmy Maximum Likelihood, Support Vector Machine, Random Trees a K-Nearest Neighbor, zatímco pro neřízenou klasifikaci byl nasazen algoritmus ISO Cluster. Tyto přístupy byly aplikovány přímo na vstupní spektrálně zvýrazněná data s vyznačenými trénovacími plochami.

Pro hluboké učení byl využit nástroj Train Deep Learning Model dostupný v prostředí ArcGIS Pro, který umožňuje konfigurovat a trénovat různé typy neuronových sítí. Klíčovým parametrem bylo nastavení počtu epoch – ten byl ve většině případů stanoven na hodnotu 25, což představovalo vyvážený kompromis mezi délkou tréninku a kvalitou dosažených výsledků.

V dalším kroku byl vybrán typ neuronové architektury, viz obrázek 12. V jednotlivých případových studiích byly využívány následující modely: U-Net, DeepLabV3, PSPNet a Mask R-CNN. Každý z těchto modelů byl určen buď pro segmentaci na úrovni pixelů, nebo pro detekci jednotlivých objektů, v závislosti na cílech klasifikace.



Obrázek 12: Trénink DL modelu – ArcGIS

Zdroj: [vlastní zpracování v ArcGIS Pro]

Konfigurační rozhraní umožňuje rovněž nastavení dalších parametrů, jako jsou velikost dávky (batch size), která ovlivňuje rychlost a stabilitu tréninku, a aktivace rozšíření PointRend, jež umožňuje zpřesnit segmentaci hran objektů, což se uplatnilo zejména u jemně strukturovaných vegetačních tříd.

Významnou volbou byl také Backbone Model, tedy základní architektura pro extrakci obrazových rysů. Nejčastěji byly využity modely ResNet-34, ResNet-50, ResNet-101 případně VGG-16, které byly do tréninku nasazeny jako výchozí váhy pro zrychlení konvergence a lepší generalizaci modelu.

Po spuštění tréninku byly klíčové metriky – jako validační chyba, tréninková ztráta (loss), klasifikační přesnost (accuracy) a Dice koeficient – průběžně sledovány a zaznamenávány pro následnou analýzu. Například při jedné z testovacích úloh dosáhl model v první epoše následujících hodnot: training_loss = 0,695; validation_loss = 0,732; accuracy = 0,575 a Dice = 0,308. Tyto metriky sloužily jako vodítko pro případnou úpravu trénovacích parametrů či optimalizaci architektury modelu. Ve 20. epoše u jednoho z modelů došlo ke znatelnému zlepšení výkonu, kdy training_loss poklesl na 0,431; validation_loss na 0,527; accuracy se zvýšila na 0,861 a Dice dosáhl hodnoty 0,754. Takový vývoj indikoval stabilní konvergenci modelu a jeho rostoucí schopnost generalizace.

Veškeré úlohy spojené s trénováním a testováním modelů na zařízení Apple MacBook PRO 16" (model 2021) vybaveném čipem Apple M1 Pro s 10jádrovým CPU, 16jádrovým GPU a 16jádrovým Neural Engine. Zařízení disponovalo 32 GB unifikované paměti (Unified

Memory) a běželo na operačním systému Windows 11 Pro, který byl provozován ve virtualizovaném prostředí prostřednictvím aplikace Parallels Desktop. Toto řešení umožnilo kombinovat vysoký výpočetní výkon Apple Silicon s kompatibilitou prostředí ArcGIS Pro.

4.3.7 Testování Deep Learning modelu


Po dokončení tréninku modelu hlubokého učení bylo nutné aplikovat výsledný model na nová data. Na rozdíl od klasických klasifikačních algoritmů, které po zpracování přímo vrací klasifikovaný snímek, vyžadovalo použití hlubokého učení specifické nástroje pro aplikaci modelu. V prostředí ArcGIS Pro byly využity nástroje Classify Pixels Using Deep Learning pro segmentaci na úrovni pixelů a Detect Objects Using Deep Learning pro objektovou detekci.

Po načtení vytrénovaného modelu ve formátu .dlpk bylo možné upravit různé parametry inferenčního procesu, jako například batch size nebo zapnutí funkce Non Maximum Suppression (NMS), která byla využita při detekci objektů k eliminaci překrývajících se detekcí.

4.3.8 Reklasifikace pro neřízenou klasifikaci ISO Cluster

V případě neřízené klasifikace pomocí algoritmu ISO Cluster bylo nutné provést dodatečné sjednocení a přehledné vizualizace výsledků. Nejprve byla pomocí nastavení Symbology v prostředí ArcGIS Pro nastavena výchozí barva všech tříd na bílou. Následně byly jednotlivé třídy postupně barevně odlišeny tak, aby vizuálně odpovídaly skupinám, které měly být považovány za jednu sjednocenou kategorii. Ostatní neidentifikované třídy zůstaly bílé a po vypnutí této vrstvy bylo možné porovnat výstup s referenčním RGB podkladem.

Následně byly tyto zbývající třídy odlišně obarveny a výsledný snímek znovu vizuálně porovnán s původním RGB ortofotosnímek, což umožnilo přesnější určení, které oblasti odpovídají konkrétním kategoriím a jak byly algoritmem neřízené klasifikace zachyceny. Příklad postupu reklasifikace je uveden na obrázku 13 níže.



Obrázek 13: Sjedení tříd neřízené klasifikace – Reclassify

Zdroj: [vlastní zpracování v ArcGIS Pro]


Po této analýze byl využit nástroj Reclassify, pomocí něhož byla pole `Class_name` převedena z původních hodnot na nové hodnoty, které odpovídaly třídám použitým ve zbylých metodách klasifikace. Tímto způsobem byly třídy sjednoceny např. na dvě nebo tři finální kategorie (např. poškozená a nepoškozená vegetace, voda vs. sucho apod.). Následně byly barevně upraveny tak, aby odpovídaly vizualizaci výsledků z ostatních klasifikačních metod, což umožnilo jejich snadné porovnání a interpretaci.

4.3.9 Příprava dat pro ověření přesnosti

Pro kvantitativní ověření přesnosti klasifikačních výstupů byl v prostředí ArcGIS Pro využit nástroj Create Accuracy Assessment Points, kterým byla vygenerována sada náhodných validačních bodů na základě již klasifikované vrstvy. Jako vstupní byla zvolena finální klasifikovaná vrstva, přičemž pole Target Field zůstalo nastaveno na výchozí hodnotu Classified, která odkazovala na přiřazené třídy klasifikace.

Počet náhodně generovaných bodů se pohyboval v rozmezí přibližně 500 až 1500, v závislosti na velikosti analyzovaného území a počtu tříd. Pro výběr bodů byla použita strategie Stratified

Random, která zajišťuje rovnoměrné zastoupení všech klasifikačních tříd náhodně rozmístěných po ploše, jak je možné vidět na obrázku 14. Tím bylo dosaženo reprezentativního vzorku pro výpočet konfuzní matice a dalších evaluačních metrik.



Obrázek 14: Validační body – Create Accuracy Assessment Points

Zdroj: [vlastní zpracování v ArcGIS Pro]

4.3.10 Vyhodnocení přesnosti klasifikace pomocí konfuzní matice

Po vytvoření validačních bodů následovalo samotné vyhodnocení přesnosti klasifikace. Pro tento účel byl v prostředí ArcGIS Pro využit vestavěný nástroj Compute Confusion Matrix. Tento nástroj porovnává přiřazené třídy z klasifikace s referenčními třídami určenými na validačních bodech a vypočítává statistiky vyhodnocení.


Výsledkem nástroje je konfuzní matice, která poskytuje přehled o správně i chybně klasifikovaných třídách. Výsledky byly vyexportovány do formátu CSV, nicméně výchozí formát souboru byl nepřehledný a nebylo možné z něj přímo získat přehledné hodnoty jednotlivých evaluačních metrik. Bylo proto nutné klasické metriky jako uživatelská přesnost (Precision), producentova přesnost (Recall), celková přesnost (Overall accuracy), Kappa index (Kappa) a F1-skóre (F1-score) dopočítat dodatečně, jako je uvedeno na příkladě v tabulce 2.

Tabulka 2: Konfuzní matice klasifikace – nezpracovaný export do CSV

OBJECTID	ClassValue	C 1	C 2	Total	P_Accuracy	Kappa
-1	C 1	32,0000	32,0000	64,0000	0,5000	0,0000
-1	C 2	32,0000	504,0000	536,0000	0,9403	0,0000
-1	Total	64,0000	536,0000	600,0000	0,0000	0,0000
-1	P_Accuracy	0,5000	0,9403	0,0000	0,8933	0,0000
-1	Kappa	0,0000	0,0000	0,0000	0,0000	0,4403

Zdroj: [vlastní zpracování]

K tomuto účelu byla využita vlastní aplikace MetriCalc, viz obrázek 15, která umožňuje převod CSV výstupů konfuzní matice a automatický výpočet všech potřebných metrik. Výstupem je přehledně strukturovaný soubor ve formátu Excel, ve kterém jsou hodnoty uvedeny přehledně včetně procentuálního zastoupení, viditelné na obrázku 16. Aplikace zároveň umožňuje dávkové (batch) zpracování, takže bylo možné zpracovat výstupy z celé případové studie najednou pouhým nahráním více CSV souborů.



Obrázek 15: Rozhraní aplikace MetriCalc

Zdroj: [vlastní zpracování]

Metoda: DL - UNET ResNet50						
-- Vypočtené metriky --						
Třída	Precision (uživ.)	Recall (producent.)	F1-skóre	Celková přesnost	Kappa index	
C_1	1,000000000	0,938	0,968			
C_2	0,993	1	0,996			
Průměr	0,996	0,969	0,982	0,993	0,964	
-- Originální výstup z ArcGIS PRO --						
OBJECTID	ClassValue	C_1	C_2	Total	U_Accuracy	Kappa
-1	C_1	60	4	44	0,93750000	
-1	C_2	0	536	536	1,00000000	
-1	Total	60	540	600	0,00000000	
-1	P_Accuracy	1,00000000	0,99259259	0,00000000	0,99333333	
-1	Kappa	0	0	0	0	0,96402878

Obrázek 16: Výstup metrik z aplikace MetriCalc


Zdroj: [vlastní zpracování]

4.3.11 Extrakce polohy a nadmořské výšky ze snímků

Pro účely dokumentace a přesného určení geografické lokalizace jednotlivých snímků byla vyvinuta vlastní aplikace Image Meta Locator, jejíž pracovní okno je vyobrazeno na obrázku 17. Tato aplikace umožňuje načíst jednotlivé nezpracované snímky ve formátu JPEG a automaticky z nich extrahovat dostupná metadata.

Z těchto metadat byly získány souřadnice GPS ve standardizovaném souřadnicovém systému WGS 84 / UTM s konkrétně přiřazenou zónou, např. 33N (EPSG: 32633). Získané zeměpisné souřadnice byly dále zpětně dekodovány do podoby textové adresy pomocí geolokační služby. Tento krok umožnil snadnou identifikaci místa pořízení snímku bez nutnosti vizuální kontroly v mapovém rozhraní.

Kromě polohy obsahují metadata také údaj o výšce, který však představuje kombinaci výšky terénu a výšky letu dronu. Z tohoto důvodu bylo nutné zjistit přesnou výšku terénu v daném bodě. Aplikace automaticky využila online API (Application Programming Interface) pro dotaz na DEM, případně dopočítala potřebnou hodnotu z poskytnutého TIFF souboru, který obsahoval výsledné rozlišení GSD. Tímto způsobem bylo možné zpřesnit výškový údaj a zajistit konzistenci mezi výškou letu a skutečnou nadmořskou výškou daného místa.




Obrázek 17: Aplikace Image Meta Locator

Zdroj: [vlastní zpracování]

4.3.12 Extrakce metadat ortofotosnímku pro tvorbu tiráže

Pro zjednodušení tvorby popisků a metadatových údajů výsledných ortofotosnímků v prostředí ArcGIS Pro byla vytvořena vlastní aplikace Orthophoto Tool. Tato aplikace sloužila k automatickému dekódování klíčových metadat z finálních ortofotosnímků, konkrétně hodnoty GSD, použitý CRS a typ dronu, kterým byla data pořízena, okno aplikace možno vidět na obrázku 18.

Po načtení ortofotosnímku aplikace automaticky identifikovala potřebné údaje a zkompilevala je do přehledné textové podoby. Tyto výstupy bylo možné přímo zkopírovat a vložit do tiráže (legendy) výstupního mapového dokumentu, čímž se významně zrychlil celý proces dokumentace a archivace výsledků. Tím byla zajištěna konzistence v metadatech napříč všemi případovými studii a zároveň byla snížena chybovost manuálního přepisování.



Obrázek 18: Aplikace Orthophoto Tool


Zdroj: [vlastní zpracování]

4.3.13 Výpočet rozlohy analyzovaného a celkového území

Po vytvoření hranic pro ořez vybraného zájmového území z nasnímaného podkladu bylo nutné určit nejen rozlohu samotné cílové oblasti, ale také celkovou rozlohu celého pořízeného ortofotografického snímku. Tyto informace byly klíčové jak pro dokumentaci, tak i pro vyhodnocení pokrytí a efektivity jednotlivých misí.

K tomuto účelu byla využita vlastní aplikace UAV Area Calc, která umožňuje po nahrání ortofotosnímku ve formátu TIFF a polygonové vrstvy ve formátu Shapefile automaticky vypočítat přesnou rozlohu obou ploch. Výsledky výpočtu byly následně zobrazeny v přehledné

podobě přímo v rozhraní aplikace a mohly být dále exportovány pro potřeby dokumentace nebo tvorby tiráže. Díky této aplikaci bylo možné snadno zkontrolovat, zda byla vybraná oblast adekvátně pokryta a jaký poměr představovala vzhledem k celé akviziční misi. Příklad výpočtu hodnot ze snímku v aplikaci UAV Area Calc je na obrázku 19.



Obrázek 19: Aplikace UAV Area Calculator

Zdroj: [vlastní zpracování]

5 PŘÍPADOVÉ STUDIE – INTERPRETACE A ZHODNOCENÍ VÝSLEDKŮ

Tato kapitola představuje jednotlivé případové studie ověřující praktickou použitelnost zvolených klasifikačních metod v různých scénářích poškození vegetace a změn krajinného pokryvu. Studie zahrnují prezentaci výsledků a jejich interpretaci vzhledem k danému jevu. Klasifikace proběhla na UAV ortofotosnímčích srovnáním neřízeného a řízeného přístupu.

Neřízený přístup byl reprezentován metodou ISO Cluster, která provádí automatické seskupování pixelů do tříd na základě jejich spektrální podobnosti bez nutnosti předchozího označení trénovacích vzorků. Tato metoda sloužila zejména jako referenční základ pro porovnání s řízenými klasifikacemi.

Řízené klasifikační algoritmy, využívající označené trénovací plochy, zahrnovaly několik odlišných přístupů:

- Maximum Likelihood (ML) – pravděpodobnostní metoda vycházející ze statistik tříd,
- K-Nearest Neighbors (KNN) – klasifikace podle nejbližších sousedů,
- Random Trees (RT) – ensemble rozhodovacích stromů,
- Support Vector Machine (SVM) – separace tříd hyperrovinou,
- Deep Learning (DL) – hluboké neuronové sítě bez ruční extrakce příznaků.

Vybrané algoritmy byly aplikovány na různé kombinace vstupních RGB dat. Cílem bylo ověřit nejen samotnou účinnost jednotlivých metod, ale i vliv spektrálního zvýraznění na výslednou přesnost klasifikace vegetačního pokryvu.

Hodnocení klasifikačních metod probíhalo na základě tří standardních metrik: F1-skóre, celkové přesnosti (Overall Accuracy, OA) a Kappa koeficientu. Hlavním kritériem pro porovnání výkonnosti byla hodnota F1-skóre, která kombinuje přesnost a úplnost klasifikace a je zároveň robustní vůči nevyváženému zastoupení tříd. Kappa koeficient a celková přesnost byly využity jako doplňkové ukazatele ověřující míru shody s referenčními daty a celkového počtu správně klasifikovaných vzorků.

Následující případové studie dodržují jednotnou strukturu: popis lokace, ukázky snímků území, slovní zhodnocení vycházející z průměrných hodnot metody, grafy a tabulky výsledků, detailní rozbor, zobrazení výstupů klasifikace a závěrečné zhodnocující shrnutí. Grafy jsou však přímo v textu uvedeny pouze u první studie (Vraclav). Vypočítané metriky precision a recall, včetně zbývajících grafů šesti studií, jsou pro úsporu místa přesunuty do příloh a zároveň jsou dostupné v interaktivní webové prezentaci prostřednictvím QR kódů.

5.1 Případová studie: klasifikace vegetace – Vraclav

Pro tuto případovou studii bylo zvoleno území v části obce Svatý Mikuláš u Vraclavi (49° 57' 55" N, 16° 05' 50" E). Jedná se o rovinaté, bezpřekážkové pole s porostem ozimé řepky, které v závěru vegetační sezóny zasáhla prudká bouře s krupobitím a silným větrem. Následkem extrémních meteorologických podmínek došlo k úplné destrukci zralé kulturní plodiny – údery krup poškodily lodyhy a plody, zatímco vítr způsobil rozsáhlé poléhání. V lokalitě zůstaly pouze roztroušené shluky plevelné vegetace. Cílem studie bylo zaznamenat dopady tohoto jevu na zemědělský porost a ověřit možnosti rozlišení mezi zcela poškozenou řepkou a plevelnou vegetací pomocí spektrálně zvýrazněné UAV klasifikace.

K pořízení snímků lokality byl využit bezpilotní letoun DJI Phantom 4. Let byl naplánován v softwaru Pix4Dcapture s nastaveným překryvem 85 % a realizován v automatickém režimu ve výšce přibližně 37 metrů nad povrchem. Snímkování proběhlo dne 14. 7. 2024 za optimálních meteorologických podmínek, bez výrazného větru, při stabilních světelných podmínkách.


Celkově nasnímaná plocha vybrané lokality měla rozlohu 7,2075 ha, zobrazená na obrázku 20, přičemž zkoumaná oblast byla vybrána s rozlohou 0,3635 ha, viz obrázek 21. Toto rovinaté zájmové území bylo oříznuto na polygon o rozměrech 76,38 × 55,35 metrů. Celkem bylo pořízeno 190 snímků a složena ortofotomozaika s rozlišením 1,395 cm/px.

V rámci zpracování byly využity následující spektrální indexy odvozené z RGB složek: RGBVI, VARI, ExGI, GCC, GLI, MGLI2, TGI a NGRDI. Tyto indexy byly aplikovány za účelem zvýraznění rozdílů mezi poškozenou plochou a vegetačním zbytkem a následně porovnány z hlediska efektivity při klasifikaci.




QR kód 1: Interaktivní výstup – klasifikace vegetace Vraclav

Grafy a tabulky producentovy a uživatelské přesnosti jsou k dispozici pouze v příloze A a ve webové prezentaci.



Obrázek 20: Tematický snímek – případová studie Vraclav

Zdroj: [vlastní zpracování]



Obrázek 21: Rozloha CÚ a ZÚ – případová studie Vraclav

Zdroj: [vlastní zpracování]

Nejvyšší výkonnosti dosáhla metoda Deep Learning, která vykázala F1-skóre ve výši 97,0 %, celkovou přesnost 98,2 % a Kappa koeficient 0,941. Tato metoda se ukázala jako nejrobustnější zejména v případech, kdy bylo potřeba rozlišit jemné rozdíly mezi jednotlivými třídami, například mezi zdravou a poškozenou vegetací, které vykazují velmi podobnou barevnou odezvu v RGB spektru. Vysoká výkonnost této metody je pravděpodobně dána schopností hluboké neuronové sítě pracovat nejen se spektrálními charakteristikami, ale také s prostorovými a texturovými vzory v obraze.


Na druhém místě se umístila metoda Support Vector Machine, která dosáhla F1 93,0 %, celkové přesnosti 95,6 % a Kappa koeficientu 0,861. SVM byla úspěšná zejména v oblastech s dobře definovanými hranicemi mezi třídami, avšak vykazovala mírně vyšší chybovost v přechodových zónách, kde dochází k postupnému přechodu mezi zdravým a poškozeným porostem.

Třetího nejlepšího výsledku dosáhla metoda Maximum Likelihood s F1 87,5 %, celkovou přesností 92,7 % a Kappa koeficientem 0,751. Ačkoli tato metoda vychází z relativně jednoduchého předpokladu normality dat (Gaussovo rozdělení pravděpodobností), vykazovala stabilní výsledky a potvrdila svou použitelnost i při klasifikaci dat UAV s vysokým rozlišením.

Metoda Random Trees obsadila čtvrté místo s F1 85,8 %, přesností 91,5 % a Kappa indexem 0,717. Tato metoda byla efektivní při klasifikaci homogenních oblastí a dobře pracovala s nelineárními vztahy mezi proměnnými, avšak její výkon klesal v oblastech s vyšší variabilitou nebo strukturální složitostí.

Pátou příčku obsadila neřízená metoda ISO Cluster. Přestože pracuje bez vstupních trénovacích dat, dosáhla F1 81,7 %, přesnosti 88,9 % a Kappa indexu 0,637. Výsledky ISO klasifikace byly výrazně ovlivněny typem použitého spektrálního zvýraznění, přičemž metoda často vykazovala nižší schopnost přesně oddělit jemné vzory ve scéně. ISO Cluster byl navíc citlivý na přítomnost šumu a v mnoha případech klasifikoval na základě struktury nebo textury povrchu, spíše než na základě barevné odezvy jednotlivých pixelů. To vedlo k častějšímu slučování oblastí s podobnou prostorovou strukturou, i když jejich spektrální charakteristiky byly odlišné.

Na poslední místo se zařadila metoda K-Nearest Neighbor s F1 74,9 %, celkovou přesností 83,4 % a Kappa koeficientem 0,507. Výsledky ukázaly, že tato metoda byla náchylná k chybnému zařazování v mozaikovitém a nehomogenním prostředí, kde nebyla schopna přesně interpretovat přechodové zóny mezi třídami. Vlivem své jednoduchosti a závislosti na lokálním kontextu měla tendenci ztrácet konzistenci ve větších celcích klasifikované scény. Souhrn výsledků této studie reprezentují obrázky 22–24 a tabulky 3–5 níže a v příloze A obrázky 65–66 a tabulky 22–23.





Obrázek 22: F1-skóre – případová studie Vraclav

Zdroj: [vlastní zpracování]

Tabulka 3: F1-skóre – případová studie Vraclav

F1-skóre klasifikace											
metoda	zkratka	spektrální zvýraznění									průměr
		RGB	TGI	GCC	NGDRI	RGBVI	VARI	EXGI	GLI	MGLI2	
Deep Learning	DL	0,97044	-	-	-	-	-	-	-	-	0,97044
Support Vector Machine	SVM	0,94264	0,89491	0,96794	0,82792	1,00000	1,00000	0,91092	0,82792	1,00000	0,93025
Maximum Likelihood	ML	1,00000	0,87619	0,82421	0,68357	0,87619	0,90341	0,90341	0,94235	0,86563	0,87499
Random Trees	RT	0,86044	0,75294	0,83830	1,00000	0,86508	0,87561	0,83830	0,75294	0,93780	0,85794
K-Nearest Neighbors	KNN	0,80566	0,56250	0,79675	0,77258	0,63617	0,72875	0,83756	0,77258	0,83553	0,74979
ISO cluster	ISO	0,66529	0,93225	0,87500	0,89369	0,62798	0,79675	0,90253	0,83756	0,82282	0,81710
	průměr	0,87408	0,80376	0,86044	0,83555	0,80108	0,86090	0,87854	0,82667	0,89236	0,84872

Zdroj: [vlastní zpracování]




Obrázek 23: Celková přesnost – případová studie Vraclav

Zdroj: [vlastní zpracování]

Tabulka 4: Celková přesnost – případová studie Vraclav

Celková přesnost klasifikace											
metoda	zkratka	spektrální zvýraznění									průměr
		RGB	TGI	GCC	NGDRI	RGBVI	VARI	EXGI	GLI	MGLI2	
Deep Learning	DL	0,98150	-	-	-	-	-	-	-	-	0,98150
Support Vector Machine	SVM	0,96230	0,94340	0,98110	0,88680	1,00000	1,00000	0,94340	0,88680	1,00000	0,95598
Maximum Likelihood	ML	1,00000	0,92310	0,90380	0,82690	0,92310	0,94230	0,94230	0,96150	0,92310	0,92734
Random Trees	RT	0,90380	0,86270	0,90200	1,00000	0,92160	0,92160	0,90200	0,86270	0,96080	0,91524
K-Nearest Neighbors	KNN	0,86790	0,72000	0,88000	0,86000	0,72000	0,82000	0,90000	0,86000	0,88000	0,83421
ISO cluster	ISO	0,76790	0,96000	0,92000	0,94000	0,80000	0,88000	0,94000	0,90000	0,90000	0,88977
	průměr	0,91390	0,88184	0,91738	0,90274	0,87294	0,91278	0,92554	0,89420	0,93278	0,90618

Zdroj: [vlastní zpracování]



Obrázek 24: Kappa index – případová studie Vraclav

Zdroj: [vlastní zpracování]

Tabulka 5: Kappa index – případová studie Vraclav

Kappa koeficient klasifikace											
metoda	zkratka	spektrální zvýraznění									průměr
		RGB	TGI	GCC	NGDRI	RGBVI	VARI	EXGI	GLI	MGLI2	
Deep Learning	DL	0,94090	-	-	-	-	-	-	-	-	0,94090
Support Vector Machine	SVM	0,88550	0,79110	0,93590	0,65660	1,00000	1,00000	0,82190	0,65660	1,00000	0,86084
Maximum Likelihood	ML	1,00000	0,75240	0,65050	0,37100	0,75240	0,80690	0,80690	0,88500	0,73200	0,75079
Random Trees	RT	0,72220	0,50890	0,67680	1,00000	0,73090	0,75120	0,67680	0,50890	0,87560	0,71681
K-Nearest Neighbors	KNN	0,61310	0,14430	0,60320	0,55240	0,28570	0,46040	0,67700	0,55920	0,67110	0,50738
ISO cluster	ISO	0,33820	0,86490	0,75000	0,78870	0,26470	0,59460	0,80520	0,67530	0,64790	0,63661
	průměr	0,74998	0,61232	0,72328	0,67374	0,60674	0,72262	0,75756	0,65700	0,78532	0,69984

Zdroj: [vlastní zpracování]

Hlubší analýza výsledků klasifikačních metod odhaluje jejich silné a slabé stránky ve vztahu k typům použitých vstupních dat, zejména spektrálních zvýraznění odvozených z RGB kanálů.

Metoda Deep Learning byla použita pouze na základních RGB datech bez aplikace spektrálních indexů. Vysoké průměrné výsledky dosažené touto metodou lze přisoudit schopnosti hlubokých neuronových sítí komplexně modelovat nejen spektrální, ale především prostorové a texturové vztahy v obraze. Z tohoto důvodu dokázala DL metoda stabilně rozlišovat třídy, které měly podobnou barevnou odezvu, ale výrazně se lišily svou strukturou či texturou. Omezení této metody spočívá v její vyšší výpočetní náročnosti a potřebě většího množství dat pro trénink.

Support Vector Machine prokázala velmi dobrou výkonnost při využití spektrálních indexů RGBVI, VARI a MGLI2, které byly efektivní v rozlišení vegetace díky zvýraznění zelené složky obrazu. U některých těchto indexů SVM dosáhla lokálně nejvyšších hodnot F1-skóre až 1,0; což představuje dokonalou klasifikaci v daném kontextu. Přesnost SVM silně závisela na výběru vhodných příznaků, což je důvodem její variabilní výkonnosti při méně vhodných indexech, jako byl NGDRI. Vysoká citlivost na výběr správných spektrálních příznaků naznačuje, že důkladná předběžná analýza dat může výrazně zvýšit stabilitu a přesnost této metody.

Metoda Maximum Likelihood dosáhla vysoké přesnosti na základních RGB datech i s jednoduššími indexy (GLI, VARI, EXGI), přičemž na základních RGB datech rovněž zaznamenala lokální maximální hodnotu F1 1,0. Výrazně horší výsledky byly zaznamenány při použití komplexnějších nebo nestabilních indexů jako NGDRI. Důvodem této odchylky bylo pravděpodobně porušení základního předpokladu ML o normálním rozdělení spektrálních hodnot v jednotlivých třídách, zejména u tříd s vysokou heterogenitou, jakými byly oblasti poškozené vegetace či plevele.

Random Trees vykazovaly vysokou variabilitu přesnosti v závislosti na použitém spektrálním zvýraznění, což souviselo s jejich schopností modelovat nelineární vztahy mezi třídami, ale zároveň citlivostí na šum v datech. Přestože index NGDRI přinesl v některých případech mimořádně vysoké výsledky, včetně dosažení lokálně maximální hodnoty F1 1,0; jiné indexy jako TGI vedly k výrazně nižší přesnosti. RT se proto jeví jako metoda vhodná pro prostředí s jasně definovanými strukturami, avšak méně efektivní v oblastech s vysokou prostorovou variabilitou a přechodovými zónami.


Neřízená metoda ISO Cluster byla stabilnější napříč různými spektrálními zvýrazněními, ale její výkonnost byla omezená zejména citlivostí na prostorovou strukturu a šum. ISO metoda upřednostňovala seskupování oblastí podle podobné textury, což snižovalo její schopnost efektivně rozlišovat spektrálně podobné, ale prostorově odlišné třídy. Výhodou této metody je

jednoduchost a možnost rychlé orientační klasifikace bez předchozího označení trénovacích dat.

Nejslabší výsledky metody K-Nearest Neighbor byly způsobeny její silnou závislostí na lokálním kontextu pixelů a citlivostí na změny spektrálních hodnot v rámci jednotlivých tříd. V mozaikovitém nebo prostorově fragmentovaném prostředí nedokázala metoda KNN efektivně generalizovat vztahy mezi třídami, což vedlo k výrazným chybám v přechodových oblastech a nižší celkové přesnosti. Vizuální porovnání všech zmíněných metod je na obrázku 25.


Z pohledu spektrálních indexů se potvrdilo, že nejspolehlivější výsledky obecně poskytovaly indexy zaměřené na zelenou složku (např. MGLI2, GCC, EXGI), díky jejich schopnosti zvýraznit vegetační charakteristiky a snížit vliv proměnlivých světelných podmínek. Naopak indexy citlivé na osvětlení či stíny (RGBVI, VARI) a složitější poměrové indexy (TGI, NGDRI) vykazovaly vyšší variabilitu a citlivost, což v některých případech vedlo ke snížení jejich využitelnosti. Vizuální porovnání všech zmíněných indexů pro metodu ISO je na obrázku 26.

Celkově lze konstatovat, že pro dosažení optimálních výsledků je klíčové nejen zvolit vhodnou klasifikační metodu, ale také správně vybrat a aplikovat odpovídající spektrální zvýraznění v závislosti na charakteru klasifikované oblasti a spektrálně-prostorových specifikách dat.



Obrázek 25: Porovnání metod klasifikace – případová studie Vraclav

Zdroj: [vlastní zpracování]



Obrázek 26: Spektrální indexy – ISO – případová studie Vraclav

Zdroj: [vlastní zpracování]

V rámci této analýzy dosáhla nejpřesnějších výsledků metoda DL, která efektivně analyzovala texturu a prostorové vzory přímo z RGB dat. Bezprostředně za ní se umístila metoda SVM, jejíž výkon však zásadně závisel na volbě vhodných spektrálních indexů. Za klíčový se ukázal zejména index MGLI2, jehož pokročilá konstrukce, potlačující vliv stínů a cíleně zvýrazňující zdravou vegetaci, poskytla metodě SVM tak kvalitní vstupní data, že lokálně dosáhla až na perfektní F1-skóre 1,0. Ostatní testované metody vykázaly nižší, či méně stabilní výkonnost, což souviselo s jejich citlivostí na charakter dat a obrazový šum. Tato studie tedy potvrzuje, že zatímco DL exceluje díky schopnosti interně vyhodnocovat analýzu komplexních příznaků, přesnost ostatních metod je přímo úměrná kvalitě zvoleného spektrálního indexu.

5.2 Případová studie: klasifikace spáleného porostu – Albánie

Studijní území druhé případové studie se nachází v severozápadní Albánii, v bezprostředním okolí vesnice Margjonaj, nad přímořským městem Shëngjin (41° 49' 15" N, 19° 34' 19" E). Území je pokryto středomořskou křovinatou vegetací s roztroušenými borovicemi a bylo zasaženo intenzivním přízemním požárem. Výsledkem je mozaika ostře kontrastujících ploch – zcela spálené porosty se střídají s nepoškozenou zelení – což vytvořilo ideální podmínky pro testování klasifikačních metod zaměřených na detekci a kvantifikaci požárových škod.

Lokalita byla vybrána díky své dobré dostupnosti, přehlednému terénu a reprezentativnímu charakteru středomořských oblastí, kde se obdobné události vyskytují pravidelně. Testování klasifikace zde poskytuje relevantní poznatky pro operativní UAV mapování dopadů požáru i pro dlouhodobý monitoring regenerace vegetace.

K pořízení snímků byl využit bezpilotní letoun DJI Phantom 4 Pro. Let byl naplánován v softwaru Pix4Dcapture s vysokým překryvem a aktivovaným režimem terrain awareness, vzhledem k umístění lokality ve svahovitém terénu. Snímkování proběhlo automaticky ve výšce přibližně 85 metrů během dvou po sobě jdoucích dnů – 2. srpna 2024 byla nasnímana východní část lokality, 3. srpna 2024 západní část.

Celkově nasnímaná plocha měla rozlohu 23,477 ha, přičemž zkoumaná oblast byla vymezena polygonem o rozloze 2,148 ha (155,59 × 128,95 m), viz obrázek 27 a 28. Celkem bylo pořízeno 761 snímků a složena ortofotomozaika s prostorovým rozlišením 1,802 cm/px. Snímkování proběhlo za příznivých, neměnných světelných podmínek, bez rušivých meteorologických jevů.

V rámci analýzy byly využity RGB snímky a odvozený index SNDGR, který zvýrazňuje živou zeleň díky vyšší odrazivosti ve zeleném pásmu a zároveň potlačuje spálené nebo degradované plochy s vyšší odrazivostí v červeném kanálu.



QR kód 2: Interaktivní výstup – klasifikace spáleného porostu Albánie

Grafy jsou k dispozici pouze v příloze B a ve webové prezentaci.

VYMEZENÉ ZÁJMOVÉ ÚZEMÍ spálený porost Albánie



0 150 300 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32634

VÝSEČ ZÁJMOVÉHO ÚZEMÍ spálený porost Albánie




0 25 50 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32634

Obrázek 27: Tematický snímek – případová studie Albánie

Zdroj: [vlastní zpracování]



TIFF Area: 23.4769 ha | ROI Area: 2.1482 ha

Obrázek 28: Rozloha CÚ a ZÚ – případová studie Albánie

Zdroj: [vlastní zpracování]

V rámci klasifikace spáleného vegetačního porostu nejvyšší výkonnosti dosáhla metoda Deep Learning, která vykazala průměrné F1-skóre 96,7 %, celkovou přesnost 97,5 % a Kappa koeficient 0,933. Vysokou úspěšnost DL lze odůvodnit schopností hlubokých neuronových sítí komplexně modelovat nejen spektrální, ale zejména prostorové a texturové charakteristiky obrazových dat. Díky tomu dosahovala metoda stabilních a konzistentních výsledků napříč různými scénáři.

Druhou nejlepší metodou se podle průměrného F1 ukázala Maximum Likelihood, která dosáhla F1 92,8 %, celkové přesnosti 89,1 % a Kappa koeficientu 0,744. Solidní výkonnost ML byla dána zejména jejím statistickým přístupem, který je efektivní v homogenních oblastech a méně komplexních situacích. Nižší celková přesnost a Kappa však naznačují omezení této metody v heterogenním nebo méně normálně rozloženém prostředí.

Metoda Support Vector Machine dosáhla velmi podobných výsledků, s průměrným F1 92,7 %, celkovou přesností 94,0 % a Kappa koeficientem 0,854. SVM se ukázala jako spolehlivá metoda zejména díky své schopnosti efektivně oddělovat třídy pomocí hyperrovin. Vysoká přesnost a stabilita výsledků svědčí o vhodnosti této metody pro scény se středně jasnými hranicemi tříd.

Metoda Random Trees dosáhla průměrného F1 88,9 %, celkové přesnosti 92,0 % a Kappa koeficientu 0,812. Výsledky naznačují, že RT byla úspěšná především díky schopnosti modelovat složité a nelineární vztahy mezi třídami. Nižší hodnota F1 oproti předním metodám ale ukazuje na mírné slabiny této metody při klasifikaci oblastí s vyšší prostorovou variabilitou a přechodovými zónami.

Neřízená metoda ISO Cluster dosáhla průměrného F1 88,5 %, celkové přesnosti 89,9 % a Kappa koeficientu 0,759. ISO metoda poskytovala stabilní, byť mírně nižší výsledky, především kvůli své závislosti na textuře a struktuře obrazu namísto spektrálních detailů. Tato vlastnost ji činí vhodnou spíše pro orientační nebo rychlou klasifikaci než pro detailní rozlišení podobných tříd.

Nejnižší výkonnosti dosáhla metoda K-Nearest Neighbors s průměrným F1 81,5 %, celkovou přesností 89,0 % a Kappa koeficientem 0,774. Slabší výsledky této metody byly způsobeny především její vysokou citlivostí na lokální kontext dat. V prostředí s komplexními přechody mezi třídami a fragmentovanou strukturou nebyla schopna efektivně generalizovat, což vedlo ke zvýšenému výskytu chyb. Porovnání výsledků metod je uvedeno níže v tabulkách 6–8 a v příloze B v tabulkách 24–25 a obrázcích 67–71.

Tabulka 6: F1-skóre – případová studie Albánie

F1-skóre klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	SNDGR	průměr
Deep Learning	DL	0,98798	0,94518	0,96658
Support Vector Machine	SVM	0,94103	0,91223	0,92663
Maximum Likelihood	ML	0,96462	0,89133	0,92797
Random Trees	RT	0,93048	0,84668	0,88858
K-Nearest Neighbors	KNN	0,88312	0,70129	0,79221
ISO cluster	ISO	0,70479	0,91530	0,81004
	průměr	0,90200	0,86867	0,88534

Zdroj: [vlastní zpracování]

Tabulka 7: Celková přesnost – případová studie Albánie

Celková přesnost klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	SNDGR	průměr
Deep Learning	DL	0,99000	0,96000	0,97500
Support Vector Machine	SVM	0,95000	0,93000	0,94000
Maximum Likelihood	ML	0,91100	0,87100	0,89100
Random Trees	RT	0,97000	0,87000	0,92000
K-Nearest Neighbors	KNN	0,90000	0,73000	0,81500
ISO cluster	ISO	0,77000	0,94000	0,85500
	průměr	0,91517	0,88350	0,89933

Zdroj: [vlastní zpracování]

Tabulka 8: Kappa index – případová studie Albánie

Kappa koeficient klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	SNDGR	průměr
Deep Learning	DL	0,97596	0,89000	0,93298
Support Vector Machine	SVM	0,88219	0,82500	0,85359
Maximum Likelihood	ML	0,79978	0,68800	0,74389
Random Trees	RT	0,92931	0,69500	0,81216
K-Nearest Neighbors	KNN	0,76668	0,41400	0,59034
ISO cluster	ISO	0,40965	0,83100	0,62033
	průměr	0,79393	0,72383	0,75888

Zdroj: [vlastní zpracování]

Podrobná analýza výsledků klasifikace ukázala, že spektrální zvýraznění významně ovlivnilo přesnost jednotlivých metod, viz obrázky 29–34. Výsledky byly porovnány s použitím dvou vstupních variant dat: základních RGB složek a SNDGR indexu.

Metoda Deep Learning byla testována na obou vstupních variantách a dosáhla vysokého F1-skóre jak u RGB dat (98,8 %), tak u SNDGR indexu (94,5 %). Lokální maximum F1 (98,8 %) na RGB datech je důsledkem schopnosti hlubokých neuronových sítí využívat nejen spektrální informace, ale také složité prostorové a texturové charakteristiky obrazu. Mírný pokles u SNDGR naznačuje, že specifická konstrukce tohoto indexu nebyla pro DL natolik informativní jako samotné RGB složky.

Metoda Maximum Likelihood dosáhla lepších výsledků na RGB datech (F1 96,5 %), zatímco u SNDGR indexu došlo k poklesu (89,1 %). Důvodem poklesu je porušení předpokladu normálního rozložení hodnot v jednotlivých třídách u spektrálního zvýraznění, které je svou konstrukcí citlivější na extrémní hodnoty v červeném kanálu.

Support Vector Machine vykazovala konzistentně vysokou výkonnost jak na RGB datech (94,1 %), tak na SNDGR (91,2 %). Lokální maximum u RGB dat je dáno schopností metody efektivně oddělit jednotlivé třídy pomocí hranic a odlišných textur a odstínů definovaných přímo v RGB prostoru. Nižší, ale stále vysoké hodnoty pro SNDGR ukazují na dobrou adaptabilitu SVM i vůči specifitějším indexům.


Random Trees vykazovala vyšší variabilitu výsledků. Zatímco na RGB datech dosáhla velmi dobrého výsledku (93,0 %), u spektrálního zvýraznění došlo k výraznému poklesu F1 na 84,7 %. Tato variabilita poukazuje na citlivost metody vůči konkrétní formě vstupních dat a větší závislost na specifických vlastnostech jednotlivých kanálů nebo indexů.

Neřízená metoda ISO Cluster dosáhla na SNDGR indexu velmi solidních výsledků (F1 91,5 %), které byly srovnatelné s řízenými metodami, na RGB datech toto skóre bylo 70,5 %. Tato vysoká hodnota F1 u SNDGR naznačuje, že konstrukce tohoto indexu (s důrazem na rozdíl mezi zelenou a červenou složkou) poskytovala této metodě dostatečně jasné a zřetelné spektrální hranice, které byly dobře využitelné pro automatické seskupování pixelů do tříd. Schopnost ISO Cluster efektivně využít SNDGR index k dosažení takto dobrých výsledků podtrhuje jeho potenciál pro rychlou orientační klasifikaci bez nutnosti předchozího tréninku. V porovnání s ostatními metodami se ukazuje, že ISO Cluster profituje ze spektrálních indexů, které výrazněji odlišují jednotlivé spektrální charakteristiky vegetace.

Metoda K-Nearest Neighbors vykazovala největší pokles výkonu při přechodu z RGB (F1 88,3 %) na SNDGR (70,1 %). Důvodem je pravděpodobně zvýšená citlivost této metody na


lokální variabilitu spektrálních hodnot v indexech, což vedlo k častějšímu výskytu chyb a nižší celkové spolehlivosti klasifikace.

Závěrem lze konstatovat, že správně zvolená kombinace klasifikační metody a spektrálního indexu je klíčová pro dosažení optimálních výsledků. Specifický SNDGR index přinesl zajímavé a konzistentní výsledky zejména u metody ISO Cluster, což naznačuje jeho vhodnost pro automatické klasifikační úlohy bez trénovacích dat. Naproti tomu pro metody využívající hlubší prostorovou analýzu (DL, SVM) nebyla přidána hodnota SNDGR indexu nalezena, neboť tyto metody dokázaly velmi efektivně využívat již samotné RGB spektrum.



Obrázek 29: Spektrální indexy – ISO – případová studie Albánie


Zdroj: [vlastní zpracování]




Obrázek 30: Spektrální indexy – KNN – případová studie Albánie

Zdroj: [vlastní zpracování]

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Maximum Likelihood
spálený porost Albánie - RGB data




KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Maximum Likelihood
spálený porost Albánie - NDGR zvýraznění




Obrázek 31: Spektrální indexy – ML – případová studie Albánie

Zdroj: [vlastní zpracování]

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Random Trees
spálený porost Albánie - RGB data




KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Random Trees
spálený porost Albánie - NDGR zvýraznění




Obrázek 32: Spektrální indexy – RT – případová studie Albánie

Zdroj: [vlastní zpracování]

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Support Vector Machine
spálený porost Albánie - RGB data



KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Support Vector Machine
spálený porost Albánie - NDGR zvýraznění



Obrázek 33: Spektrální indexy – SVM – případová studie Albánie

Zdroj: [vlastní zpracování]

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Deep Learning
spálený porost Albánie - RGB data



KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Deep Learning
spálený porost Albánie - NDGR zvýraznění



Obrázek 34: Spektrální indexy – DL – případová studie Albánie

Zdroj: [vlastní zpracování]

V této případové studii dosáhly nejvyšší přesnosti nejpokročilejší metody Deep Learning a Support Vector Machine, které efektivně využily detailní texturní i prostorové informace z RGB snímků. Zlom však nastal při využití vlastního odvozeného indexu SNDGR. Zatímco u vyspělých algoritmů žádné zlepšení nepřinesl, u neřízené metody ISO Cluster vedl k výraznému skoku ve výkonnosti – F1-skóre vzrostlo ze 70,5 % (RGB) na 91,5 % (SNDGR). Příčinou je, že SNDGR díky zvýraznění rozdílu mezi zeleným a červeným kanálem vytvořil

výrazně oddělené spektrální shluky, které mohl jednoduchý ISO Cluster bez trénovacích dat snadno rozpoznat.

Tato studie ukazuje, že přínos spektrálního indexu je silně závislý na použité metodě. Pro metody jako DL a SVM, které samy analyzují komplexní data, neměl index přidanou hodnotu, avšak pro rychlou a automatickou klasifikaci pomocí ISO Cluster se ukázal být klíčovým nástrojem.

5.3 Případová studie: klasifikace poškození obilnin – Loučky

Třetí případová studie je situována na zemědělském pozemku u místní části Loučky, obce Svatý Jiří (49° 58' 53" N, 16° 15' 46" E). Pole s porostem obilnin bylo krátce před leteckou akvizicí snímků zasaženo prudkými letními bouřkami doprovázenými silným větrem a krupobitím, které způsobily nerovnoměrné poléhání porostu, čímž vznikla výrazná mozaika hustých, lehlých a poničených pásů kontrastujících se zbytky intaktního obilí.

Vzhledem ke svému charakteru se lokalita ukázala jako vhodná pro testování UAV klasifikace zaměřené na rychlou identifikaci poškozených oblastí a odhad výnosových ztrát. Rovinatý, ničím nezastíněný terén zároveň umožnil přesné plánování leteckých přeletů a zajištění kvalitních obrazových dat.

K pořízení snímků byl využit bezpilotní letoun DJI Phantom 4 Pro. Let byl naplánován v softwaru Pix4Dcapture s vysokým překryvem 85 % a realizován v automatickém režimu ve výšce přibližně 42 metrů. Snímkování proběhlo dne 17. 7. 2024 za stabilních světelných podmínek, bez výskytu meteorologických vlivů, které by mohly negativně ovlivnit kvalitu dat.

Celkově nasnímaná plocha lokality činila 4,298 ha, přičemž zkoumaná oblast byla vymezena polygonem o rozloze 3,282 ha (232,70 × 155,04 m), viz obrázek 35 a 36. Z pořízených snímků byla složena ortofotomozaika s prostorovým rozlišením 1,041 cm/px.

Pro účely klasifikace byla využita RGB obrazová data a index TGI (Triangular Greenness Index), který byl zvolen pro svou schopnost zvýraznit intenzitu zelené složky a tím i relativní vitalitu vegetace. Výsledky sloužily k testování přesnosti rozlišení mezi zdravými a poškozenými částmi porostu.




QR kód 3: Interaktivní výstup – klasifikace poškození obilnin Loučky

Grafy jsou k dispozici pouze v příloze C a ve webové prezentaci.



Obrázek 35: Tematický snímek – případová studie Loučky

Zdroj: [vlastní zpracování]



Obrázek 36: Rozloha CÚ a ZÚ – případová studie Loučky

Zdroj: [vlastní zpracování]

V případové studii zaměřené na klasifikaci poškozených obilnin nejvyšší výkonnosti dosáhla metoda Deep Learning, která vykázala průměrné F1-skóre 94,4 %, celkovou přesnost 94,5 % a Kappa koeficient 0,889. Tento výsledek potvrzuje že opětovně hluboká neuronová síť dokázala efektivně modelovat texturové vzory, a to i v prostředí s minimálními spektrálními rozdíly mezi třídami. Metoda DL se tak ukázala jako nejrobustnější nástroj pro klasifikaci obrazových dat s minimálním světelným a barevným rozdílem.

Na druhém místě se umístila metoda Random Trees, která dosáhla průměrného F1 77,9 %, celkové přesnosti 78,0 % a Kappa koeficientu 0,562. Tato stromová metoda dobře modelovala nelineární vztahy mezi třídami a dosahovala stabilních výsledků v homogenních oblastech. Nižší přesnost v přechodových zónách však ukazuje na její vyšší citlivost na lokální variabilitu a přítomnost šumu v obraze.

Třetí nejlepší výkonnost vykázala metoda Maximum Likelihood s F1 75,2 %, přesností 75,5 % a Kappa 0,514. Pravděpodobnostní přístup ML se ukázal jako spolehlivý především v případech, kdy rozdělení hodnot v jednotlivých třídách přibližně odpovídalo gaussovskému modelu. V heterogenních oblastech se však její účinnost mírně snižovala.

Čtvrtou příčku zaujala metoda K-Nearest Neighbors s F1 70,0 %, přesností 70,0 % a Kappa koeficientem 0,398. Výsledky ukázaly, že metoda KNN byla silně závislá na lokálním kontextu a rozložení trénovacích vzorků. To vedlo k výrazné chybovosti v mozaikovitých a přechodových oblastech, kde nebyla schopna správně generalizovat.

Páté místo obsadila metoda Support Vector Machine s F1 67,0 %, přesností 67,5 % a Kappa 0,458. Ačkoliv SVM často dosahuje vysoké přesnosti při klasifikaci s jasně vymezenými hranicemi mezi třídami, v tomto případě byla omezena prostorovou variabilitou scény a nízkým kontrastem mezi jednotlivými vegetačními typy.

Nejslabších výsledků zde dosáhla neřízená metoda ISO Cluster, která vykázala průměrné F1 51,9 %, přesnost 59,0 % a Kappa koeficient 0,065. Vzhledem k absenci trénovacích dat ISO metoda seskupovala pixely zejména na základě podobnosti textury a prostorového uspořádání, což vedlo k nepřesnému rozlišení tříd. Z důvodu nižších výsledků tato metoda není vhodná jako orientační nástroj pro rychlou segmentaci snímků v situacích, kdy není možné připravit trénovací vzorky. Porovnání výsledků metod je uvedeno níže v tabulkách 9–11 na obrázku 37 a dále v příloze C v tabulkách 26–27 a obrázcích 72–76.

Tabulka 9: F1-skóre – případová studie Loučky


F1-skóre klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	TGI	průměr
Deep Learning	DL	0,95900	0,92900	0,94400
Support Vector Machine	SVM	0,69000	0,64900	0,66950
Maximum Likelihood	ML	0,80000	0,70300	0,75150
Random Trees	RT	0,84900	0,70900	0,77900
K-Nearest Neighbors	KNN	0,87000	0,52800	0,69900
ISO cluster	ISO	0,62700	0,41100	0,51900
	průměr	0,79917	0,65483	0,72700

Zdroj: [vlastní zpracování]

Tabulka 10: Celková přesnost – případová studie Loučky

Celková přesnost klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	TGI	průměr
Deep Learning	DL	0,96000	0,93000	0,94500
Support Vector Machine	SVM	0,69000	0,66000	0,67500
Maximum Likelihood	ML	0,80000	0,71000	0,75500
Random Trees	RT	0,85000	0,71000	0,78000
K-Nearest Neighbors	KNN	0,87000	0,53000	0,70000
ISO cluster	ISO	0,65000	0,53000	0,59000
	průměr	0,80333	0,67833	0,74083

Zdroj: [vlastní zpracování]



Obrázek 37: Kappa index – případová studie Loučky

Zdroj: [vlastní zpracování]

Tabulka 11: Kappa index – případová studie Loučky

Kappa koeficient klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	TGI	průměr
Deep Learning	DL	0,91800	0,86000	0,88900
Support Vector Machine	SVM	0,38000	0,53600	0,45800
Maximum Likelihood	ML	0,60300	0,42400	0,51350
Random Trees	RT	0,69900	0,42400	0,56150
K-Nearest Neighbors	KNN	0,74000	0,05500	0,39750
ISO cluster	ISO	0,26700	-0,13700	0,06500
	průměr	0,60117	0,36033	0,48075

Zdroj: [vlastní zpracování]

Hlubší analýza výsledků ukázala, že účinnost jednotlivých klasifikačních metod, viz obrázky 38–43, byla výrazně ovlivněna volbou vstupních dat, konkrétně použitím základních RGB složek nebo spektrálního zvýraznění prostřednictvím indexu TGI (Triangular Greenness Index).

Metoda Deep Learning dosahovala vysoké přesnosti jak na RGB datech (F1-skóre 95,9 %), tak při použití TGI (92,9 %), přičemž TGI zvýraznění špatně rozlišovalo stíny od zdravé vegetace. F1-skóre naznačuje, že hluboké neuronové sítě dokázaly extrahovat obtížně rozlišitelné klíčové prostorové a texturové vzory přímo z původních kanálů bez potřeby dodatečného zvýraznění. Díky své schopnosti naučit se reprezentace z dat samotných si DL udržovala vysokou stabilitu napříč různými vstupy.

Metoda Random Trees potvrdila svou citlivost na volbu vstupních dat. Zatímco na RGB datech dosáhla výborného výsledku (F1 84,9 %), při použití TGI došlo k výraznějšímu poklesu (F1 70,9 %). Výsledky ukazují, že RT dobře fungovala při práci se syrovými RGB daty, avšak ztrácela schopnost rozlišovat jemné rozdíly, pokud byly spektrální informace sloučeny do jednoho indexu.

Maximum Likelihood vykazovala stabilní, ale klesající výkonnost při přechodu z RGB (F1 80 %) na TGI (70,3 %). Tento pokles lze přičíst skutečnosti, že TGI jako složený index porušuje předpoklad normality rozdělení hodnot, na němž ML stojí. To se projevovalo zejména u tříd s větší vnitřní heterogenitou, jako jsou poškozené vegetační plochy nebo přechodové zóny.


K-Nearest Neighbors vykazovala velice výrazný rozdíl mezi výsledky na RGB datech a spektrálně zvýrazněném TGI. Na RGB dosáhla F1 87,0 %, naproti tomu při použití TGI došlo k výraznému propadu, kdy F1 kleslo až na 52,8 % a Kappa na velmi nízkou hodnotu 0,055. Tento pokles ukazuje, že metoda je extrémně závislá na lokální variabilitě a hustotě bodů v trénovacím prostoru, která byla v případě TGI deformována do podoby méně informativního

rozložení. Spektrální zvýraznění zde místo zpřesnění vedlo ke snížení výkonnosti a výrazně zhoršené schopnosti generalizace.

Support Vector Machine dosahovala konzistentních výsledků, avšak s mírně lepšími hodnotami u RGB (F1 69 %) než u TGI (64,9 %). Výsledky naznačují, že SVM lépe klasifikovala třídy na základě hranic mezi původními barevnými složkami, zatímco spektrálně zvýrazněný TGI index neposkytl tolik diskriminačních informací pro optimalizaci separační roviny.


Neřízená metoda ISO Cluster dosáhla lepších výsledků na RGB datech, kde vykazala F1-skóre 62,7 %. Při použití indexu TGI došlo k výraznému zhoršení, kdy F1 kleslo na 41,1 % a Kappa index šel dokonce na zápornou hodnotu -0,137, což indikuje shodu horší než náhodný výběr. Tento pokles lze přičíst tomu, že ISO klasifikuje obraz na základě spektrální podobnosti a TGI v tomto případě neposkytl dostatečně odlišitelné hranice mezi třídami. Výsledky potvrzují, že ISO Cluster je citlivý na kvalitu spektrální informace a vhodnost konkrétního indexu.

Z výsledků je patrné, že přínos spektrálního zvýraznění silně závisí na typu klasifikační metody. Zatímco metody jako DL nebo SVM byly schopny poměrně efektivně klasifikovat i s využitím indexu, klasifikátory citlivé na distribuci dat (např. ML, KNN) byly výrazněji ovlivněny typem vstupu. Ačkoliv se na první pohled může TGI jevit jako užitečný nástroj pro vizuální odlišení vegetačních struktur při manuálním vyhodnocení, v případě strojové klasifikace neposkytoval dostatečně stabilní a informativní spektrální základ pro konzistentní a přesnou segmentaci tříd.




Obrázek 38: Spektrální indexy – ISO – případová studie Loučky

Zdroj: [vlastní zpracování]




Obrázek 39: Spektrální indexy – KNN – případová studie Loučky

Zdroj: [vlastní zpracování]




Obrázek 40: Spektrální indexy – ML – případová studie Loučky

Zdroj: [vlastní zpracování]




Obrázek 41: Spektrální indexy – RT – případová studie Loučky

Zdroj: [vlastní zpracování]



Obrázek 42: Spektrální indexy – SVM – případová studie Loučky

Zdroj: [vlastní zpracování]



Obrázek 43: Spektrální indexy – DL – případová studie Loučky

Zdroj: [vlastní zpracování]

V této případové studii zaměřené na poškození obilnin dosáhla znovu nejvyšší přesnost metoda Deep Learning, jež s přehledem dominovala díky schopnosti analyzovat jemné texturové vzory přímo z RGB snímků. Nejvýrazněji se však projevil negativní vliv indexu TGI. Oproti předchozím analýzám zde spektrální zvýraznění většinu metod neobohatilo, naopak významně snížilo jejich přesnost. Největší propad vykázaly K Nearest Neighbors a neřízený ISO Cluster. U ISO Clusteru TGI dokonce snížilo výsledek pod úroveň náhody ($\kappa -0,137$). V prostředí s nízkým kontrastem překvapivě selhal i Support Vector Machine, jenž patřil k nejslabším. Studie tak potvrzuje, že spektrální index není univerzálním řešením. Pokud poškození charakterizují spíše textury než barvy, může index potlačit klíčové informace skryté v RGB kanálech a paradoxně snížit celkovou přesnost klasifikace.

5.4 Případová studie: klasifikace vegetačních složek – Hrádek

Čtvrtá případová studie se nachází na obilném poli u osady Hrádek (49° 56' 42" N, 16° 19' 08" E) v katastru Dolní Sloupnice. Krátce před snímkováním zasáhla lokalitu bouře s krupobitím a silným větrem, které způsobily nepravidelné pásy vybitých klasů a poléhajícího obilí, zatímco zbylé části pole zůstaly nepoškozené. V mezerách mezi řádky se navíc rozvinuly plevelné shluky, takže porost vykazoval tři odlišné povrchové třídy – zdravou plodinu, poškozené obilí a plevel.

Cílem této studie bylo ověřit možnosti klasifikace tří vegetačních složek v rámci kulturního porostu, a to výhradně pomocí RGB obrazových dat. Oproti předchozím případovým studiím tak nebyly klasifikovány pouze dvě třídy (poškozená a nepoškozená úroda), ale i třetí třída – plevel. Tato úprava umožnila testovat přesnější segmentaci vegetace a sledovat, do jaké míry lze pomocí základních spektrálních informací odlišit doprovodnou flóru.

Snímky byly pořízeny pomocí bezpilotního letounu DJI Phantom 4 Pro. Let byl naplánován v softwaru Pix4Dcapture s vysokým překryvem a proveden automaticky ve výšce přibližně 55 metrů. Snímkování proběhlo dne 16. 7. 2024 za příznivých světelných podmínek, bez negativních meteorologických jevů.


Celkově nasnímaná plocha lokality činila 18,481 ha, zobrazená na obrázku 44, přičemž zájmové území určené k podrobnější analýze mělo rozlohu 1,82 ha. Toto území bylo vymezeno polygonem o rozměrech 215,60 × 103,23 metrů, viz obrázek 45. Bylo pořízeno celkem 350 snímků, z nichž byla složena ortofotomozaika s prostorovým rozlišením 1,53 cm/px.

Výsledky klasifikace byly využity pro kvantitativní vyhodnocení prostorového rozložení tří sledovaných tříd a posouzení schopnosti RGB dat odlišit poškozené porosty od plevele a zdravé vegetace.




QR kód 4: Interaktivní výstup – klasifikace vegetačních složek Hrádek

Grafy jsou k dispozici pouze v příloze D a ve webové prezentaci.



Obrázek 44: Tematický snímek – případová studie Hrádek

Zdroj: [vlastní zpracování]



Obrázek 45: Rozloha CÚ a ZÚ – případová studie Hrádek

Zdroj: [vlastní zpracování]

V rámci případové studie zaměřené na rozlišení tří tříd na obilném poli – nepoškozenou vegetací, poškozenou vegetací a plevelem.

Nejvyšší výkonnosti dosáhla metoda Deep Learning, která vykázala průměrné F1-skóre 94,4 %, celkovou přesnost 96,5 % a Kappa koeficient 0,890. Výsledky potvrzují schopnost hlubokých neuronových sítí zachytit nejen spektrální charakteristiky vegetace, ale také prostorové souvislosti a jemné texturové rozdíly mezi třídami. Díky těmto vlastnostem byla metoda DL schopna stabilně klasifikovat i přechodové zóny mezi zdravým porostem a poškozenou vegetací, avšak nebyla schopna korektně rozlišit plevel od nezasažené úrody, neboť docházelo k prolnutí klasů a plevelu.

Druhé nejvyšší přesnosti dosáhla metoda Support Vector Machine, která vykázala F1 79,3 %, celkovou přesnost 83,5 % a Kappa koeficient 0,560. Metoda prokázala schopnost efektivně separovat třídy pomocí optimalizovaných rozhodovacích hranic, přičemž si udržovala dobrou stabilitu i v oblastech s vyšší prostorovou nebo spektrální variabilitou. Nižší hodnota Kappa souvisí s častějším výskytem chyb právě v přechodových pásmech, zejména mezi jemnými hranicemi mezi zasaženou a nezasaženou plochou. Výrazným přínosem SVM byla její schopnost spolehlivě detekovat třídu plevelu, kterou jiné metody buď nadhodnocovaly, nebo naopak zcela potlačily.

Třetí nejlepší výsledky vykázala metoda Maximum Likelihood, s průměrným F1 79,0 %, přesností 87,7 % a Kappa koeficientem 0,648. Statistický přístup založený na předpokladu normálního rozdělení spektrálních hodnot se ukázal jako efektivní zejména v homogenních oblastech, které tvořily rozsáhlejší plochy jednotných tříd. Naopak slabší výkon byl patrný při rozlišování přechodových zón mezi nezasaženou a poškozenou vegetací, kde metoda nedosahovala úrovně hlubokého učení. Značná část území byla navíc chybně klasifikována jako plevel, což naznačuje tendenci ML k nadhodnocení této třídy a její expanzi do okolních oblastí.

Čtvrtou příčku obsadila metoda Random Trees s F1 76,1 %, přesností 83,5 % a Kappa indexem 0,505. Ensemble přístup založený na rozhodovacích stromech prokázal schopnost rozlišovat třídy i v případě nelineárních vztahů mezi spektrálními příznaky. Nižší hodnota Kappa však naznačuje problémy s konzistencí klasifikace zejména v přechodových zónách a při rozlišování méně zastoupených tříd. To bylo patrné například u plevelu, který byl mírně nadhodnocen a v některých případech zasahoval do oblastí poškozené vegetace.

Na pátém místě se umístila metoda K-Nearest Neighbors, která dosáhla F1 75,8 %, přesnosti 78,0 % a Kappa koeficientu 0,514. Ačkoliv KNN je metoda s jednoduchým principem, její výkonnost byla silně ovlivněna lokálním rozložením dat a hustotou tříd v prostoru. Výsledky naznačují, že v mozaikovitém nebo prostorově fragmentovaném prostředí klasifikace často

selhávala v přechodových oblastech, kde lokální podobnost nebyla dostatečně výrazná, což vedlo k výraznému nadhodnocení plochy poškozené úrody. Zajímavé však je, že stejně jako SVM dokázala metoda KNN velmi přesně identifikovat třídu plevelu, a to i v případě jejího nepravidelného výskytu a minimálních spektrálních i texturových rozdílů vůči okolním třídám.

Nejslabších výsledků dosáhla neřízená metoda ISO Cluster, která vykazovala F1 42,9 %, přesnost 83,5 % a Kappa koeficient 0,244. Ačkoliv metoda dosáhla poměrně vysoké celkové přesnosti, nízké hodnoty F1-skóre a Kappa koeficientu odhalují výraznou nerovnováhu ve schopnosti rozlišit jednotlivé třídy. Třída zasažené úrody byla systematicky podhodnocována a kategorie plevel byla zcela ignorována, což ukazuje na nedostatečné rozlišení méně výrazných tříd. Na druhou stranu metoda vykazovala relativně přesné určení hlavních hranic mezi zdravými a nezdravými oblastmi, a v přechodových zónách nevznikaly výrazné chyby.

Výsledky tak naznačují, že ISO klasifikace vycházela převážně z dominantních spektrálních a texturových vzorů, což z ní činí spíše nástroj pro orientační a předběžnou segmentaci než pro podrobnou analýzu vegetace. Porovnání výsledků metod je uvedeno níže v tabulkách 12–14 a dále v příloze D v tabulkách 28–29 a obrázcích 77–81.

Tabulka 12: F1-skóre – případová studie Hrádek

F1-skóre klasifikace		
metoda	zkratka	RGB
Deep Learning - UNET	DL	0,94412
Support Vector Machine	SVM	0,79252
Maximum Likelihood	ML	0,79015
Random Trees	RT	0,76110
K-Nearest Neighbors	KNN	0,75824
ISO cluster	ISO	0,42901
	<i>průměr</i>	0,74586

Zdroj: [vlastní zpracování]

Tabulka 13: Celková přesnost – případová studie Hrádek

Celková přesnost klasifikace		
metoda	zkratka	RGB
Deep Learning - UNET	DL	0,96500
Support Vector Machine	SVM	0,83500
Maximum Likelihood	ML	0,87700
Random Trees	RT	0,83500
K-Nearest Neighbors	KNN	0,78000
ISO cluster	ISO	0,83500
	<i>průměr</i>	0,85450

Zdroj: [vlastní zpracování]

Tabulka 14: Kappa index – případová studie Hrádek

Kappa koeficient klasifikace		
metoda	zkratka	RGB
Deep Learning - UNET	DL	0,89000
Support Vector Machine	SVM	0,56000
Maximum Likelihood	ML	0,64800
Random Trees	RT	0,50500
K-Nearest Neighbors	KNN	0,51400
ISO cluster	ISO	0,24400
	<i>průměr</i>	0,56017

Zdroj: [vlastní zpracování]

Výsledky případové studie potvrdily, že přesnost klasifikace jednotlivých metod byla výrazně ovlivněna schopností algoritmu pracovat s jemnými spektrálními a texturálními rozdíly, viz obrázek 46. Nejvyšší celkové výkonnosti dosáhla metoda Deep Learning, která dokázala spolehlivě rozlišit především poškozenou vegetaci a zdravý porost. Její výkon však byl o něco nižší u třídy plevelu, což se odrazilo na vyšším počtu záměn.


Support Vector Machine si udržela velmi dobrý a zároveň nejvyrovnanější výkon právě u třídy plevelu. Její schopnost oddělovat třídy se ukázala jako výhodná v případě, kdy bylo nutné rozlišit spektrálně podobné třídy. Díky tomu SVM klasifikovala plevel s nejvyšší přesností v rámci všech testovaných přístupů.

Také K-Nearest Neighbors podala překvapivě dobré výsledky při detekci plevelu. Přestože v celkových metrikách zaostávala, v klasifikaci této třídy překonala i robustnější algoritmy. Lokální podobnostní přístup, umožnil v tomto případě správné rozpoznání plevelných segmentů, byť s nižší generalizací napříč třídami.

Metoda Random Trees vykazovala mírně nižší přesnost při klasifikaci plevelu, častěji došlo k záměnám s poškozenou vegetací. Navzdory tomu si zachovala solidní výkon u ostatních tříd, a to především díky své schopnosti modelovat nelineární vztahy mezi proměnnými.

Maximum Likelihood dosáhla velmi dobrých výsledků u tříd zdravé a poškozené vegetace, avšak plevel byla nejproblematictější třídou. Metoda měla tendenci přisuzovat spektrálně nejednoznačné segmenty poškozeným oblastem, čímž docházelo ke ztrátě přesnosti v menšinové třídě.

Naopak ISO Cluster, jako neřízená metoda bez využití trénovacích vzorků, nedokázala plevel vůbec správně detekovat, což potvrzuje omezenou schopnost neřízených algoritmů při rozlišování méně zastoupených a spektrálně nevyhraněných kategorií.



Obrázek 46: Porovnání metod klasifikace – případová studie Hrádek

Zdroj: [vlastní zpracování]

Tato případová studie se nejvíce blížila reálné praxi, protože jako jediná ze studií poškození úrody řešila komplexnější úkol: rozlišení tří vegetačních tříd (zdravá plodina, poškozená plodina, plevel) pouze pomocí RGB dat. Variabilní textura a barva plevelu ztěžovaly identifikaci. Poškozená vegetace vykazovala nižší jas, zatímco plevel se lišil saturací a chromatičností. Přesnost klasifikace ovlivnily jemné spektrální rozdíly a nejednoznačné textury v heterogenním prostředí.

Nejvyšší celkové přesnosti dosáhl Deep Learning, jenž spolehlivě oddělil poškozené od zdravých částí, avšak plevel rozpoznal pouze omezeně. Překvapivě si nejlépe vedly Support Vector Machine a K-Nearest Neighbors, které spolehlivě detekovaly plevel, neboť ostatní metody jej nadhodnocovaly (ML, RT) či zcela ignorovaly (ISO Cluster).

Výsledky potvrzují, že žádná metoda není univerzálně nejlepší. Zatímco DL exceluje v celkové segmentaci, pro obtížné úkoly, jako je detekce plevelu, mohou být vhodnější algoritmy, např. SVM. Výsledky také ukazují, že přesnost klasifikace závisela na schopnosti algoritmů zpracovat silně heterogenní vegetační pokryv, což podtrhuje limity RGB dat a potenciál multispektrálních dat pro lepší výsledky.

5.5 Případová studie: klasifikace zaplavené plochy – Čestice

Lokalita páté případové studie se nachází na pravém břehu řeky Divoká Orlice u osady Častolovické Horky (50° 07' 21" N, 16° 08' 21" E) v katastru obce Čestice. Dva dny před pořízením snímků oblast zasáhly prudké přívalové deště, v jejichž důsledku došlo k rozlivu řeky a později po ústupu záplav ke vzniku mozaiky mělkých kaluží, nasáklých pásů půdy a částečně již vyschlých vyvýšenin. Let byl proveden kolem slunného poledne, kdy odlesky od hladiny mohly ztížit interpretaci obrazu, což vytvořilo vhodné podmínky pro ověření schopnosti UAV klasifikace identifikovat zaplavené a nezaplavené plochy na základě obrazových dat. Cílem bylo posoudit využitelnost spektrálních dat pro operativní detekci povodňových jevů, a to i v náročných světelných podmínkách.

Snímky byly pořízeny bezpilotním letounem DJI Phantom 4 Pro. Let byl naplánován v softwaru Pix4Dcapture s vysokým překryvem a realizován automaticky ve výšce přibližně 65 metrů. Snímkování proběhlo dne 18. 9. 2024 za poledních hodin, kdy světelné podmínky byly částečně komplikovány výraznými odlesky od vodních ploch.

Celkově nasnímaná plocha lokality činila 12,211 ha, viz obrázek 47, přičemž zájmové území vybrané k podrobnější analýze mělo rozlohu 9,986 ha. Toto území bylo vymezeno polygonem o rozměrech 517,20 × 339,68 metrů, viz obrázek 48. Pořízeno bylo celkem 133 snímků a složena ortofotomozaika s prostorovým rozlišením 1,800 cm/px.

Pro klasifikaci byly využity nativní RGB složky a spektrální index GBRWI, který napomáhá spolehlivému zvýraznění vodních ploch i za náročných světelných podmínek. Výsledky sloužily k ověření přesnosti detekování zbytkové vody v krajině a pro posouzení relevance použití RGB spektrálních dat při UAV mapování povodňových škod.




QR kód 5: Interaktivní výstup – klasifikace zaplavené plochy Čestice

Grafy jsou k dispozici pouze v příloze E a ve webové prezentaci.



Obrázek 47: Tematický snímek – případová studie Čestice

Zdroj: [vlastní zpracování]



Obrázek 48: Rozloha CÚ a ZÚ – případová studie Čestice

Zdroj: [vlastní zpracování]

Nejvyšší průměrné přesnosti dosáhla metoda Support Vector Machine, která vykázala F1-skóre ve výši 89,9 %, celkovou přesnost 93,5 % a Kappa koeficient 0,799. Díky schopnosti efektivně optimalizovat rozhodovací hranice mezi třídami a adaptovat se na různé spektrální charakteristiky dat, byla metoda úspěšná jak u základních RGB snímků, tak i při použití spektrálního zvýraznění. SVM prokázala vysokou stabilitu napříč vstupními daty a ukázala se jako mimořádně vhodná pro úlohy, kde jsou spektrální hranice tříd ostře definovány.

Druhé místo obsadila metoda Deep Learning s průměrným F1 86,8 %, přesností 93,5 % a Kappa koeficientem 0,738. Přestože DL mírně zaostala za SVM z hlediska F1 a Kappa, její vysoká přesnost potvrzuje schopnost hluboké neuronové sítě modelovat složité vztahy v datech, včetně prostorových a texturových vzorů.

Třetí nejlepší výsledky vykázala metoda Maximum Likelihood, s průměrným F1 81,0 %, přesností 87,0 % a Kappa koeficientem 0,626. Statistický přístup založený na předpokladu normálního rozdělení spektrálních hodnot byl zvláště účinný v homogenních oblastech, které zastupovaly poměrně velké plochy jednotných tříd. Přestože metoda nedosahovala úrovně hlubokého učení v rozlišení tříd mezi nezaplavenou plochou a plochou se zbytkovými kalužemi, její výsledky byly stabilní napříč oběma datovými variantami.

Čtvrtou příčku obsadila metoda Random Trees s F1 79,7 %, přesností 85,6 % a Kappa indexem 0,605. Ensemble přístup založený na rozhodovacích stromech prokázal schopnost rozlišovat třídy i v případě nelineárních vztahů, avšak mírně nižší hodnota Kappa naznačuje určité problémy s konzistencí výsledků v přechodových zónách a u tříd s menším zastoupením.

Na pátém místě se umístila neřízená metoda ISO Cluster s F1 76,9 %, celkovou přesností 86,0 % a Kappa koeficientem 0,540. Přestože metoda pracuje bez vstupních trénovacích dat, překvapila svou výkonností, která v některých případech předčila i klasifikátory s učením. Vysoká hodnota přesnosti byla však částečně dosažena na úkor rovnoměrnosti klasifikace, o čemž svědčí nižší hodnota F1 i Kappa. ISO klasifikace preferovala dominantní spektrální vzory a méně přesně klasifikovala okrajové nebo minoritní třídy.

Nejslabších výsledků dosáhla metoda K-Nearest Neighbors, která vykázala průměrné F1 70,5 %, celkovou přesnost 77,0 % a Kappa koeficient 0,428. Přestože se jedná o jednoduchou a snadno interpretovatelnou metodu, její výkonnost byla výrazně ovlivněna lokální distribucí dat a hustotou tříd v prostoru. V prostředí s mozaikovitou strukturou nebo vyšší fragmentací území měla metoda tendenci selhávat v přechodových zónách, kde nedokázala spolehlivě odlišit třídy s jemnými spektrálními rozdíly. Typickým problémem bylo nadhodnocení plochy označené jako zaplavená, zejména v oblastech s podobnou barevnou odezvou nebo strukturou.

Porovnání výsledků klasifikačních metod je uvedeno níže v tabulkách 15–17 a dále v příloze E v tabulkách 30–31 a obrázcích 82–86.

Tabulka 15: F1-skóre – případová studie Čestice

F1-skóre klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	GBRWI	průměr
Deep Learning	DL	0,92900	0,80700	0,86800
Support Vector Machine	SVM	0,89630	0,90250	0,89940
Maximum Likelihood	ML	0,80740	0,81360	0,81050
Random Trees	RT	0,80810	0,78490	0,79650
K-Nearest Neighbors	KNN	0,73780	0,67270	0,70525
ISO cluster	ISO	0,74590	0,79240	0,76915
	průměr	0,82075	0,79552	0,80813

Zdroj: [vlastní zpracování]

Tabulka 16: Celková přesnost – případová studie Čestice

Celková přesnost klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	GBRWI	průměr
Deep Learning	DL	0,96000	0,91000	0,93500
Support Vector Machine	SVM	0,93000	0,94000	0,93500
Maximum Likelihood	ML	0,87000	0,87000	0,87000
Random Trees	RT	0,86140	0,85000	0,85570
K-Nearest Neighbors	KNN	0,82000	0,72000	0,77000
ISO cluster	ISO	0,82000	0,90000	0,86000
	průměr	0,87690	0,86500	0,87095

Zdroj: [vlastní zpracování]

Tabulka 17: Kappa index – případová studie Čestice

Kappa koeficient klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	GBRWI	průměr
Deep Learning	DL	0,85900	0,61700	0,73800
Support Vector Machine	SVM	0,79339	0,80519	0,79929
Maximum Likelihood	ML	0,61944	0,63152	0,62548
Random Trees	RT	0,63425	0,57483	0,60454
K-Nearest Neighbors	KNN	0,48037	0,37472	0,42755
ISO cluster	ISO	0,49438	0,58609	0,54024
	průměr	0,64680	0,59823	0,62252

Zdroj: [vlastní zpracování]

Přesnost klasifikace byla výrazně ovlivněna použitým typem vstupních dat, viz obrázky 49–54. Porovnání základního RGB spektra a jeho spektrálně zvýrazněné varianty pomocí indexu GBRWI ukázalo, že reakce jednotlivých metod na spektrální transformaci byla značně rozdílná.

Metoda Support Vector Machine dosáhla velmi konzistentních výsledků, a to jak při klasifikaci RGB dat (F1-skóre 89,6 %, Kappa 0,793), tak při použití GBRWI (F1 90,3 %, Kappa 0,805). Spektrální zvýraznění tak v tomto případě přispělo ke zlepšení shody s referenčními daty i při zachování vysoké klasifikační úspěšnosti. To potvrzuje schopnost SVM efektivně využívat i transformované spektrální informace a adaptovat se na nové hranice mezi třídami.

Deep Learning dosáhl v RGB variantě nejvyššího F1 (92,9 %) a Kappa koeficientu (0,859), ale při použití GBRWI došlo k citelnému poklesu (F1 80,7 %, Kappa 0,617). To naznačuje, že hluboké neuronové sítě jsou silně optimalizované na texturové a prostorové charakteristiky přítomné ve vizuálních datech, a index GBRWI jim mohl narušit spektrální kontinuitu, čímž omezil schopnost modelu efektivně rozlišovat jemné vzory vzniklé snížením rozlišovacích dat z 8bitových hodnot na interval $\langle -1; 1 \rangle$. I přesto však DL zůstal metodou s velmi vysokou celkovou přesností.


Maximum Likelihood vykazovala jen velmi malé rozdíly mezi RGB (F1 80,7 %, Kappa 0,619) a GBRWI (F1 81,4 %, Kappa 0,632), což potvrzuje stabilitu metody v prostředí, kde se spektrální rozdíly mezi třídami výrazněji nemění. Mírné zlepšení s použitím indexu naznačuje, že ML je schopna profitovat i z jednoduchých transformací dat bez zásadního narušení vnitřní struktury tříd.

Metoda Random Trees reagovala na spektrální zvýraznění mírným poklesem – v RGB dosáhla F1-skóre 80,8 % a Kappa 0,634, zatímco u GBRWI klesla na F1 78,5 % a Kappa 0,575. Tento rozdíl poukazuje na vyšší citlivost RT vůči změnám v distribuci dat, které mohou ovlivnit výstup jednotlivých stromů. Přesto metoda zůstala relativně robustní a výkonná i při použití zvýraznění.

K-Nearest Neighbors byla nejcitlivější na použití GBRWI. Zatímco v RGB dosáhla slušného výsledku (F1 73,8 %, Kappa 0,480), při použití indexu došlo k dramatickému zhoršení (F1 67,3 %, Kappa 0,375). To ukazuje, že metoda je extrémně závislá na zachování lokálních podobností mezi pixely. V RGB klasifikaci KNN nadhodnocovala zaplavené oblasti, ale její chování bylo ještě předvídatelné. V případě GBRWI se začala chovat téměř náhodně, o čemž svědčí i velmi nízký Kappa koeficient, což naznačuje slabou shodu s reálnými třídami. Nízká hodnota Kappa je však pro metodu KNN typická i u jiných spektrálních vstupů v této případové studii, což poukazuje na obecné omezení této metody při složitějších scénářích.

Neřízená metoda ISO Cluster naopak při použití indexu GBRWI zlepšila své výsledky – F1-skóre se zvýšilo z 74,6 % (RGB) na 79,2 % (GBRWI) a Kappa z 0,494 na 0,586. To potvrzuje, že spektrální zvýraznění umožnilo lepší oddělení přirozených shluků v datech, na kterých ISO metoda závisí. Využitím GBRWI došlo k výraznému zpřesnění přechodových zón, přičemž byla výrazně omezena přítomnost falešně pozitivních (false positive) zaplavených ploch, které byly typické pro klasifikaci bez zvýraznění. Výstup ISO klasifikace tak v některých částech připomínal čistotou a koherentností výstup metody DL. Přesto zůstávalo patrné, že ISO nedokázala přesně detekovat a vymezit hranice skutečně zaplavených oblastí, což vedlo k méně detailnímu a ostře vymezenému výsledku v porovnání s řízenými metodami.

Celkově lze konstatovat, že vliv spektrálního zvýraznění je silně závislý na použité metodě klasifikace. Zatímco některé algoritmy (např. SVM nebo ISO) byly schopné profitovat z informací obsažených v GBRWI indexu, jiné (zejména DL a KNN) zaznamenaly propad výkonu. Ačkoliv se index GBRWI ukazuje jako přínosný pro vizuální analýzu a manuální interpretaci zaplavených oblastí, v případě automatické klasifikace může být jeho přínos značně omezený nebo dokonce kontraproduktivní.




Obrázek 49: Spektrální indexy – ISO – případová studie Čestice

Zdroj: [vlastní zpracování]

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - K-Nearest Neighbor
pole po povodni Čestice - RGB data

■ zaplavená plocha
■ nezaplavená plocha




0 100 200 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - K-Nearest Neighbor
pole po povodni Čestice - GBRWI zvýraznění

■ zaplavená plocha
■ nezaplavená plocha



0 100 200 m


Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

Obrázek 50: Spektrální indexy – KNN – případová studie Čestice

Zdroj: [vlastní zpracování]

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Maximum Likelihood
pole po povodni Čestice - RGB data

■ zaplavená plocha
■ nezaplavená plocha




0 100 200 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Maximum Likelihood
pole po povodni Čestice - GBRWI zvýraznění

■ zaplavená plocha
■ nezaplavená plocha




0 100 200 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633


Obrázek 51: Spektrální indexy – ML – případová studie Čestice

Zdroj: [vlastní zpracování]




Obrázek 52: Spektrální indexy – RT – případová studie Čestice

Zdroj: [vlastní zpracování]



Obrázek 53: Spektrální indexy – SVM – případová studie Čestice

Zdroj: [vlastní zpracování]



Obrázek 54: Spektrální indexy – DL – případová studie Čestice

Zdroj: [vlastní zpracování]

V této studii zaměřené na detekci zaplavených ploch se jako nejúspěšnější metoda prokázala metoda Support Vector Machine, která si zachovala vysokou a konzistentní přesnost pro RGB datech i při využití specializovaného indexu GBRWI. Naproti tomu metoda Deep Learning, ačkoli stále velmi přesná, zaznamenala s tímto indexem znatelný pokles výkonu. Největší přínos indexu GBRWI se však projevil u neřízené metody ISO Cluster. Spektrální zvýraznění přineslo výrazné zlepšení – F1-skóre stoupl ze 74,6 % na 79,2 %. Index zvýraznil oddělení přirozených shluků v datech, snížil chybné klasifikace a v některých oblastech dosáhl čistoty srovnatelné s DL.

To potvrzuje potenciál této kombinace pro rychlou přehledovou analýzu. Studie naznačuje, že zatímco některé metody (SVM, ISO) z indexu GBRWI profitují, pro jiné (DL, KNN) je jeho vliv spíše kontraproduktivní.

5.6 Případová studie: porovnání klasifikačních modelů – Čestice (II)

Šestá případová studie využívá stejný povodní zasažený pozemek u osady Častolovické Horky (50° 07' 21" N, 16° 08' 21" E) popsany v předchozí studii. Lokalita vykazovala kombinaci zaplavených, podmáčených i vyschlých ploch, které vytvořily ideální tréninkové i validační prostředí pro testování různých klasifikačních metod. V této fázi bylo cílem systematicky porovnat efektivitu jednotlivých přístupů pro detekci zbytkové vody v krajině.

Snímkování proběhlo 18. 9. 2024 z vyšší letové hladiny – 75 metrů pomocí bezpilotního letounu DJI Phantom 4 Pro, čímž se mírně zvýšilo prostorové pokrytí, ale současně došlo ke snížení rozlišení na 2,000 cm/px. Let byl naplánován v softwaru Pix4Dcapture, proveden automaticky za stabilních světelných podmínek a bez meteorologických rušivých vlivů, v poledních hodinách při přímém slunečním svitu.

Celkově nasnímaná plocha lokality činila 11,847 ha, viz obrázek 55, přičemž analyzované území bylo vymezeno polygonem o rozloze 0,973 ha (97,87 × 108,07 m), viz obrázek 56. Bylo pořízeno 125 snímků, z nichž byla složena ortofotomozaika s uvedeným rozlišením.

Pro klasifikaci byly využity pouze RGB složky. Z tradičních metod byl testován RT se dvěma různými úrovněmi hloubky, dále SVM, ISO Cluster, ML a KNN. Hlavní část analýzy se však zaměřila na hluboké neuronové sítě. Testovány byly následující architektury:


- U-Net s páteřními modely ResNet50 a VGG16,
- PSPNet (ResNet50) a jeho rozšířená varianta s aktivovanou technologií PointRend,
- DeepLabV3 s ResNet50 i ve verzi s PointRend.

Primárním cílem bylo zjistit, jak volba klasifikační architektury a nastavení parametrů ovlivňuje přesnost detekování stojaté vody a vlhkých ploch. Závěry této analýzy přispěly k návrhu doporučení pro operativní UAV mapování povodňových jevů v obdobných homogenních terénech.




QR kód 6: Interaktivní výstup – porovnání klasifikačních modelů Čestice

Grafy jsou k dispozici pouze v příloze F a ve webové prezentaci.



Obrázek 55: Tematický snímek – případová studie Čestice II

Zdroj: [vlastní zpracování]



Obrázek 56: Rozloha CÚ a ZÚ – případová studie Čestice II

Zdroj: [vlastní zpracování]

V této případové studii bylo porovnáno celkem dvanáct klasifikačních metod zahrnujících jak pokročilé modely hlubokého učení, tak tradiční algoritmy. Všechny modely byly aplikovány na RGB ortofotosnímku bez použití spektrálních indexů.

Nejvyšší výkonnosti dosáhla metoda Deep Learning – PSPNet s modulem PointRend, která vykázala F1 98,3 %, celkovou přesnost 99,3 % a Kappa koeficient 0,966. Modul PointRend přispěl ke zvýšení ostrosti klasifikace na hranách objektů, čímž došlo ke zlepšení přesnosti v přechodových oblastech. Tato kombinace se ukázala jako nejvhodnější pro detailní rozlišení tříd v prostoru.

Těsně druhé místo obsadil Deep Learning – U-Net (ResNet50) s F1 98,2 %, celkovou přesností 99,3 % a Kappa 0,964. Model prokázal vysokou robustnost a konzistenci napříč celou scénou. Díky použití hlubokých reziduálních bloků dokázal spolehlivě modelovat i jemné texturové rozdíly.

Třetí nejlepší výsledek zaznamenala metoda DeepLabV3 – PointRend, s F1 92,7 %, celkovou přesností 98,2 % a Kappa koeficientem 0,898. Díky integraci modulu PointRend byla metoda schopna zpřesnit segmentaci tříd s jemnými okraji a zvýšit celkovou shodu s referenčními daty.

Na čtvrtém místě skončila metoda DeepLabV3, která dosáhla F1 91,6 %, přesnosti 97,3 % a Kappa 0,832. Výsledky byly stabilní a svědčí o vhodnosti této architektury i bez dodatečného zpřesňujícího modulu. Model byl úspěšný zejména v homogenních oblastech a při klasifikaci hlavních tříd.

Pátou příčku obsadil model PSPNet (bez PointRend), který dosáhl F1 88,7 %, celkové přesnosti 95,3 % a Kappa 0,773. Přestože nedisponoval modulem pro zpřesnění hran, byl stále schopen kvalitně klasifikovat většinu tříd, zejména v jádrových oblastech bez výrazného přechodu.

Šestým nejlepším modelem byl Deep Learning – U-Net (VGG16) s F1 87,4 %, celkovou přesností 96,1 % a Kappa 0,749. Ačkoliv měl mělčí architekturu než ResNet50, model si vedl dobře v dominantních třídách, ale vykazoval slabší výsledky v prostorově složitějších oblastech.

Support Vector Machine dosáhla F1 86,1 %, celkové přesnosti 90,0 % a Kappa koeficientu 0,627. Jednalo se o nejlepší konvenční klasifikační algoritmus nezaložený na hlubokých neuronových sítích. Klasifikátor se osvědčil zejména v dobře ohraničených oblastech, kde dokázal efektivně oddělit jednotlivé třídy pomocí optimalizované hyperroviny. Přesto se v přechodových zónách mezi třídami objevovala vyšší míra nejistoty, což mírně snižovalo celkovou robustnost modelu. Výsledky však potvrzují, že i tradiční algoritmy mohou při správné optimalizaci nabídnout konkurenceschopný výkon vůči pokročilejším modelům hlubokého učení.

Metoda Random Trees s výchozí hloubkou (depth 30) dosáhla F1-skóre 84,1 %, celkové přesnosti 87,3 % a Kappa koeficientu 0,507. Tento ensemble přístup založený na souboru rozhodovacích stromů efektivně modeloval i nelineární vztahy mezi třídami. Výsledky ukazují, že metoda byla schopna rozlišovat dominantní struktury v datech, avšak její výkon kolísal v oblastech s vysokou variabilitou, zejména na rozhraní mezi třídami.

Maximum Likelihood dosáhla F1 81,1 %, přesnosti 91,3 % a Kappa koeficientu 0,684. Statistický přístup této metody poskytl konzistentní výstup v oblastech s normálně rozloženými daty, ale vykazoval slabiny při klasifikaci tříd s výraznější vnitřní variabilitou.

Verze Random Trees s vyšší maximální hloubkou 100 (RT – depth 100) vykázala nižší F1 75,2 %, celkovou přesnost 89,5 % a Kappa 0,275. Zvýšení hloubky vedlo k vyšší citlivosti na detaily v trénovacích datech, což zřejmě způsobilo přeučení a snížilo schopnost modelu generalizovat. Výsledkem byla nižší stabilita klasifikace a zhoršené rozpoznávání jemnějších vzorů ve scéně.

Neřízená metoda ISO Cluster vykázala F1 72,0 %, přesnost 92,7 % a Kappa 0,702. Přestože nevyužívá žádné trénovací vzorky, byla schopna rozpoznat základní spektrální struktury v obraze.

Nejslabší výsledky zaznamenala metoda K-Nearest Neighbors, která dosáhla F1 63,4 %, přesnosti 89,3 % a Kappa 0,440. Silná závislost na lokálním rozložení dat způsobila časté chyby v oblastech s přechody mezi třídami. Výsledky ukazují, že KNN je méně vhodná pro klasifikaci vegetačních scén s prostorovou složitostí.

Celkově lze konstatovat, že hluboké neuronové sítě s pokročilými architekturami výrazně překonaly klasické algoritmy. Nejlepších výsledků bylo dosaženo kombinací hlubokého modelu a zpřesňujících modulů, které umožňují přesnější segmentaci hranic a robustnější detekci tříd i v komplikovaných scénách. Porovnání výsledků metod je uvedeno níže v tabulkách 18–20 a dále v příloze F v tabulkách 32–33 a obrázcích 87–91.

Tabulka 18: F1-skóre – případová studie Čestice II

F1-skóre klasifikace		
metoda	zkratka	RGB
Deep Learning - U-NET	DL - U-NET - ResNet50	0,98200
Deep Learning - U-NET	DL - U-NET - VGG16	0,87400
Deep Learning - PSPNet	DL - PSPNet	0,88700
Deep Learning - PSPNet - PointRend	DL - PSPNet - P.R.	0,98300
Deep Learning - DeepLabV3	DL - DeepLabV3	0,91600
Deep Learning - DeepLabV3 - PointRend	DL - DeepLabV3 - P.R.	0,96500
Support Vector Machine	SVM	0,86100
Maximum Likelihood	ML	0,81100
Random Trees	RT	0,84100
Random Trees - depth 100	RT - depth 100	0,75200
K-Nearest Neighbors	KNN	0,63400
ISO cluster	ISO	0,72000
	<i>průměr</i>	0,85217

Zdroj: [vlastní zpracování]

Tabulka 19: Celková přesnost – případová studie Čestice II

Celková přesnost klasifikace		
metoda	zkratka	RGB
Deep Learning - U-NET	DL - U-NET - ResNet50	0,99300
Deep Learning - U-NET	DL - U-NET - VGG16	0,96100
Deep Learning - PSPNet	DL - PSPNet	0,95300
Deep Learning - PSPNet - PointRend	DL - PSPNet - P.R.	0,99300
Deep Learning - DeepLabV3	DL - DeepLabV3	0,97300
Deep Learning - DeepLabV3 - PointRend	DL - DeepLabV3 - P.R.	0,98700
Support Vector Machine	SVM	0,92700
Maximum Likelihood	ML	0,90000
Random Trees	RT	0,91300
Random Trees - depth 100	RT - depth 100	0,87300
K-Nearest Neighbors	KNN	0,79300
ISO cluster	ISO	0,89300
	<i>průměr</i>	0,92992

Zdroj: [vlastní zpracování]

Tabulka 20: Kappa index – případová studie Čestice II

Kappa koeficient klasifikace		
metoda	zkratka	RGB
Deep Learning - U-NET	DL - U-NET - ResNet50	0,96400
Deep Learning - U-NET	DL - U-NET - VGG16	0,74900
Deep Learning - PSPNet	DL - PSPNet	0,77300
Deep Learning - PSPNet - PointRend	DL - PSPNet - P.R.	0,96600
Deep Learning - DeepLabV3	DL - DeepLabV3	0,83200
Deep Learning - DeepLabV3 - PointRend	DL - DeepLabV3 - P.R.	0,93000
Support Vector Machine	SVM	0,72300
Maximum Likelihood	ML	0,62700
Random Trees	RT	0,68400
Random Trees - depth 100	RT - depth 100	0,50700
K-Nearest Neighbors	KNN	0,27500
ISO cluster	ISO	0,44000
	<i>průměr</i>	0,70583

Zdroj: [vlastní zpracování]

Hlubková analýza výsledků klasifikace ukazuje, že rozdíly mezi metodami nejsou dány pouze celkovou přesností, ale především jejich schopností přizpůsobit se konkrétním charakteristikám obrazových dat – od architektury modelu až po reakci na spektrální a prostorové variace scén, viz obrázky 57 a 58, které je možno porovnat s ortofotomozaikou na obrázku 59.

Nejvyšší výkonnosti dosáhla PSPNet s modulem PointRend, která vynikala především v lokalizaci okrajů a přechodových zón. PointRend dynamicky zpřesňuje výpočet právě v těch oblastech, kde je nejvyšší neurčitost – typicky v přechodu mezi třídami. Díky tomu nedocházelo k rozmazání hran nebo nesprávné klasifikaci v okrajových oblastech, což je běžný problém u jednodušších segmentačních modelů. Model tak spojil silné stránky hluboké prostorové reprezentace (PSPNet) s jemnou texturovou analýzou (PointRend).

U-Net s ResNet50 architekturou byl taktéž mimořádně úspěšný. Residuální bloky umožňují efektivnější průchod signálu sítí bez jeho „vyvanutí“ (vanishing gradient), čímž se zvyšuje schopnost zachytit hlubší vzory v datech. Model si velmi dobře poradil i se subtilními rozdíly v obraze, což je klíčové při rozlišování mezi podobně zbarvenými třídami. Navzdory absenci dodatečného zpřesňujícího modulu se tak U-Net ResNet50 udržel těsně za nejlepší metodou.

DeepLabV3 s PointRend ukázal velmi dobrou rovnováhu mezi přesností a ostrostí segmentace, a i bez využití předtrénovaných reziduálních bloků v jádře modelu byl schopen se velmi dobře přizpůsobit scéně. Naopak základní DeepLabV3 bez PointRend sice zvládal klasifikaci hlavních tříd, ale ztrácel přesnost v místech, kde hranice mezi třídami nebyly jednoznačně spektrálně ohraničené.

PSPNet bez PointRend vykazoval mírně nižší výkon, což potvrzuje důležitost doplňujících modulů pro práci s hraničními oblastmi. Tento model byl silný v jádrových oblastech, ale měl tendenci „rozmazávat“ nebo špatně interpretovat přechody, což se projevilo nižším F1-skóre.

U-Net s VGG16 dosáhl o něco slabších výsledků než jeho hlubší protějšek s ResNet50, což je očekávatelné – architektura VGG16 má omezenější kapacitu modelovat komplexní vztahy v datech a není tak hluboká. Přesto však zvládla konzistentní výstup v hlavních oblastech zájmu.

Z tradičních metod vynikla SVM, která se ukázala jako nejrobustnější mezi nekonvolučními algoritmy. Její síla spočívá v tom, že využívá optimalizaci hraničních oblastí a pracuje efektivně v prostorech s dobře separovatelnými třídami. V oblastech s jasně vymezeným rozdílem mezi zaplavenou a nezaplavenou plochou se metoda ukázala jako velmi spolehlivá. Naopak její slabinou byly rozostřené nebo texturně složité přechody.

Random Trees (depth 30) nabídla velmi solidní výkon, což ukazuje, že správně nastavený ensemble stromových klasifikátorů může poskytnout překvapivě dobré výsledky. Avšak zvýšení hloubky stromů na 100 (RT – depth 100) vedlo k přeučení – model zachytil i šum a specifické detaily trénovacích vzorků, což následně způsobilo ztrátu schopnosti generalizovat. Tento jev je typický pro složité a rozsáhlé rozhodovací stromy v prostředí s omezeným množstvím dat.


Maximum Likelihood si vedla dobře v oblastech, kde se třídy vyznačovaly normálním rozdělením hodnot. Jakmile se však v obraze vyskytly nepravidelné nebo nehomogenní plochy (např. mozaikovitě poškozená vegetace), výkon této metody mírně poklesl. Přesto zůstává ML spolehlivou volbou pro jednoduché scénáře.

Překvapivě dobře si vedla i neřízená metoda ISO Cluster, která – navzdory absenci trénovacích vzorků – dokázala identifikovat základní spektrální vzory. Vyšší přesnost je zřejmě dána tím, že obraz obsahoval jednoznačně odlišitelné oblasti, jejichž spektrální charakteristiky byly relativně homogenní. Nicméně chyběla jí schopnost rozlišit detaily v jemně strukturovaných přechodech.

Na opačném konci výkonnostního spektra se nacházela KNN, která měla problémy s lokální konzistencí. Model se silně spoléhal na blízkost pixelů v trénovacím prostoru, což vedlo k chybnému zařazení v oblastech s přechody nebo tam, kde byly třídy mozaikovitě promíchány. Nižší Kappa koeficient potvrdil nízkou shodu klasifikace s referenčními daty.


Z pohledu celkového hodnocení se ukázalo, že architektury hlubokého učení s doplňujícími moduly výrazně převyšují konvenční metody. Jejich schopnost integrovat prostorové a texturové vztahy v obraze, zejména v komplikovaných scénách, je klíčem k dosažení vysoké

přesnosti. Tradiční algoritmy mohou být nadále užitečné pro jednodušší úlohy, avšak při požadavku na detailní segmentaci a práci s hranami je jejich potenciál omezený.



Obrázek 57: Klasifikace – konvenční metody – případová studie Čestice II

Zdroj: [vlastní zpracování]




Obrázek 58: Klasifikace – DL metody – případová studie Čestice II

Zdroj: [vlastní zpracování]

VÝSEČ ZÁJMOVÉHO ÚZEMÍ

pole po povodni Čestice - porovnání modelů



Obrázek 59: RGB snímek s výřezem – případová studie Čestice II

Zdroj: [vlastní zpracování]

Tato případová studie podrobně porovnává různé klasifikační modely, především na architektury hlubokého učení (Deep Learning, DL), které byly aplikovány na RGB snímky bez použití spektrálních indexů. Výsledky jednoznačně potvrdily, že DL výrazně překonává tradiční algoritmy. Nejvyšší přesnost dosáhl model PSPNet s modulem PointRend (F1 98,3 %), což potvrzuje, že zpřesnění hranic mezi třídami je klíčové pro dosažení nejlepších výsledků. Studie rovněž zdůraznila význam volby páteří kostry: U Net s hlubším ResNet50 výrazně předčil variantu s mělčím VGG16. Z tradičních metod byla nejúspěšnější SVM, která se opět potvrdila jako nejrobustnější nekonvoluční algoritmus.

Celkově se ukazuje, že pro detailní segmentaci je klíčová volba pokročilé DL architektury a doplňujících modulů umožňujících přesnou interpretaci složitých prostorových vzorů.


5.7 Případová studie: detekce objektů – sad Trpík

Sedmá případová studie je v lokalitě u obce Trpík (49° 51' 14" N, 16° 34' 29" E) a byla zaměřena na inventarizaci stromů v semenném sadu s pravidelně rozmístěnými jedinci, což umožnilo ověřit možnosti automatizovaného detekčního počítání objektů na základě RGB dat z UAV a prověřit schopnost vybraného modelu identifikovat jednotlivé koruny stromů i místa s jejich absencí.


K pořízení obrazových dat byl využit bezpilotní letoun DJI Phantom 4 Pro. Let proběhl 22. 8. 2024 v automatickém režimu naplánovaném v softwaru Pix4Dcapture s vysokým překryvem 90 % ve výšce přibližně 40 metrů. Snímkování proběhlo za stabilních světelných podmínek, které byly příznivé pro detekci drobných objektů a kontur jednotlivých stromových korun.

Celková nasnímaná plocha oblasti činila 9,361 ha, přičemž zájmové území určené pro detekci mělo rozlohu 3,415 ha, viz obrázek 60. Polygon zájmového území měl délku 373,71 metrů a šířku 146,10 metrů, viz obrázek 61. Celkem bylo pořízeno 527 snímků a složena ortofotomozaika s prostorovým rozlišením 1,106 cm/px.

Pro analýzu byla využita metoda object detection pomocí modelu hlubokého učení, konkrétně Mask R-CNN s páteří architekturou ResNet50, trénovaného výhradně na RGB datech. Model byl učen rozpoznávat jednotlivé koruny stromů v rámci pravidelně strukturovaného porostu a výsledky následně sloužily jako podklad pro kvantitativní inventarizaci sadového porostu.




QR kód 7: Interaktivní výstup – detekce objektů, sad Trpík



Obrázek 60: Tematický snímek – případová studie Trpík

Zdroj: [vlastní zpracování]



Obrázek 61: Rozloha CÚ a ZÚ – případová studie Trpík

Zdroj: [vlastní zpracování]

V rámci případové studie zaměřené na detekci jednotlivých stromových objektů dosáhla metoda hlubokého učení ResNet-50 velmi vysoké úspěšnosti, viz obrázky 62 a 63. Model vykázal F1-skóre 96,6 %, celkovou přesnost 93,3 % a recall 100 %, což znamená, že všechny skutečně existující stromy byly správně identifikovány. Tato schopnost úplné detekce je mimořádně důležitá zejména v úlohách spojených s monitoringem, inventarizací nebo sčítáním vegetačních objektů.


Z dodatečných výpočtů, viz tabulka 21, vyplývá, že:

- bylo správně detekováno 687 stromů (True Positives),
- zaznamenáno 49 falešných pozitivních detekcí (False Positives),
- a žádný strom z referenčních dat nebyl opomenut (False Negatives = 0).

Hodnota precision 93,3 % poukazuje na přítomnost určitého množství falešně pozitivních detekcí. Přestože nebyly zásadní, ukazují, že model v některých případech identifikoval jako samostatné stromy části rozložené a členitě prořezané koruny. Tyto chyby vedly k mírnému nadhodnocení počtu stromů, což je však méně závažné než jejich vynechání.


Absence Kappa koeficientu je dána tím, že úloha detekce probíhala v rámci jedné třídy – „stromy“, a tedy nelze hodnotit shodu mezi více kategoriemi.

Výsledky potvrzují, že hluboká neuronová síť s architekturou ResNet-50 je dobře uzpůsobena pro segmentační úlohy s důrazem na přesnou lokalizaci a detekci objektů na vysoce detailních RGB snímcích z UAV. Tato metoda se ukázala jako velmi vhodná pro praktické využití při analýze sadů nebo izolovaných dřevin v zemědělské a lesnické praxi.



Obrázek 62: Metriky detekce objektů – případová studie Trpík

Zdroj: [vlastní zpracování]



Obrázek 63: Rozložení výstupů detekce objektů – případová studie Trpík

Zdroj: [vlastní zpracování]

Tabulka 21: Metriky detekce objektů – případová studie Trpík

VYPOČÍTANÉ METRIKY	
Uživatelská přesnost klasifikace (Precision)	0,933
Producentova přesnost klasifikace (Recall)	1
F1-skóre klasifikace	0,966
Kappa index	NaN (pouze 1 třída)
Celková přesnost klasifikace (Overall Accuracy)	0,933
DODATEČNÉ POČTY	
True Positives (TP)	687
False Positives (FP)	49
False Negatives (FN)	0
Total Ground Truth Labels	687

Zdroj: [vlastní zpracování]

Hlubší pohled na výsledky detekce stromů ukazuje, že dosažená výkonnost metody ResNet-50 nebyla náhodná, ale vycházela z několika synergických faktorů souvisejících jak s architekturou modelu, tak s vlastnostmi vstupních dat a charakterem sledovaného území, viz obrázek 64.


Zcela zásadním faktorem vysoké úspěšnosti byla 100% úplnost detekce (recall), která potvrzuje, že model dokázal spolehlivě identifikovat všechny skutečně přítomné stromy. Tato vlastnost je klíčová zejména v aplikačních scénářích, kde je požadována maximální úplnost inventarizace – například v ovocnářství, lesnictví, správě městské zeleně nebo při hodnocení vitality stromových entit. Významnost této vlastnosti převyšuje drobné nadhodnocení, které je z hlediska praktického využití méně problematické než opomenutí existujících objektů.

Precision ve výši 93,3 % odhaluje určitou míru falešných pozitiv, přičemž detailní inspekce ukázala, že se nejednalo o chybnou identifikaci cizích objektů, ale o situace, kdy byl jeden strom detekován vícekrát. Nejčastěji k tomu docházelo u rozložitých nebo nepravidelně tvarovaných korun, jejichž středová část byla vizuálně ovlivněná tvarovacím řezem do nízké a široké koruny s bohatým větvením. Model takovou korunu segmentoval jako dva či více samostatných objektů – například oddělením levé a pravé poloviny stromu. Tento jev je typický pro segmentační architektury, které silně reagují na okrajové kontury, ale ne vždy disponují dostatečným kontextem pro posouzení celistvosti objektu.

Vysoké hodnoty F1 skóre a OA dokládají, že model i přes tyto drobné nepřesnosti zachoval celkovou konzistenci a stabilitu výsledků napříč celou scénou. To je dáno mimo jiné architekturou ResNet-50, která využívá reziduální propojení umožňující efektivní přenos informací napříč hlubokými konvolučními vrstvami. Díky tomu je síť schopna zachytit textury, prostorové vzory i jemné tvarové odlišnosti, které jsou typické pro koruny stromů na RGB snímcích.

Je třeba rovněž zdůraznit, že testovaná lokalita byla tvořena semenným sadem s pravidelným pravoúhlým rozmístěním stromů, což výrazně přispělo k vyšší čitelnosti scény a usnadnilo jak trénování, tak predikci modelu. Pravidelné vzorce výsadby umožnily modelu snáze identifikovat tvarové a prostorové opakování, které je typické pro jednotlivé stromové objekty. V prostředích s nižší mírou pravidelnosti, překryvy korun, stíny nebo výskytem pozemní vegetace by mohlo dojít k mírnému snížení výkonnosti, zejména v přesnosti segmentace a lokalizace jednotlivých objektů.

Z hlediska praktického nasazení lze konstatovat, že detekce pomocí hlubokého učení (konkrétně ResNet-50) je vhodná i při absenci multispektrálních dat, pokud jsou k dispozici vysokorozlišovací RGB ortofotosnímky. Díky kombinaci precizní segmentace a robustního učení je model schopen poskytovat výstupy použitelné v reálných scénářích – a to jak pro analytické, tak operativní účely.



Obrázek 64: Detekce objektů – DL – případová studie Trpík

Zdroj: [vlastní zpracování]

Tato případová studie se zaměřuje na detekci objektů, konkrétně inventarizaci jednotlivých stromů v sadu pomocí modelu Mask R-CNN s páteří ResNet 50. Model dosáhl 100 % úplnosti detekce (recall) – identifikoval všech 687 stromů bez jediné vynechané položky. Taková úplnost je pro inventarizační úlohy zásadní. Přesnost činila 93,3 % a odráží 49 falešných pozitivit. Analýza potvrdila, že falešné detekce nevznikly záměnou s jinými objekty, ale rozdělením mohutně větvených korun na více segmentů.

Výsledky potvrzují vysokou efektivitu tohoto přístupu pro praktické nasazení v sadech i při využití pouze RGB dat; k úspěchu přispělo i pravidelné rozmístění stromů v lokalitě.

ZÁVĚR

Tato diplomová práce, nazvaná Klasifikace UAV obrazových dat v rámci vybraných území, se zaměřila na komplexní analýzu a ověření účinnosti metod řízené a neřízené klasifikace v kombinaci se spektrálními indexy. Testování bylo provedeno na obrazových datech s velmi vysokým prostorovým rozlišením pořízených nízkonákladovými bezpilotními prostředky vybavenými standardními RGB senzory, a to na vybraných krajinných a zemědělských scénářích.

Teoretická část práce vymezila fyzikální principy dálkového průzkumu Země, zejména interakci elektromagnetického záření s atmosférou a odrazové vlastnosti povrchů, které určují spektrální podpis snímků. Bylo popsáno, že standardní RGB senzory, i přes absenci diagnosticky cenného NIR pásma, představují díky nízkým pořizovacím nákladům a snadné interpretovatelnosti perspektivní alternativu pro širokou škálu aplikací. Práce zdůraznila přednosti UAV, které díky vysoké frekvenci sběru dat, centimetrovému prostorovému rozlišení a provozní flexibilitě umožňují detailní tematické mapování lokálních jevů. Následně byl podrobně popsán zpracovatelský řetězec VHR dat, zahrnující přímé a nepřímé georeferencování, radiometrické a geometrické korekce, tvorbu ortofotosnímků a hierarchii metod spektrálního zvýraznění. Dále byly představeny tři klasifikační přístupy, konkrétně neřízené shlukování, řízené statistické metody a hluboké učení. Teoretický rámec byl uzavřen stručným popisem evaluačních metrik, které zajistily konzistentní a transparentní hodnocení testovaných metod.

Shrnutí současného stavu ve směru práce potvrdilo rostoucí význam UAV s RGB kamerami jako klíčového zdroje vysoce detailních dat pro precizní zemědělství, krizové mapování a environmentální monitoring, díky jejich schopnosti poskytovat data s frekvencí a rozlišením, které družicové platformy nabídnout nemohou. Výzvy analýzy RGB dat, zejména nedostatky způsobené citlivostí na kolísání saturace a jasu, vedly k využití robustnějších barevných prostorů. Komparativní studie ukázaly, že řízené klasifikátory (Random Forest, SVM) převyšují neřízené, ale vyžadují náročné rozsáhle anotované datasety a často ztrácejí výkonnost při přenosu na odlišné lokality. Z výzkumů vyplynuly určité mezery: absence modulárního workflow pro operativní nasazení UAV, omezená generalizace modelů hlubokého učení a nedostatek komplexních srovnání tradičních a moderních metod na jednotném souboru reálných dat.

Praktická část představila ucelený metodický rámec pracovního postupu, aplikovaný na vybraná zájmová území. Zahrnovala zpracování neupravených RGB snímků z UAV až po tvorbu přesných tematických snímků a zhodnocení aplikovaných klasifikací. Nejprve byl

proveden průzkum dronem DJI Mini 3 Pro pro vytvoření letového plánu, na jehož základě byla uskutečněna akvizice dat pomocí dronů DJI Phantom 4 a Phantom 4 Pro. Získané snímky byly zpracovány do ortofotomozaik, které byly optimalizovány prostřednictvím aplikace vyvinuté pro zmenšení dat. Následně byl vybrán a otestován vhodný spektrální index v programu vytvořeném pro tento účel. Analýza a tvorba tematických snímků probíhaly v ArcGIS Pro, kde byla obrazová data obohacena i o autorem navržené spektrální indexy (SNDGR, GBRWI, MGLI2). Klasifikace dat byla provedena kombinací statistických metod (ML, RF, SVM, KNN), neřízeného shlukování (ISO) a architektury hlubokého učení (U-Net, VGG16, DeepLabV3, PSPNet, Mask R-CNN). Přesnost klasifikací byla ověřena sadou validačních bodů a vyhodnocena metrikami celkové přesnosti, uživatelské a producentovy přesnosti, F1-skóre a Kappa koeficientu pomocí nástroje vytvořeného pro tento účel. Pro práci s metadaty a popisky tematických snímků byla použita aplikace, která extrahovala polohová metadata a generovala údaje pro tiráž obsahující GSD, typ dronu a použitý CRS. Na závěr byla využita aplikace vyvinutá pro výpočet CÚ a ZÚ.

Ověření navrženého postupu v praxi proběhlo prostřednictvím sedmi případových studií, které využívaly RGB ortofotosnímky a odvozené spektrální indexy.

Ve studii Vraclav, zaměřené na poškození řepky bouří, klasifikátory s indexem MGLI2 dosáhly F1-skóre 89,24 %, na RGB datech 87,41 % a s indexem TGI 80,38 %. SVM dosáhl průměrné F1 93,03 % na všech indexech, přičemž index MGLI2 potlačil stíny a zvýraznil vegetaci. Síť U-Net s ResNet-34 vykázala průměrné F1 97,04 % díky analýze textur a plynulým hranicím tříd. Hluboké učení překonalo klasifikátory díky zpracování textur, zatímco ostatní metody byly méně stabilní kvůli obrazovému šumu.

Studie Albánie, zkoumající spálenou vegetaci, ukázala, že ISO Cluster dosáhl na RGB datech F1-skóre 70,48 %, ale s indexem SNDGR se přesnost zvýšila na 91,53 %, čímž se přiblížilo SVM s F1 92,66 % a hlubokému učení s F1 96,66 %. Index SNDGR zlepšil výkon ISO Cluster, avšak u SVM a hlubokého učení nepřinesl přidanou hodnotu, což ukazuje závislost přínosu indexů na použité metodě.

V případě studie Loučky, zaměřené na poškození obilnin, síť U-Net dosáhla F1-skóre 94,4 % díky analýze textur, zatímco druhý klasifikátor Random Trees vykázal 77,9 %. Index TGI snížil přesnost metod KNN a ISO Cluster ($\kappa -0,137$), a SVM selhal v nízkokонтastním prostředí, přičemž hluboké učení dominovalo díky schopnosti zpracování textur.

Studie Hrádek, klasifikující zdravou, poškozenou a plevelnou vegetaci, prokázala, že hluboké učení dosáhlo F1-skóre 94,41 %, čímž předčilo SVM o 15 % bodů. SVM a KNN však lépe

detekovaly plevel, což naznačuje vhodnost jednodušších metod pro specifické úkoly a nízké texturální a jasové rozdíly.

Ve studii Čestice, zaměřené na rozliv vody, SVM dosáhl celkové přesnosti 93,5 % a F1-skóre 89,94 % na RGB datech i s indexem GBRWI. Hluboké učení vykázalo F1 86,8 %, ale GBRWI snížilo jeho výkon, zatímco ISO Cluster s GBRWI zlepšil F1-skóre z 74,6 % na 79,2 %, což je vhodné pro rychlou přehledovou analýzu.

Studie Čestice II, zkoumající stejná vodní rezidua na RGB datech, ukázala, že PSPNet s PointRend dosáhl F1-skóre 98,3 % a celkové přesnosti 99,3 %, podobně jako U-Net s ResNet50 s F1 98,2 % a přesností 99,3 %. SVM dosáhl F1 86,1 % a přesnosti 92,7 %, přičemž hluboké učení excelovalo díky přesné segmentaci textur.

Studie Trpík, zaměřená na objektovou detekci stromů v sadu, prokázala, že Mask R-CNN s ResNet-50 dosáhla F1-skóre 96,6 %, celkové přesnosti 93,3 % a producentovy přesnosti 100 %, čímž identifikovala všech 687 stromů. Falešné detekce (49) byly způsobeny chybným vyhodnocením rozložitých korun na více segmentů.

Výsledky souhrnně potvrzují, že RGB snímky s vhodnými indexy dosahují přesnosti srovnatelné s multispektrálními senzory, přičemž hluboké učení vyniká v analýze textur a prostorových vzorů.

Přidanou hodnotu práce zvyšuje sedm autorem vyvinutých open-source nástrojů v jazyce Python: GeoShrink, FCC (FlyCamCzech) MS Image Processor, MetriCalc, ImageMetaLocator, OrthophotoTool a UAVAreaCalc, které automatizují předzpracování, vizualizaci a statistické vyhodnocení dat. Byly zveřejněny pod autorskou licencí a jejich zdrojové kódy jsou dostupné na GitHub pro snadnou replikaci a rozšíření. Každá případová studie je doprovázena tematickými snímky, grafy a tabulkami, zajišťujícími přehlednost výsledků. Součástí práce je také moderní webová aplikace UAVThesisWeb, vyvinutá pro interaktivní zobrazení a porovnání klasifikačních výstupů ze sedmi případových studií, s responzivním designem využívajícím HTML, CSS, JavaScript, EJS a Node.js/Express, optimalizovaným pro desktop i mobilní zařízení.

Použitý klasifikační postup ukázal, že RGB snímky z nízkonákladových UAV lze po vhodném spektrálním zvýraznění a výběru algoritmů efektivně využít pro detailní tematické analýzy. Největší přínos hlubokých sítí byl patrný ve scénářích vyžadujících zachycení jemných texturových a prostorových vzorů. Navržené spektrální indexy umožnily rychlou a přesnou detekci bez potřeby hlubokého učení, což je zásadní pro operativní použití v krizových situacích. Pro potvrzení jejich robustnosti je však třeba otestovat jejich stabilitu na dalších

územích. Otevřený ekosystém nástrojů a replikovatelný pracovní postup zvyšují jejich využitelnost a usnadňují další nasazení.

Výstupy z klasifikace obrazových dat zájmových území lze účelně využít například ve veřejné správě, zemědělských podnicích a organizacích zabývajících se monitoringem a managementem krajiny. Tyto výsledky mohou najít uplatnění pro potřeby vnitřní analýzy podniků či vlastníků pozemků, přičemž přispívají k operativnímu řízení, optimalizaci hospodaření, výnosů a zisků, strategickému plánování, zefektivnění reporting managementu a posílení managementu rizik.

Budoucí výzkum by se mohl zaměřit na fúzi multispektrálních a RGB dat pro zlepšení detekce v hustých vegetačních porostech, vývoj semi a self-supervizovaných metod ke snížení potřeby manuálních anotací a využití pokročilých architektur hlubokého učení pro zvýšení robustnosti klasifikačních analýz.

POUŽITÁ LITERATURA

- AGGARWAL, Charu C., 2023. Neural Networks and Deep Learning: a textbook. 2. vyd. Cham, Switzerland: Springer Nature. ISBN 978-3-031-29641-3.
- BANNARI, A.; MORIN, D.; BONN, F. a HUETE, A. R., 1995. A review of vegetation indices. online. In: Remote Sensing Reviews. Roč. 13, č. 1–2, s. 95–120. Dostupné z: <https://doi.org/10.1080/02757259509532298>. [cit. 2025-02-15].
- BENDIG, J.; YU, K.; AASEN, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; GNYP, M. L. a BARETH, G., 2015. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. online. In: International Journal of Applied Earth Observation and Geoinformation. Roč. 39, s. 79–87. ISSN 1569-8432. Dostupné z: <https://doi.org/10.1016/j.jag.2015.02.012>. [cit. 2025-02-15].
- BHANDARI, Mahendra; et al., 2021. Assessing the Effect of Drought on Winter Wheat Growth Using Unmanned Aerial System (UAS)-Based Phenotyping. online. In: Remote Sensing. Roč. 13, č. 6, 1144, s. 1–20. Licence: CC BY. Dostupné z: MDPI, <https://doi.org/10.3390/rs13061144>. [cit. 2025-06-28].
- BOON, M. A.; DRIJFHOUT, A. P. a TEFAMICHAEL, S., 2017. Comparison of a fixed-wing and multi-rotor UAV for environmental mapping applications: a case study. online. In: The international archives of the photogrammetry, remote sensing and spatial information sciences. Roč. XLII-2/W6, s. 47–54. Dostupné z: <https://doi.org/10.5194/isprs-archives-XLII-2-W6-47-2017>. [cit. 2025-07-03].
- BOONRANG, Apinya; PIYATADSANANON, Pantip a SRITARAPIPAT, Tanakorn, 2024. Efficient UAV-Based Automatic Classification of Cassava Fields Using K-Means and Spectral Trend Analysis. online. In: AgriEngineering. Roč. 6, č. 4, s. 4406–4424. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/agriengineering6040250>. [cit. 2025-07-05].
- CAMPBELL, James B.; WYNNE, Randolph H., 2011. Introduction to Remote Sensing. 5. vyd. New York: Guilford Press. ISBN 978-1-60918-176-5.
- CVETKOVIĆ, Nikola; ĐOKOVIĆ, Aleksandar; DOBROTA, Marina a RADOJIČIĆ, Miroslav, 2023. New Methodology for Corn Stress Detection Using Remote Sensing and Vegetation Indices. online. In: Sustainability. Roč. 15, č. 6, 5487, s. 1–12. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/su15065487>. [cit. 2025-07-05].
- DE SWAEF, Tom; MAES, Wouter H.; APER, Jeroen; BAERT, Jan; COUGNON, Mark; REHEUL, Dirk; STEPPE, Kathy; ROLDÁN-RUIZ, Isabel a LOOTENS, Peter, 2021. Applying RGB- and Thermal-Based Vegetation Indices from UAVs for High-Throughput Field Phenotyping of Drought Tolerance in Forage Grasses. online. In: Remote Sensing. Roč. 13, č. 1, 147, s. 1–24. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/rs13010147>. [cit. 2025-07-04].
- DJI, [b.r.]. Specifikace. In: DJI.com, [online]. Dostupné z: <https://www.dji.com/cz/support/product/phantom-4>; <https://www.dji.com/cz/support/product/phantom-4-pro>. [cit. 2025-06-23].
- DOBROVOLNÝ, Petr, 1998. Dálkový průzkum Země, Digitální zpracování obrazu. Brno: MU Brno. ISBN 80-210-1812-7.
- EDITORS, SatNow, 2025. What is an Highly Elliptical Orbit?. Online. In: SatNow. 14.2.2025. Dostupné z: <https://www.satnow.com/community/what-is-an-highly-elliptical-orbit>. [cit. 2025-06-19].

ESRI, [b.r.]. The image classification wizard. online. In: ArcGIS Pro. Dostupné z: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/image-analyst/the-image-classification-wizard.htm>. [cit. 2025-05-12].

GANO, Boubacar; BHADRA, Subhajyoti; VILBIG, John M.; AHMED, Naser; SAGAN, Vasiť a SHAKOOR, Nadia, 2024. Drone-based imaging sensors, techniques, and applications in plant phenotyping for crop breeding: A comprehensive review. online. In: The Plant Phenome Journal. Wiley Periodicals LLC, roč. 7, e20100, s. 1-28. Licence: CC BY-NC-ND. Dostupné z: <https://doi.org/10.1002/ppj2.20100>. [cit. 2025-07-02].

GIAMERTI, Yuti; DARMADI, Didi; JUNAEDI, Ahmad; LUBIS, Iskandar; SOPANDIE, Didie; MEISHANTI, Ospa Pea Yuanita; SARI, Kartika; HONGO, Chiharu a HOMMA, Koki, 2024. Evaluation Trial of Drought Damage of Rice Based on RGB Aerial Image by UAV. online. In: agriTECH. Roč. 44, č. 4, s. 354-361. ISSN 0216-0455. Dostupné z: <http://doi.org/10.22146/agritech.86077>. [cit. 2025-06-17].

GILLESPIE, Alan R.; KAHLE, Anne B. a WALKER, Richard E., 1987. Color enhancement of highly correlated images. II. Channel ratio and “chromaticity” transformation techniques. online. In: Remote Sensing of Environment. Roč. 22, č. 3, s. 343–365. ISSN 0034-4257. Dostupné z: [https://doi.org/10.1016/0034-4257\(87\)90088-5](https://doi.org/10.1016/0034-4257(87)90088-5). [cit. 2025-02-23].

GITELSON, Anatoly A.; KAUFMAN, Yoram J.; STARK, Robert a RUNDQUIST, Don, 2002. Novel algorithms for remote estimation of vegetation fraction. online. In: Remote Sensing of Environment. Roč. 80, č. 1, s. 76–87. ISSN 0034-4257. Dostupné z: [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9). [cit. 2025-02-15].

GOBRON, N.; PINTY, B.; VERSTRAETE, M. M. a WIDLOWSKI, J. L., 2000. Advanced vegetation indices optimized for up-coming sensors: design, performance, and applications. online. In: IEEE Transactions on Geoscience and Remote Sensing. Roč. 38, č. 6, s. 2489–2505. Dostupné z: <https://doi.org/10.1109/36.885197>. [cit. 2025-02-23].

GONZALEZ, Rafael C.; WOODS, Richard E., 2018. Digital Image Processing. 4. vyd. Pearson. ISBN 978-1-292-22304-9.

GOODFELLOW, Ian; BENGIO, Yoshua a COURVILLE, Aaron, 2016. Deep Learning. MIT Press. ISBN 978-0-262-03561-3.

GÖRLICH, Florian; MARKS, Elias; MAHLEIN, Anne-Katrin; KÖNIG, Kathrin; LOTTES, Philipp a STACHNISS, Cyrill, 2021. UAV-Based Classification of Cercospora Leaf Spot Using RGB Images. online. In: Drones. Roč. 5, č. 2, 34, s. 1-15. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/drones5020034>. [cit. 2025-05-21].

HUNT, E. Raymond; DORAISWAMY, Paul C.; McMURTREY, James E.; DAUGHTRY, Craig s. T.; PERRY, Eileen M. a AKHMEDOV, Bakhyt, 2013. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. online. In: International Journal of Applied Earth Observation and Geoinformation. Roč. 21, s. 103–112. ISSN 1569-8432. Dostupné z: <https://doi.org/10.1016/j.jag.2012.07.020>. [cit. 2025-02-14].

CHIABRANDO, F.; DONADIO, E. a RINAUDO, F., 2015. SfM for orthophoto generation: a winning approach for cultural heritage knowledge. online. In: The international archives of the photogrammetry, remote sensing and spatial information sciences. Roč. XL-5/W7, s. 47–54. Dostupné z: <https://doi.org/10.5194/isprsarchives-XL-5-W7-91-2015>. [cit. 2025-06-23].

ILCEV, St. D., 2010. Highly elliptical orbits (HEO) for high latitudes and polar coverage. Online. In: 2010 20th International Crimean Conference "Microwave & Telecommunication Technology". s. 396-399. Dostupné z: <https://doi.org/10.1109/CRMICO.2010.5632684>. [cit. 2025-07-09].

JECH, Jakub, 2024. Návrh klasifikačního přístupu pro obrazová data s velmi vysokým prostorovým rozlišením. Online, disertační práce. Univerzita Pardubice. Dostupné z: <https://hdl.handle.net/10195/84041>. [cit. 2025-03-18].

JECH, Jakub; KOMÁRKOVÁ, Jitka; SEDLÁK, Pavel a KRÁTKÝ, Martin, 2023. Utilization of UAV-Borne RGB Data for Monitoring Horses: Comparison of Classification Methods. Online. 2023 18th Iberian Conference on Information Systems and Technologies (CISTI). IEEE, s. 1-7. ISSN 2166-0727. Dostupné z: <https://doi.org/10.23919/CISTI58278.2023.10211822>. [cit. 2025-03-14].

KERDEGARI, Hamideh; RAZAAK, Manzoor; ARGYRIOU, Vasileios a REMAGNINO, Paolo, 2019. Semi-supervised GAN for Classification of Multispectral Imagery Acquired by UAVs. online, preprint. Dostupné z: arXiv, <https://doi.org/10.48550/arXiv.1905.10920>. [cit. 2025-07-07].

KHAN, Shahbaz; TUFAIL, Muhammad; KHAN, Muhammad Tahir; KHAN, Zubair Ahmad; IQBAL, Javaid a ALAM, Mansoor, 2021. A novel semi-supervised framework for UAV based crop/weed classification. online. In: PLOS ONE. Roč. 16, č. 5, e0251008, s. 1-18. Licence: CC BY. Dostupné z: <https://doi.org/10.1371/journal.pone.0251008>. [cit. 2025-07-03].

KOLÁŘ, Jan, 1990. Dálkový průzkum Země. Populární přednášky o fyzice, sv. 35. Praha: Státní nakladatelství technické literatury. ISBN 80-03-00517-5.

KOMÁRKOVÁ, Jitka a JECH, Jakub, 2020. Processing UAV Based RGB Data to Identify Land Cover with Focus on Small Water Body: Comparison of Methods. online. In: 2020 15th Iberian Conference on Information Systems and Technologies (CISTI). IEEE, ISSN 2166-0727. Dostupné z: <https://doi.org/10.23919/CISTI49556.2020.9141170>. [cit. 2025-04-28].

KRÁTKÝ, Martin a KOMÁRKOVÁ, Jitka, 2023. Evaluating the Use of Very High-Resolution RGB Imagery from UAV for Vegetation Classification. In: 2023 International Conference on Information and Digital Technologies (IDT). Zilina, Slovakia. s. 51-56. ISSN 2575-677X, 2575-6753. Dostupné z: <https://doi.org/10.1109/IDT59031.2023.10194395>. [cit. 2025-05-21].

LI, Jiating, 2019. Unmanned Aerial Vehicle Data Analysis For High-throughput Plant Phenotyping. Online. Master's Thesis. University of Nebraska – Lincoln. Dostupné z: DigitalCommons@University of Nebraska – Lincoln, <https://digitalcommons.unl.edu/biosysengdiss/88>. [cit. 2025-07-09].

LILLESAND, Thomas; KIEFER, Ralph W. a CHIPMAN, Jonathan, 2015. Remote Sensing and Image Interpretation. 7. vyd. Hoboken, John Wiley & Sons. ISBN 978-1-118-34328-9.

LONGLEY, Paul A.; GOODCHILD, Michael F.; MAGUIRE, David J. a RHIND, David W., 2015. Geographic Information Systems and Science. 4. vyd. Hoboken, NJ: John Wiley & Sons. ISBN 978-1-118-67695-0.

LOUHAICHI, M.; BORMAN, M. M. a JOHNSON, D. E., 2001. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. online. In: Geocarto International. Roč. 16, č. 1, s. 65–70. Dostupné z: <https://doi.org/10.1080/10106040108542184>. [cit. 2025-03-21].

LURTON, X.; LAMARCHE, G.; BROWN, C.; LUCIEER, V.; RICE, G.; SCHIMEL, A. a WEBER, T., 2015. Backscatter measurements by seafloor-mapping sonars: guidelines and recommendations. online.

[Technická zpráva]. GeoHab. Dostupné z: <https://doi.org/10.5281/zenodo.10089261>; <https://www.researchgate.net/publication/275890570>. [cit. 2025-06-27].

MAIMAITIJIANG, Maitiniyazi; SAGAN, Vasiť; SIDKE, Paheding; DALOYE, Ahmad M.; ERKBOL, Hasanjan a FRITSCHI, Felix B., 2020. Crop Monitoring Using Satellite/UAV Data Fusion and Machine Learning. online. In: Remote Sensing. Roč. 12, č. 9, 1357, s. 1-23. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/rs12091357>. [cit. 2025-07-04].

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION. NOAA'S NATIONAL OCEAN SERVICE, [b.r.]. What is Bathymetry? And why is it important?. online. Dostupné z: <https://oceanservice.noaa.gov/facts/bathymetry.html>. [cit. 2025-06-22].

OERKE, E.C., 2006. Crop losses to pests. Online. The Journal of Agricultural Science. Roč. 144, č. 1, s. 31-43. ISSN 0021-8596. Dostupné z: Cambridge Core, doi:10.1017/S0021859605005708; <https://doi.org/10.1017/S0021859605005708>. [cit. 2025-07-03].

PÁDUA, Luís; ADÃO, Telmo; HRUŠKA, Jonáš; GUIMARÃES, Nathalie; MARQUES, Pedro; PERES, Emanuel a SOUSA, Joaquim J., 2020. Vineyard Classification Using Machine Learning Techniques Applied to RGB-UAV Imagery. online. In: 2020 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Waikoloa, HI, USA. s. 6309-6312. ISBN 978-1-7281-6374-1. Dostupné z: <https://doi.org/10.1109/IGARSS39084.2020.9324380>. [cit. 2025-07-08].

PRATT, William K., c2001. Digital Image Processing: PIKS Inside. 3. vyd. New York: John Wiley. ISBN 978-0-471-37407-5.

RUFO, Rubén; SORIANO, Jose Miguel; VILLEGAS, Dolors; ROYO, Conxita a BELLVERT, Joaquim, 2021. Using Unmanned Aerial Vehicle and Ground-Based RGB Indices to Assess Agronomic Performance of Wheat Landraces and Cultivars in a Mediterranean-Type Environment. online. In: Remote Sensing. Roč. 13, č. 6, 1187, s. 1-19. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/rs13061187>. [cit. 2025-06-23].

RUSS, John C. a NEAL, F. Brent, 2016. The Image Processing Handbook. 7. vyd. New York: CRC Press. ISBN 978-1-4987-4028-9.

SABINS, Floyd F., 2007. Remote Sensing: Principles and Interpretation. Waveland Press. ISBN 1577665074, 9781577665076.

SEDLÁK, Pavel; KOMÁRKOVÁ, Jitka; JECH, Jakub a MAŠÍN, Oldřich, 2019. Low-cost UAV as a Source of Image Data for Detection of Land Cover Changes. Online. Journal of Information Systems Engineering & Management. Roč. 5, č. 1, 1-7. ISSN 2468-4376. Dostupné z: <https://doi.org/10.29333/jisem/5894>; <https://www.jisem-journal.com/download/low-cost-uav-as-a-source-of-image-data-for-detection-of-land-cover-changes-5894.pdf>. [cit. 2025-04-16].

SEDLÁK, Pavel; KOMÁRKOVÁ, Jitka; LANGEROVÁ, Magdaléna a ČERMÁKOVÁ, Ivana, 2018. Usage of Spectral Indices in Monitoring pf Gree in the Selected Parts of the Pardubice Region (the Czech Republic). In: 7th International Conference on Cartography and GIS: proceedings vol. 1, 2. Sozopol. s. 442-451. ISSN 1314-0604. Dostupné z: <https://hdl.handle.net/10195/72892>. [cit. 2025-04-20].

SEDLÁK, Pavel; KOMÁRKOVÁ, Jitka; MAŠÍN, Oldřich a JECH, Jakub, 2019b. The Procedure for Processing Images from a Low-cost UAV. online. In: 2019 14th Iberian Conference on Information Systems and Technologies (CISTI). Coimbra, Portugal. s. 1-4. Dostupné z: <https://doi.org/10.23919/CISTI.2019.8760952>. [cit. 2025-04-18].

SHU, Mengyi; FEI, Suxia; ZHANG, Baojun; YANG, Xiaoyan; GUO, Yan; LI, Bingjie a MA, Yang, 2022. Application of UAV multisensor data and ensemble approach for high-throughput estimation of maize phenotyping traits. online. In: Plant Phenomics. 2022, 9802585. Dostupné z: <https://doi.org/10.34133/2022/9802585>. [cit. 2025-06-19].

SIMES, Tomás; PÁDUA, Luís a MOUTINHO, Alexandra, 2024. Wildfire Burnt Area Severity Classification from UAV-Based RGB and Multispectral Imagery. online. In: Remote Sensing. Roč. 16, č. 1, 30, s. 1-19. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/rs16010030>. [cit. 2025-07-02].

TUCKER, Compton J., 1979. Red and photographic infrared linear combinations for monitoring vegetation. online. In: Remote Sensing of Environment. Roč. 8, s. 127–150. ISSN 0034-4257. Dostupné z: [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0). [cit. 2025-03-06].

UNITED NATIONS. Department of Economic and Social Affairs. Population Division, 2017. World Population Prospects: The 2017 Revision, Key Findings and Advance Tables. online. Working Paper No. ESA/P/WP/248. Dostupné z: https://www.un.org/en/development/desa/population/events/pdf/other/21/21June_FINAL%20PRESS%20RELEASE_WPP17.pdf. [cit. 2025-07-09].

WOEBBECKE, D. M.; MEYER, G. E.; VON BARGEN, K. a MORTENSEN, D. A., 1995. Color indices for weed identification under various soil, residue, and lighting conditions. online. In: Transactions of the ASAE. Roč. 38, č. 1, s. 259–269. ISSN 0001-2351. Dostupné z: <https://doi.org/10.13031/2013.27838>. [cit. 2025-07-05].

YANG, Xin; GAO, Shichen; SUN, Qian; GU, Xiaohe; CHEN, Tianen; ZHOU, Jingping a PAN, Yuchun, 2022. Classification of Maize Lodging Extents Using Deep Learning Algorithms by UAV-Based RGB and Multispectral Images. online. In: Agriculture. Roč. 12, č. 7, 970, s. 1-16. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/agriculture12070970>. [cit. 2025-05-21].

POUŽITÉ OBRÁZKY

DABASS, Jyoti, 2025. Convolutional Neural Network (CNN) [elektronický obrázek]. In: What are Convolutional Neural Networks (CNNs) [online]. 25. října 2020. Dostupné z: <https://medium.com/@jyotidabass/what-are-convolutional-neural-networks-cnns-456175b5691c>. [cit. 2025-06-25].

INDUTIVELOAD a RONAN, Philip, [b.r.]. Electromagnetic spectrum (modified from original) [elektronický obrázek]. Licence: CC 3.0. Dostupné z: <https://cdn.kastatic.org/ka-perseus-images/1f69f2373d9136ed9a061a3a1b64cbffe3abc9b2.png>; https://commons.wikimedia.org/wiki/File:EM_Spectrum_Properties_edit.svg. [cit. 2025-06-19].

MICASENSE, [b.r.]. MicaSense RedEdge-P Multispectral camera [elektronický obrázek]. In: AgEagle Aerial Systems Inc. [online]. Dostupné z: <https://ageagle.com/drone-sensors/rededge-p-high-res-multispectral-camera/>. [cit. 2025-07-09].

SEZNAM PŘÍLOH

Součástí diplomové práce je sada příloh, které doplňují teoretický a praktický rámec práce. Přílohy zahrnují grafické výstupy statistických analýz z případových studií, vlastní navržené spektrální indexy a sadu softwarových nástrojů vytvořených pro podporu zpracování UAV obrazových dat.

První část příloh tvoří grafy statistických výstupů z případových studií, které znázorňují výsledky klasifikačních metod. Tyto grafy zahrnují klíčové metriky, jako jsou F1-skóre, Kappa koeficient, celková přesnost (Overall Accuracy), přesnost (Precision) a citlivost (Recall).

Druhá část příloh obsahuje tři vlastní navržené spektrální indexy, které byly vyvinuty pro specifické účely klasifikace vegetačního pokryvu, detekce zaplavených oblastí a analýzy poškozených porostů. Tyto indexy (GBRWI, MGLI2 a SNDGR) byly navrženy s cílem maximalizovat kontrast mezi různými typy povrchů a zlepšit přesnost klasifikace na základě RGB a multispektrálních dat. Každý index je podrobně popsán, včetně jeho matematického základu, aplikačních možností a příkladů použití v případových studiích.

Třetí část příloh tvoří sedm softwarových nástrojů, které byly vytvořeny za účelem podpory zpracování UAV obrazových dat – od přípravy a převzorkování rastrových snímků, přes výpočet spektrálních indexů a klasifikačních metrik, až po analýzu metadat a automatizovanou interpretaci výstupů. Vývoj těchto aplikací probíhal ještě před zahájením praktického testování, aby bylo možné zefektivnit základní úlohy zpracování a zajistit jednotné prostředí pro různé typy analýz. V průběhu práce byly nástroje dále rozvíjeny – na základě zpětné vazby z jednotlivých případových studií docházelo k odhalování drobných nedostatků, doplňování funkcionalit a optimalizaci výkonu. Výsledná podoba tak reflektuje praktické potřeby a zkušenosti z reálného nasazení.

Většina nástrojů je vytvořena v jazyce Python, s využitím knihoven jako rasterio, numpy a Pillow, a obsahuje uživatelské rozhraní postavené na knihovnách PySide6 nebo CustomTkinter. Výjimku tvoří dvě webové aplikace, jejichž frontend je založen na technologiích HTML, CSS, JavaScript a EJS. Veřejné repozitáře na GitHub obsahují kompletní zdrojové kódy, návody k použití (README), historii verzí (changelog), jednotlivé commity i přehled nahlášených problémů (issues). Tyto aplikace byly využívány ve všech hlavních etapách práce a představují praktický doplněk metodického rámce této studie, čímž usnadnily automatizaci a zefektivnění zpracování dat.


OBSAH PŘÍLOH

GRAFY A TABULKY STATISTICKÝCH VÝSTUPŮ.....	140
PŘÍLOHA A – PŘÍPADOVÁ STUDIE VRACLAV.....	140
PŘÍLOHA B – PŘÍPADOVÁ STUDIE ALBÁNIE.....	142
PŘÍLOHA C – PŘÍPADOVÁ STUDIE LOUČKY.....	147
PŘÍLOHA D – PŘÍPADOVÁ STUDIE HRÁDEK	152
PŘÍLOHA E – PŘÍPADOVÁ STUDIE ČESTICE.....	155
PŘÍLOHA F – PŘÍPADOVÁ STUDIE ČESTICE II.....	160
NAVRŽENÉ SPEKTRÁLNÍ INDEXY	164
PŘÍLOHA 1 – NAVRŽENÝ SPEKTRÁLNÍ INDEX SNDGR	164
PŘÍLOHA 2 – NAVRŽENÝ SPEKTRÁLNÍ INDEX GBRWI	169
PŘÍLOHA 3 – NAVRŽENÝ SPEKTRÁLNÍ INDEX MGLI2	174
NAVRŽENÉ SOFTWAREVÉ APLIKACE	179
PŘÍLOHA I – GEOSHRINK	179
PŘÍLOHA II – FCC MS IMAGE PROCESSOR.....	180
PŘÍLOHA III – METRICALC.....	181
PŘÍLOHA IV – IMAGEMETALOCATOR	182
PŘÍLOHA V – UAVAREACALC	183
PŘÍLOHA VI – ORTOPHOTOTOOL	184
PŘÍLOHA VII – INTERAKTIVNÍ WEBOVÁ PREZENTACE UAV DAT.....	185
FOTODOKUMENTACE TERÉNNÍHO PRŮZKUMU ÚZEMÍ	186

GRAFY A TABULKY STATISTICKÝCH VÝSTUPŮ

Tato příloha obsahuje grafy F1-skóre, Kappa koeficientu, celkové přesnosti, přesnosti a citlivosti z případových studií a doplňující tabulky přesnosti a citlivosti.

Příloha A – Případová studie Vraclav




Obrázek 65: Uživatelská přesnost – případová studie Vraclav

Zdroj: [vlastní zpracování]

Tabulka 22: Uživatelská přesnost – případová studie Vraclav

Uživatelská přesnost klasifikace (Precision)											
metoda	zkratka	spektrální zvýraznění									průměr
		RGB	TGI	GCC	NGDRI	RGBVI	VARI	EXGI	GLI	MGLI2	
Deep Learning	DL	0,95455	-	-	-	-	-	-	-	-	0,95455
Support Vector Machine	SVM	0,91667	0,96739	0,98864	0,80894	1,00000	1,00000	0,89719	0,80894	1,00000	0,93197
Maximum Likelihood	ML	1,00000	0,87619	0,88413	0,71905	0,87619	0,92119	0,92119	0,91667	0,90341	0,89089
Random Trees	RT	0,83333	0,80032	0,85317	1,00000	0,90262	0,87561	0,85317	0,80032	0,93780	0,87293
K-Nearest Neighbors	KNN	0,78269	0,59801	0,93182	0,85880	0,67500	0,76016	0,88988	0,92045	0,83553	0,80582
ISO cluster	ISO	0,65122	0,97619	0,87500	0,96512	0,67045	0,82738	0,92005	0,85230	0,88206	0,84664
	průměr	0,85641	0,84362	0,90655	0,87038	0,82485	0,87687	0,89630	0,85974	0,91176	0,87150

Zdroj: [vlastní zpracování]



Obrázek 66: Producentova přesnost – případová studie Vraclav


Zdroj: [vlastní zpracování]

Tabulka 23: Producentova přesnost – případová studie Vraclav

Producentova přesnost klasifikace (Recall)											
metoda	zkratka	spektrální zvýraznění									průměr
		RGB	TGI	GCC	NGDRI	RGBVI	VARI	EXGI	GLI	MGLI2	
Deep Learning	DL	0,98864	-	-	-	-	-	-	-	-	0,98864
Support Vector Machine	SVM	0,97674	0,85000	0,95000	0,85349	1,00000	1,00000	0,92674	0,85349	1,00000	0,93450
Maximum Likelihood	ML	1,00000	0,87619	0,78810	0,66429	0,87619	0,88810	0,88810	0,97619	0,83810	0,86614
Random Trees	RT	0,90238	0,72561	0,82561	1,00000	0,83780	0,87561	0,82561	0,72561	0,93780	0,85067
K-Nearest Neighbors	KNN	0,84186	0,56133	0,75000	0,73684	0,62868	0,71053	0,80536	0,73077	0,83553	0,73343
ISO cluster	ISO	0,70217	0,90000	0,87500	0,85000	0,61250	0,77500	0,88750	0,82500	0,78750	0,80163
	průměr	0,90197	0,78263	0,83774	0,82092	0,79103	0,84985	0,86666	0,82221	0,87979	0,84056



Zdroj: [vlastní zpracování]

Příloha B – Případová studie Albánie





Obrázek 67: F1-skóre – případová studie Albánie

Zdroj: [vlastní zpracování]





Obrázek 68: Celková přesnost – případová studie Albánie

Zdroj: [Vlastní zpracování]



Obrázek 69: Kappa index – případová studie Albánie

Zdroj: [vlastní zpracování]





Obrázek 70: Uživatelská přesnost – případová studie Albánie

Zdroj: [vlastní zpracování]

Tabulka 24: Uživatelská přesnost – případová studie Albánie

Uživatelská přesnost klasifikace (Precision)				
metoda	zkratka	spektrální zvýraznění		průměr
		RGB	SNDGR	
Deep Learning	DL	0,98333	0,93333	0,95833
Support Vector Machine	SVM	0,95459	0,89971	0,92715
Maximum Likelihood	ML	0,95106	0,87798	0,91452
Random Trees	RT	0,97887	0,87595	0,92741
K-Nearest Neighbors	KNN	0,89898	0,73611	0,81755
ISO cluster	ISO	0,70244	0,95100	0,82672
	průměr	0,91154	0,87901	0,89528

Zdroj: [vlastní zpracování]



Obrázek 71: Producentova přesnost – případová studie Albánie


Zdroj: [vlastní zpracování]

Tabulka 25: Producentova přesnost – případová studie Albánie

Producentova přesnost klasifikace (Recall)				
		spektrální zvýraznění		
metoda	zkratka	RGB	SNDGR	průměr
Deep Learning	DL	0,99296	0,95878	0,97587
Support Vector Machine	SVM	0,93015	0,92775	0,92895
Maximum Likelihood	ML	0,91868	0,91447	0,91658
Random Trees	RT	0,95313	0,83021	0,89167
K-Nearest Neighbors	KNN	0,87155	0,69678	0,78416
ISO cluster	ISO	0,70738	0,91530	0,81134
	průměr	0,89564	0,87388	0,88476



Zdroj: [vlastní zpracování]

Příloha C – Případová studie Loučky





Obrázek 72: F1-skóre – případová studie Loučky

Zdroj: [vlastní zpracování]





Obrázek 73: Celková přesnost – případová studie Loučky

Zdroj: [Vlastní zpracování]



Obrázek 74: Kappa index – případová studie Loučky

Zdroj: [vlastní zpracování]





Obrázek 75: Uživatelská přesnost – případová studie Loučky

Zdroj: [vlastní zpracování]

Tabulka 26: Uživatelská přesnost – případová studie Loučky

Uživatelská přesnost klasifikace (Precision)				
metoda	zkratka	spektrální zvýraznění		průměr
		RGB	TGI	
Deep Learning	DL	0,96200	0,92900	0,94550
Support Vector Machine	SVM	0,69000	0,65700	0,67350
Maximum Likelihood	ML	0,80500	0,71300	0,75900
Random Trees	RT	0,84900	0,71400	0,78150
K-Nearest Neighbors	KNN	0,87000	0,52800	0,69900
ISO cluster	ISO	0,62900	0,43800	0,53350
	průměr	0,80083	0,66317	0,73200

Zdroj: [vlastní zpracování]



Obrázek 76: Producentova přesnost – případová studie Loučky


Zdroj: [vlastní zpracování]

Tabulka 27: Producentova přesnost – případová studie Loučky

Producentova přesnost klasifikace (Recall)				
metoda	zkratka	spektrální zvýraznění		průměr
		RGB	TGI	
Deep Learning	DL	0,95600	0,94000	0,94800
Support Vector Machine	SVM	0,69000	0,67700	0,68350
Maximum Likelihood	ML	0,80500	0,73800	0,77150
Random Trees	RT	0,85000	0,72100	0,78550
K-Nearest Neighbors	KNN	0,87000	0,52800	0,69900
ISO cluster	ISO	0,64900	0,40800	0,52850
	průměr	0,80333	0,66867	0,73600


Zdroj: [vlastní zpracování]

Příloha D – Případová studie Hrádek




Obrázek 77: F1-skóre – případová studie Hrádek

Zdroj: [vlastní zpracování]




Obrázek 78: Celková přesnost – případová studie Hrádek

Zdroj: [vlastní zpracování]



Obrázek 79: Kappa index – případová studie Hrádek

Zdroj: [vlastní zpracování]




Obrázek 80: Uživatelská přesnost – případová studie Hrádek

Zdroj: [vlastní zpracování]

Tabulka 28: Uživatelská přesnost – případová studie Hrádek

Uživatelská přesnost klasifikace (Precision)		
metoda	zkratka	RGB
Deep Learning - UNET	DL	0,95296
Support Vector Machine	SVM	0,80854
Maximum Likelihood	ML	0,90794
Random Trees	RT	0,86237
K-Nearest Neighbors	KNN	0,81992
ISO cluster	ISO	0,43182
	průměr	0,79726

Zdroj: [vlastní zpracování]



Obrázek 81: Producentova přesnost – případová studie Hrádek


Zdroj: [vlastní zpracování]

Tabulka 29: Producentova přesnost – případová studie Hrádek

Producentova přesnost klasifikace (Recall)		
metoda	zkratka	RGB
Deep Learning - UNET	DL	0,94462
Support Vector Machine	SVM	0,77892
Maximum Likelihood	ML	0,74676
Random Trees	RT	0,71295
K-Nearest Neighbors	KNN	0,75107
ISO cluster	ISO	0,42724
	<i>průměr</i>	0,72693



Zdroj: [vlastní zpracování]

Příloha E – Případová studie Čestice




Obrázek 82: F1-skóre – případová studie Čestice

Zdroj: [vlastní zpracování]





Obrázek 83: Celková přesnost – případová studie Čestice

Zdroj: [vlastní zpracování]



Obrázek 84: Kappa index – případová studie Čestice

Zdroj: [vlastní zpracování]





Obrázek 85: Uživatelská přesnost – případová studie Čestice

Zdroj: [vlastní zpracování]

Tabulka 30: Uživatelská přesnost – případová studie Čestice

Uživatelská přesnost klasifikace (Precision)				
		spektrální zvýraznění		
metoda	zkratka	RGB	GBRWI	průměr
Deep Learning	DL	0,89500	0,76900	0,83200
Support Vector Machine	SVM	0,93660	0,92010	0,92835
Maximum Likelihood	ML	0,87490	0,87740	0,87615
Random Trees	RT	0,84150	0,84350	0,84250
K-Nearest Neighbors	KNN	0,78180	0,75290	0,76735
ISO cluster	ISO	0,77500	0,76340	0,76920
	průměr	0,85080	0,82105	0,83593

Zdroj: [vlastní zpracování]



Obrázek 86: Producentova přesnost – případová studie Čestice


Zdroj: [vlastní zpracování]

Tabulka 31: Producentova přesnost – případová studie Čestice

Producentova přesnost klasifikace (Recall)				
metoda	zkratka	spektrální zvýraznění		průměr
		RGB	GBRWI	
Deep Learning	DL	0,97600	0,87000	0,92300
Support Vector Machine	SVM	0,86840	0,88750	0,87795
Maximum Likelihood	ML	0,77490	0,78260	0,77875
Random Trees	RT	0,78740	0,75720	0,77230
K-Nearest Neighbors	KNN	0,71620	0,67340	0,69480
ISO cluster	ISO	0,72870	0,83520	0,78195
	průměr	0,80860	0,80098	0,80479


Zdroj: [vlastní zpracování]

Příloha F – Případová studie Čestice II




Obrázek 87: F1-skóre – případová studie Čestice II

Zdroj: [vlastní zpracování]




Obrázek 88: Celková přesnost – případová studie Čestice II

Zdroj: [vlastní zpracování]



Obrázek 89: Kappa index – případová studie Čestice II

Zdroj: [vlastní zpracování]




Obrázek 90: Uživatelská přesnost – případová studie Čestice II

Zdroj: [vlastní zpracování]

Tabulka 32: Uživatelská přesnost – případová studie Čestice II

Uživatelská přesnost klasifikace (Precision)		
metoda	zkratka	RGB
Deep Learning - U-NET	DL - U-NET - ResNet50	0,99600
Deep Learning - U-NET	DL - U-NET - VGG16	0,81200
Deep Learning - PSPNet	DL - PSPNet	0,87700
Deep Learning - PSPNet - PointRend	DL - PSPNet - P.R.	0,97100
Deep Learning - DeepLabV3	DL - DeepLabV3	0,86700
Deep Learning - DeepLabV3 - PointRend	DL - DeepLabV3 - P.R.	0,96500
Support Vector Machine	SVM	0,89800
Maximum Likelihood	ML	0,91800
Random Trees	RT	0,87400
Random Trees - depth 100	RT - depth 100	0,80800
K-Nearest Neighbors	KNN	0,66900
ISO cluster	ISO	0,72000
	<i>průměr</i>	0,86458

Zdroj: [vlastní zpracování]



Obrázek 91: Producentova přesnost – případová studie Čestice II

Zdroj: [vlastní zpracování]

Tabulka 33: Producentova přesnost – případová studie Čestice II

Producentova přesnost klasifikace (Recall)		
metoda	zkratka	RGB
Deep Learning - U-NET	DL - U-NET - ResNet50	0,96900
Deep Learning - U-NET	DL - U-NET - VGG16	0,97900
Deep Learning - PSPNet	DL - PSPNet	0,89700
Deep Learning - PSPNet - PointRend	DL - PSPNet - P.R.	0,99600
Deep Learning - DeepLabV3	DL - DeepLabV3	0,98600
Deep Learning - DeepLabV3 - PointRend	DL - DeepLabV3 - P.R.	0,96500
Support Vector Machine	SVM	0,83400
Maximum Likelihood	ML	0,76200
Random Trees	RT	0,81700
Random Trees - depth 100	RT - depth 100	0,72000
K-Nearest Neighbors	KNN	0,61900
ISO cluster	ISO	0,72000
	<i>průměr</i>	0,85533

Zdroj: [vlastní zpracování]

NAVRŽENÉ SPEKTRÁLNÍ INDEXY

Příloha popisuje tři vlastní spektrální indexy (SNDGR, GBRWI, MGLI2) pro klasifikaci UAV dat, včetně jejich konstrukce a přínosu pro analýzu vegetace a poškozených ploch.

Příloha 1 – Navržený spektrální index SNDGR

V rámci zpracování UAV snímků byl pro účely klasifikace požárem zasažené krajiny navržen vlastní spektrální index SNDGR (Stabilized Normalized Difference Green-Red). Tento index byl vyvinut specificky pro zvýšení kontrastu mezi spálenou půdou, vysušenou vegetací a zdravým vegetačním pokryvem, a to za použití výhradně RGB spektrálních dat. Jeho cílem je umožnit efektivní identifikaci oblastí bez vegetace, stejně jako detekci popela, zuhelnatělého povrchu nebo hnědočervených reziduí po požáru, a současně odlišit tyto jevy od vegetace, která zůstala nepoškozená či byla ovlivněna pouze suchem.

Matematická definice

$$\text{SNDGR} = [\text{Green} - (2 \times \text{Red})] / [\text{Green} + (2 \times \text{Red}) + 0,5]$$

kde:

- Green představuje odrazivost v zeleném pásmu,
- Red představuje odrazivost v červeném pásmu ,
- 0,5 je stabilizační konstanta přidaná do jmenovatele pro zvýšení numerické robustnosti,
- 2×Red představuje zvýšenou váhu červeného pásma pro zvýraznění spálené půdy.

Index byl implementován v prostředí ArcGIS Pro prostřednictvím následujícího výrazu pomocí funkce Raster Calculator:

$$\text{Float}(\text{"Green"} - (2 * \text{"Red"})) / \text{Float}(\text{"Green"} + (2 * \text{"Red"}) + 0.5)$$

Vztah k běžným vegetačním indexům

Základní konstrukce vychází z běžně užívaného NGRDI (Normalized Green-Red Difference Index):

$$\text{NGRDI} = (\text{Green} - \text{Red}) / (\text{Green} + \text{Red})$$

Zdroj: [Tucker, 1979]

NGRDI je osvědčeným ukazatelem přítomnosti vegetace. V případě SNDGR byl však tento princip záměrně modifikován pro analýzu půdy a vegetace zasažených požárem:

- Zesílená váha červeného kanálu (2×R) – reflektuje zvýšený odraz červené až hnědé složky ve spálených oblastech (spálená půda často vykazuje vyšší intenzitu R než G)
- Stabilizační konstanta 0,5 – zabraňuje dělení malými hodnotami a snižuje vliv šumu zejména v oblastech bez vegetace.

- Asymetrie konstrukce – potlačuje falešně pozitivní hodnoty ve slabě vegetovaných plochách.

Spektrální chování spálené půdy v RGB datech

Spálená půda má v RGB obrazových datech specifický spektrální podpis:

- Nízké hodnoty v zelené složce (kvůli destrukci chlorofylu).
- Zvýšené hodnoty červené nebo červeno-hnědé složky (v důsledku zbytkového žáru, popela, oxidů železa a minerálů).
- Často zvýšená heterogenita a struktura povrchu, což snižuje spolehlivost klasických NDVI-typových indexů odvozených z NIR dat.

Vzhledem k absenci blízkého infračerveného pásma, který by jinak výrazně zvýšil schopnost detekce živé vegetace a popožárních změn, je SNDGR navržen jako účelový nástroj optimalizovaný pro RGB-only snímkování.

Interpretace hodnot indexu SNDGR

Výsledné hodnoty indexu SNDGR umožňují odlišit základní spektrální typy povrchu v popožární krajině následujícím způsobem:

- Kladné hodnoty (např. +0,2 až +0,6) odpovídají plochám s vyšším podílem zelené složky, což značí zdravou, nespálenou vegetaci nebo porost, který nebyl požárem významně zasažen.
- Hodnoty blízké nule zpravidla indikují přechodové oblasti – typicky se jedná o řídké zarostlé plochy, suchou travní vegetaci nebo částečně degradovaný porost.
- Záporné hodnoty (např. -0,4 až -0,1) jsou charakteristické pro spálenou půdu, obnažený povrch bez vegetace nebo místa s přítomností popela, zuhelnatělých zbytků a hnědočervených reziduí po požáru.

Tato škála hodnot byla využita k vizuálnímu zvýraznění stavu povrchu území po požáru, jak je znázorněno na přiloženém výstupním snímku. Jasně oblasti (světle šedé až bílé) reprezentují zachovalou vegetaci, zatímco tmavé plochy (tmavě šedé až černé) poukazují na rozsáhle poškozené nebo zcela spálené lokality.


Výhody spektrálního indexu SNDGR ve zpracování UAV dat

Spektrální index SNDGR (Stabilized Normalized Difference Green-Red) byl navržen jako jednoduchý nástroj pro zvýraznění spálených a degradovaných ploch za použití pouze RGB spektrálních složek. Přestože některé pokročilé klasifikační metody (např. Deep Learning) dosahují vyšších hodnot přesnosti přímo na původních RGB datech, index SNDGR nabízí specifické výhody, zejména při rychlém a automatizovaném zpracování bez trénovacích dat.

- Index SNDGR prokázal mimořádnou účinnost při neřízené klasifikaci metodou ISO Cluster, kde výrazně překonal RGB vstupy (F1-skóre 91,5 % oproti 70,5 %). Tato výkonnost je důsledkem jasně definovaných spektrálních hranic mezi spáleným povrchem a vegetací, které ISO Cluster dokázal efektivně využít při seskupování pixelů do tříd.
- Díky své jednoduché konstrukci a výpočtu z běžně dostupných RGB dat je index vhodný pro rychlou a provozně nenáročnou klasifikaci, a to i na méně výkonných zařízeních či v prostředích s omezeným výpočetním výkonem.
- SNDGR byl navržen s důrazem na detekci spálené půdy a silně degradované vegetace, a to díky zvýšené váze červené složky ($2 \times R$), která reaguje na hnědé, načervenalé a popelové odstíny typické pro požářiště.
- Díky přidané konstantě ve jmenovateli (+0,5) je index odolný vůči šumu v oblastech s nízkou intenzitou odrazu, což je výhodné při práci se zastíněnými nebo řídkými vegetačními plochami.
- Výsledné hodnoty v rozsahu -1 až $+1$ umožňují snadnou vizuální interpretaci i nastavení prahových hodnot pro klasifikaci bez nutnosti složité kalibrace.


Z těchto důvodů se index SNDGR ukazuje jako efektivní a praktický nástroj zejména pro rychlou orientační klasifikaci a mapování degradace vegetace v post-katastrofických scénářích, kde není možné využít složitější modely nebo rozsáhlá trénovací data.

SNÍMEK SE SPEKTRÁLNÍM ZVÝRAZNĚNÍM SNDGR spálený porost Albánie



Zdroj: [vlastní zpracování]

ZÁKLADNÍ SNÍMEK VE VIDITELNÉM RGB SPEKTRU spálený porost Albánie



Příloha 2 – Navržený spektrální index GBRWI

Pro účely detekce zaplavených oblastí na základě UAV RGB snímků byl navržen vlastní spektrální index GBRWI (Green-Blue-Red Water Index). Tento index byl vytvořen jako modifikace běžně používaného NGBDI (Normalized Green-Blue Difference Index), přičemž jeho konstrukce zohledňuje specifika kalné či bahnité vody typické pro povrchové záplavy. Cílem indexu je umožnit přesnější a stabilnější identifikaci vodních ploch vzniklých po příválových deštích či v důsledku povodní.

Matematická definice

$$\text{GBRWI} = [(1,2 \times \text{Green}) + (0,8 \times \text{Blue}) - \text{Red}] / [(1,2 \times \text{Green}) + (0,8 \times \text{Blue}) + \text{Red} + 0,5]$$

kde:

- Red představuje odrazivost v červeném pásmu,
- Green představuje odrazivost v zeleném pásmu,
- Blue představuje odrazivost v modrém pásmu,
- 1,2 a 0,8 jsou váhové koeficienty pro zdůraznění vegetace a oslabení vlivu vody,
- 0,5 je stabilizační konstanta ve jmenovateli pro eliminaci šumu a dělení malými hodnotami.

Výpočet indexu byl realizován v prostředí ArcGIS Pro pomocí standardního výrazu v Raster Calculatoru.

$$\text{Float}((1.2 * \text{"Green"} + 0.8 * \text{"Blue"} - \text{"Red"})) / \text{Float}((1.2 * \text{"Green"} + 0.8 * \text{"Blue"} + \text{"Red"} + 0.5))$$

Vztah k původnímu indexu NGBDI

Základní struktura indexu GBRWI vychází z původního NGBDI (Normalized Green-Blue Difference Index), který je definován jako:

$$\text{NGBDI} = (\text{Green} - \text{Blue}) / (\text{Green} + \text{Blue})$$

Zdroj: [Bannari et al., 1995]

Tento index je příbuzný s NGRDI (Normalized Green-Red Difference Index), kde je červený kanál nahrazen modrým s cílem využít odlišného spektrálního chování vegetace a vody v oblasti viditelného světla. NGRDI se standardně zapisuje jako:

$$\text{NGRDI} = (\text{Green} - \text{Red}) / (\text{Green} + \text{Red})$$

Zdroj: [Tucker, 1979]

Zatímco vegetace má vyšší odrazivost v zeleném pásmu, voda, zejména opticky čistá, odráží více v modré složce.

Index GBRWI představuje cílenou modifikaci NGBDI pro detekci zaplavené půdy a bahnitých povrchů. Na rozdíl od čisté vody, která má typicky výrazný modrý odraz, záplavová voda obsahuje sedimenty, rozptýlený kal a organický materiál, což mění její spektrální charakteristiku – dochází ke snížení dominance modré složky a často i k mírnému zvýšení odrazivosti v zeleném pásmu.

Na základě praktických testů na UAV datech se však ukázalo, že klasické NGBDI zvýrazňuje vodní plochy příliš světlým odstínem, podobně jako vegetaci. Tím dochází ke zhoršenému rozlišení mezi mokrým a vegetačně pokrytým terénem. Index GBRWI proto představuje cílenou úpravu, která navíc zahrnuje červenou složku pro lepší potlačení odezvy kalné vody a bahnitých povrchů. Více zohledňuje rozdíly mezi:

- vegetací (vysoké G, nízké R),
- vodou (nižší G, různá B, vyšší R u kalných oblastí),
- a suchým terénem (dominantní červená složka).

Z těchto důvodů byla modrá složka v konstrukci indexu záměrně váhově oslabena. Tato úprava reflektuje empiricky pozorované rozdíly mezi opticky čistými vodními plochami a záplavovou vodou, přičemž:

- zvyšuje kontrast mezi zaplaveným a vegetačním povrchem,
- snižuje falešné zvýraznění stínů a stromových korun,
- stabilizuje výsledek v proměnlivých světelných podmínkách.

Tato modifikace zároveň reaguje na omezení NGBDI identifikovaná v literatuře (např. Zhang et al., 2019)², která upozorňuje, že klasický poměr G/B může být náchylný k falešným detekcím ve stinných nebo vlhkých oblastech. Váhová korekce modré složky v indexu GBRWI tento jev výrazně potlačuje a činí index vhodnější pro detekci povrchové vody s odlišnými optickými vlastnostmi, než má stabilní vodní prostředí.

Spektrální chování záplavových oblastí v RGB datech

Zaplavené plochy mají v RGB datech odlišný spektrální podpis oproti stabilním vodním tělesům:

- Vyšší odrazivost v zeleném pásmu, způsobená sedimenty a organickým materiálem,
- utlumený podíl modré složky (vliv zakalení vody),

²ZHANG, Wen, Zhiwei WANG, Hongzhi WU, Xuelian SONG, Xirui RUAN, Qian WANG, Kejian WEN, Junjiang MENG, Fuxiang LI a Jiaofa LIAO. Study on the Monitoring of Karst Plateau Vegetation with UAV Aerial Photographs and Remote Sensing Images. IOP Conference Series: Earth and Environmental Science. 2019, 384, 012188. ISSN 1755-1315. Dostupné z: <https://doi.org/10.1088/1755-1315/384/1/012188> [cit. 2025-07-07]

- vyšší odrazivost v červené složce oproti vegetaci,
- menší kontrast, což znesnadňuje klasifikaci při použití běžných indexů.

Z těchto důvodů je index GBRWI navržen jako specializovaný nástroj optimalizovaný pro detekci záplavových jevů, vlhkých ploch a mokrých povrchů. Díky své jednoduchosti a odolnosti vůči šumu jej lze efektivně využít i při UAV snímkování pouze v RGB spektru.

Interpretace hodnot indexu GBRWI

Výsledné hodnoty indexu GBRWI umožňují identifikaci zaplavených oblastí podle následujícího spektrálního chování:

- Záporné hodnoty (např. $-0,6$ až $-0,1$) odpovídají plochám s vyšší intenzitou modré složky, typicky tedy vodním plochám včetně záplavové vody, ale i stinným oblastem.
- Hodnoty blízké nule představují přechodové zóny nebo plochy s vlhkým povrchem, případně řídkým vegetačním pokryvem.
- Kladné hodnoty (např. $+0,1$ až $+0,6$) typicky označují nezaplavený, suchý terén s vyšší intenzitou odrazu v zeleném pásmu.

Díky této škále hodnot lze jednoduše vizualizovat a interpretovat rozložení záplavových jevů a vlhkosti v terénu.

Výhody spektrálního indexu GBRWI ve zpracování UAV dat


Spektrální index GBRWI byl navržen jako cílený nástroj pro detekci záplavových jevů pomocí RGB dat, přičemž prokázal svou efektivitu zejména u některých metod klasifikace a vizuální interpretace:

- Neřízená klasifikace ISO Cluster dosáhla při použití indexu vyšší přesnosti než při práci s RGB daty (F1-skóre 79,2 % oproti 74,6 %), což potvrzuje, že GBRWI výrazně zvýrazňuje spektrální hranice a umožňuje efektivnější shlukování.
- Metoda SVM využila výhod indexu a dosáhla zlepšené shody s referenčními daty (Kappa zvýšena z 0,793 na 0,805), což ukazuje na schopnost metody adaptovat se na transformovaný spektrální prostor.
- Díky své jednoduchosti je index vhodný pro rychlou orientační klasifikaci, a to i v prostředích bez trénovacích dat nebo tam, kde je třeba pracovat s omezeným výpočetním výkonem.
- Vizuální interpretace záplavových oblastí je výrazně usnadněna, neboť GBRWI zvýrazňuje rozdíly mezi vlhkými a suchými oblastmi lépe než samotné RGB složky.
- Normalizovaný rozsah hodnot (-1 až $+1$) umožňuje snadné nastavení prahových hodnot a vizualizaci pomocí diverzních barevných ramp.

Naopak u metod silně závislých na texturách a prostorových vzorcích (např. Deep Learning) se ukázalo, že transformace do indexu může vést ke ztrátě jemných vizuálních detailů, což se projevilo poklesem klasifikační přesnosti.

Praxe ukázala, že index velmi dobře zvýrazňuje volně stojící kaluže, vlhká místa i vegetaci, avšak může mít omezenou schopnost rozlišit stíny vržené na vodní hladinu – ty byly v některých případech klasifikovány jako vegetace. Z tohoto důvodu je index GBRWI zvláště vhodný pro mapování plochých luk a zemědělských polí, kde je minimální zastínění od stromů či okolní vegetace.

SNÍMEK SE SPEKTRÁLNÍM ZVÝRAZNĚNÍM GBRWI pole po povodni Čestice



$$\text{GBRWI} = [(1,2 \times \text{Green}) + (0,8 \times \text{Blue}) - \text{Red}] / [(1,2 \times \text{Green}) + (0,8 \times \text{Blue}) + \text{Red} + 0,5]$$



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

Zdroj: [vlastní zpracování]

ZÁKLADNÍ SNÍMEK VE VIDITELNÉM RGB SPEKTRU pole po povodni Čestice

Red: Band_1
Green: Band_2
Blue: Band_3



0 100 200 m



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

Zdroj: [vlastní zpracování]

Příloha 3 – Navržený spektrální index MGLI2

V rámci zpracování UAV snímků byl pro účely klasifikace vegetačního pokryvu navržen vlastní spektrální index MGLI2 (Modified Green Leaf Index 2). Tento index vychází z původního GLI2 (Green Leaf Index 2) a rozšiřuje jeho konstrukci s cílem potlačit falešně světlé reakce poškozené řepky a zároveň zesílit kontrast plevelných rostlin. Úprava se zaměřuje na redukci přirozeně negativního vlivu modré složky (stíny, odlesky) a na penalizaci přebytkového červeného odrazu typického pro suchou či stresovanou vegetaci, čímž zvyšuje robustnost indexu vůči proměnlivým světelným podmínkám.

Matematická definice

$$\text{MGLI2} = [1,6 \times (\text{Green} - \text{Red}) + 0,9 \times (\text{Green} - \text{Blue}) - 0,4 \times \text{Red}] / (1,6 \times \text{Green} + 0,5 \times \text{Red} + 2,5 \times \text{Blue})$$

kde:

- Red představuje odrazivost v červeném pásmu,
- Green představuje odrazivost v zeleném pásmu,
- Blue představuje odrazivost v modrém pásmu.

Interpretace koeficientů:

- $1,6 \times (\text{Green} - \text{Red})$ posiluje rozdíl mezi zelenou odrazivostí a červenou absorpcí chlorofylu (zdravá vegetace).
- $0,9 \times (\text{Green} - \text{Blue})$ dodává váhu rozdílu vůči modré složce, avšak s menším vlivem než hlavní zeleno-červená komponenta.
- $-0,4 \times \text{Red}$ penalizuje nadměrný červený odraz (suchá, poškozená či stárnoucí vegetace).
- $1,6 \times \text{Green}$ zachovává dominantní roli zelené složky i ve jmenovateli.
- $0,5 \times \text{Red}$ snižuje relativní váhu červené v jmenovateli a zvyšuje kontrast zdravé vegetace.
- $2,5 \times \text{Blue}$ výrazně potlačuje vliv modravých stínů a odlesků, stabilizuje index v heterogenním osvětlení.

Výpočet indexu byl realizován v prostředí ArcGIS Pro pomocí následujícího výrazu v Raster Calculatoru:

```
Float((1.6 * ("Green" - "Red") + 0.9 * ("Green" - "Blue") - 0.4 * "Red")) /  
Float(1.6 * "Green" + 0.5 * "Red" + 2.5 * "Blue")
```

Pro dosažení maximální vizuální čitelnosti a kontrastu výsledného rastru se doporučuje v symbologii zvolit metodu Stretch → Percent Clip.

Vztah k původnímu indexu GLI a GLI2

Základní struktura MGLI2 vychází z původního indexu GLI a GLI2.

Původní GLI (Green Leaf Index) je definován jako:

$$GLI = (2 \times G - R - B) / (2 \times G + R + B)$$

Zdroj: [Gobron et al., 2000]

Index GLI2 rozšiřuje tento vztah následovně:

$$GLI2 = (G - R) + (G - B) / (2 \times G + R + B)$$

Zdroj: [Louhaichi et al., 2001]

MGLI2 dále upravuje váhy jednotlivých složek:

1. Čítec:

- posiluje rozdíl $(G - R)$ koeficientem 1,6,
- mírně zvyšuje vliv $(G - B)$ (0,9),
- zavádí zápornou vazbu na R ($-0,4 R$).

2. Jmenovatel:

- relativně snižuje váhu R (0,5 R),
- výrazně zvyšuje váhu B (2,5 B).

Tato kombinace zvyšuje kontrast plevele (světlé hodnoty) oproti poškozené či slabé vegetaci (tmavé hodnoty) a současně omezuje citlivost na stínové či vlhkostní artefakty.

Spektrální chování vegetace v RGB datech

Zdravá vegetace má v RGB spektru:

- vyšší hodnoty v zeleném pásmu díky přítomnosti chlorofylu,
- nižší odrazivost v červeném pásmu,
- proměnlivou hodnotu v modrém pásmu, zkreslenou stínem nebo vlhkostí.

MGLI2 díky upravené konstrukci zvýrazňuje zelenou komponentu, tlumí vliv červené složky a vyrovnává modrou odezvu. Tím dochází ke stabilnějším výsledkům i v podmínkách s heterogenním osvětlením nebo u přechodových vegetačních typů.

Interpretace hodnot indexu MGLI2

Hodnoty indexu MGLI2 lze interpretovat následovně:

- Kladné hodnoty (typicky +0,2 až +0,8) odpovídají silně porostlým oblastem s převahou zeleného odrazu.

- Hodnoty kolem nuly představují neutrální nebo přechodové zóny, jako je řídká vegetace, suché traviny nebo mozaikovitě plochy.
- Záporné hodnoty ($-0,3$ až $-0,1$) indikují povrchy bez vegetace, odkrytý substrát, zhutněnou půdu nebo zastíněné plochy.

Výhody spektrálního indexu MGLI2 ve zpracování UAV dat


Index MGLI2 byl testován v rámci případové studie jako spektrální zvýraznění pro vegetační klasifikaci. Ve srovnání s jinými RGB indexy (např. VARI, TGI nebo RGBVI) vykázal vysokou stabilitu a výbornou využitelnost zejména u řízených metod klasifikace:

- Support Vector Machine dosáhla v některých scénách při použití MGLI2 lokálních maxim F1-skóre až 1,0, což značí výborné oddělení vegetačních tříd i v komplikovanějších podmínkách.
- Maximum Likelihood rovněž vykázala vysokou přesnost, díky stabilní konstrukci indexu a vhodné distribuci hodnot ve třídách.
- Neřízená metoda ISO Cluster těžila z MGLI2 zejména v mozaikovitém prostředí, kde index pomohl oddělit vegetaci v přechodových oblastech.

Z pohledu spektrální výpovědní hodnoty se index MGLI2 potvrdil jako spolehlivý nástroj pro zvýraznění vegetace, včetně nízko rostoucích plodin, plevelů a přechodových forem, snižující vliv stínů, osvětlení i barevné interference z pozadí. Jeho konstrukce založená pouze na RGB složkách z něj činí vhodný nástroj i pro rychlou orientační analýzu vegetačního stavu bez nutnosti multispektrálních dat.

SNÍMEK SE SPEKTRÁLNÍM ZVÝRAZNĚNÍM MGLI2 poškozená úroda řepky olejky Vraclav

0,150142 plevel
-0,1514372 zasažená úroda



$$\text{MGLI2} = \frac{1,6 \times (\text{Green} - \text{Red}) + 0,9 \times (\text{Green} - \text{Blue}) - 0,4 \times \text{Red}}{(1,6 \times \text{Green} + 0,5 \times \text{Red} + 2,5 \times \text{Blue})}$$


0 15 30 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

Zdroj: [vlastní zpracování]

ZÁKLADNÍ SNÍMEK VE VIDITELNÉM RGB SPEKTRU poškozená úroda řepky olejky Vraclav

Red: Band_1
Green: Band_2
Blue: Band_3



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

Zdroj: [vlastní zpracování]

NAVRŽENÉ SOFTWAREVÉ APLIKACE

Příloha představuje sedm vlastních softwarových nástrojů v Pythonu a webových technologiích pro zpracování UAV dat, včetně jejich zdrojových kódů a dokumentace na GitHub.

Příloha I – GeoShrink



<https://github.com/Jakub-Espandr/GeoShrink>


Aplikace GeoShrink je nástroj určený pro konverzi a optimalizaci geoprostorových rastrových dat ve formátu GeoTIFF. Hlavním účelem aplikace je převod velkých GeoTIFF souborů do kompaktnějšího PNG formátu s možností redukce velikosti, což je užitečné především pro sdílení a prohlížení snímků z UAV, satelitů nebo k dálkovému průzkumu.

Aplikace disponuje intuitivním grafickým rozhraním postaveným na knihovně CustomTkinter, které umožňuje snadný výběr vstupních GeoTIFF souborů (podporuje přípony .tif a .tiff) a specifikaci výstupního adresáře. Uživatel může prostřednictvím interaktivního posuvníku nastavit faktor škálování v rozsahu od 0,1 do 0,8, čímž přesně kontroluje výslednou velikost a rozlišení výstupního souboru.

Klíčovou funkcí je real-time odhad parametrů výstupního souboru, který zobrazuje předpokládané rozlišení a velikost souboru ještě před zahájením konverze. Samotné zpracování využívá pokročilé algoritmy včetně vysokojakostního LANCZOS převzorkování pro zachování kvality obrazu při změně velikosti a podporuje zpracování vícepásmových rastrových dat.

Aplikace je optimalizována pro výkon pomocí multi-threadingu, což zajišťuje plynulý chod uživatelského rozhraní i při zpracování rozsáhlých datových sad. Během konverze poskytuje vizuální feedback prostřednictvím progress baru se statusovými zprávami a umožňuje uživateli operaci kdykoliv přerušit. Nástroj je implementován v Pythonu s využitím specializovaných knihoven pro geospatial zpracování dat jako rasterio, numpy a Pillow.

Příloha II – FCC MS Image Processor



<https://github.com/Jakub-Espandr/FCCImageProcessor>



<https://flycamczech-imageprocessor.eu/>

Aplikace FCC MultiSpectral Image Processor je nástroj navržený pro analýzu multispektrálních UAV snímků s možností výpočtu a vizualizace více než 50 vegetačních indexů. Hlavní funkcionalita zahrnuje import a zpracování zarovnaných obrazových pásem z modifikovaných kamerových sestav nebo UAV senzorů. Aplikace podporuje výpočet rozsáhlé škály spektrálních indexů používaných pro analýzu zdraví rostlin a pokryvu půdy, včetně nejčastěji využívaných indexů jako NDVI, GNDVI, SAVI, VARI a dalších.

Aplikace poskytuje pokročilé vizualizační nástroje s real-time zobrazením zpracovaných indexů pomocí vědecky orientovaných barevných map a překryvných vrstev. Uživatelé mohou interaktivně přepínat mezi různými indexy a okamžitě sledovat změny ve vizualizaci dat. Systém umožňuje export výsledků jak ve formě zpracovaných obrázků pro další analýzu v externích nástrojích.

Příloha III – MetriCalc



<https://github.com/Jakub-Espandr/MetriCalc>

Aplikace MetriCalc je nástroj navržený pro výpočet klíčových statistických metrik z konfuzních matic exportovaných z ArcGIS Pro nebo jiných platforem. Aplikace je postavena na frameworku PySide6, který zajišťuje rychlé a nativní uživatelské prostředí s responzivním designem organizovaným do segmentovaných záložek pro jednotlivé a dávkové zpracování.

Hlavní funkcionalita zahrnuje čtení konfuzních matic ze souborů CSV s oddělovačem středník a výpočet kompletní sady klasifikačních metrik. Aplikace dokáže vypočítat přesnost (User Accuracy), senzitivitu (Producer Accuracy), F1-score, celkovou přesnost a Kappa index, přičemž všechny metriky jsou reportovány jak pro jednotlivé třídy, tak jako makro průměr.

Významnou funkcionalitou je podpora internacionalizace s možností okamžitého přepínání mezi českým a anglickým jazykem jak pro uživatelské rozhraní, tak pro výstupní data bez nutnosti restartování aplikace. Aplikace podporuje dávkové zpracování všech CSV souborů ve vybrané složce se dvěma režimy exportu – buď jeden Excel soubor pro každý vstup, nebo jeden Excel soubor s více listy.

Export do formátu XLSX obsahuje lokalizované hlavičky metrik a je strukturován do dvou listů na každý výsledek – list Metrics s vypočtenými hodnotami a list Data s původní konfuzní maticí. Celý proces zpracování běží asynchronně v pozadí pomocí separátních threadů, což udržuje uživatelské rozhraní responzivní i při zpracování velkých dat, přičemž uživatel má k dispozici real-time progress bar s možností zrušení operace.

Příloha IV – ImageMetaLocator



<https://github.com/Jakub-Espandr/ImageMetaLocator>

Aplikace ImageMetaLocator je nástroj určený pro extrakci GPS metadat z obrázků a vizualizaci jejich polohy na interaktivní mapě. Aplikace podporuje drag-and-drop workflow, reverzní geokódování a plynulou interakci pro prohlížení souřadnic, dat a lokačních informací fotografií.


Klíčovou funkcionalitou je automatický výpočet skutečné výšky letu dronu nad terénem pomocí GPS nadmořské výšky a dat o terénní elevaci s automatickou detekcí a varováním při nepřesných datech o výšce letu. Aplikace podporuje nahrávání ortofoto TIFF souborů pro extrakci skutečného rozlišení mapy a přesné výpočty s využitím fotogrammetrické formule $\text{Height} = (\text{Map_GSD} / \text{Drone_GSD}) \times \text{Drone_Height}$.

Nástroj obsahuje předkonfigurované profily pro DJI drony včetně Phantom 4 PRO (1,36 cm/px při 50 m), Phantom 4 (2,19 cm/px při 50 m), Mavic 2 PRO (1,17 cm/px při 50 m) a Mavic 2 ZOOM (1,82 cm/px při 50 m), s možností manuálního nastavení pro vlastní drony. Aplikace umožňuje manuální úpravu vypočtených výšek v případě nesprávných hodnot a poskytuje tlačítko pro přepočítání dostupné kdykoliv.

Interaktivní mapa využívá OpenStreetMap viewer se zobrazením GPS pozice pomocí špendlíku a reverzní geokódování pomocí geopy pro převod souřadnic na čitelné adresy. Aplikace nabízí click-to-copy funkcionalitu pro kopírování adresy, data fotografie nebo souřadnic jedním kliknutím a přepínání formátu souřadnic mezi decimálním a WGS 84 / UTM zone formátem.

Export do PDF generuje reporty s původním obrázkem, metadaty a mapou polohy. Aplikace integruje několik elevation API pro přesná terénní data, poskytuje bezpečnostní varování pro záporné výšky nebo výšky nad 120 m a zahrnuje live status připojení k online službám.

Příloha V – UAVAreaCalc



<https://github.com/Jakub-Espandr/UAVAreaCalc>

Aplikace UAVAreaCalc je nástroj určený pro výpočet ploch v GeoTIFF souborech a jejich porovnání s uživatelem definovanými oblastmi zájmu (ROI) ze Shapefile souborů. Aplikace je navržena pro rychlou validaci a vizualizaci pokrytí leteckých snímků a analýzu zón přímo z vysokorozlišovacích rastrových dat s celosvětovou geografickou podporou.

Klíčovou funkcionalitou je výpočet plochy viditelných oblastí z TIFF snímků s alfa kanálem a celkové plochy z Esri Shapefile polygonů s podporou jednotek v hektarech nebo čtverečních metrech. Aplikace poskytuje pokročilou celosvětovou geografickou podporu s dynamickým výběrem CRS, který automaticky určuje optimální UTM souřadnicový systém pro jakoukoliv geografickou polohu s podporou všech UTM zón (1–60) pro severní i jižní polokouli.

Vizualizační systém využívá downsampled TIFF náhled s vysokorychlostním renderováním a překrývá dva barevně odlišené poloprůhledné polygony – červený pro rozsah TIFF masky a modrý pro ROI ze shapefile.

Export vysokého rozlišení umožňuje generování high-DPI PNG obrázků s volitelnými překryvy ploch (TIFF a ROI polygony) a měřítkovými překryvy (informace o šířce, výšce a ploše) pro výstupy vhodné pro reporty a prezentace. Uživatelské rozhraní je postaveno na intuitivním GUI v PySide6 s interaktivními dialogy pro výběr souborů, real-time výstupem ploch a přepínačem jednotek.

Příloha VI – OrthophotoTool



<https://github.com/Jakub-Espandr/OrthophotoTool>


Aplikace OrthophotoTool je nástroj navržený pro analýzu a vizualizaci metadat z TIFF a JSON souborů, především pro dronové snímkování. Poskytuje uživatelsky přívětivé rozhraní pro načítání, zpracování a kompilaci metadat, což usnadňuje správu a interpretaci velkých datových sad s důrazem na výpočet Ground Sample Distance (GSD) rozlišení.

Hlavní funkcionalita zahrnuje načítání a zobrazování TIFF metadat společně s načítáním a zobrazováním kamerových metadat z JSON souborů. Klíčovou vlastností je schopnost párování kamerových kódů s modely dronů pomocí předem definovaného JSON souboru, což umožňuje automatickou identifikaci použitého zařízení na základě technických specifikací kamery.

Aplikace umožňuje kompilaci a kopírování výstupního souhrnu do schránky pro snadné sdílení nebo další zpracování výsledků analýzy. Uživatelské rozhraní je postavené na frameworku PyQt5 pro stabilní a responzivní chování. Workflow aplikace je intuitivní – uživatel postupně načte TIFF soubor pomocí tlačítka „Load TIFF“, následně JSON soubor s kamerovými metadaty pomocí „Load JSON“, zpracuje soubory tlačítkem „Process Files“ pro zobrazení metadat, a nakonec vygeneruje souhrn pomocí „Compile Output“, který je automaticky zkopírován do schránky. Funkce reset (🔄) umožňuje vymazání současného stavu a restart procesu.

Nástroj je specificky zaměřen na výpočet GSD rozlišení, což je kritický parametr pro pochopení prostorového rozlišení leteckých snímků a je nezbytný pro správnou interpretaci a další zpracování ortofoto dat v geospatial aplikacích.

Příloha VII – Interaktivní webová prezentace UAV dat



<https://github.com/Jakub-Espandr/UAVThesisWeb>



<https://uav.flycamczech-imageprocessor.eu/>

V rámci diplomové práce byla vyvinuta moderní webová aplikace UAVThesisWeb, která slouží k interaktivnímu zobrazení, porovnání a interpretaci výsledků klasifikace obrazových dat získaných bezpilotním leteckým snímáním. Aplikace je navržena jako podpůrný nástroj pro vizualizaci výstupů ze všech sedmi případových studií uvedených v práci a současně reflektuje praktické požadavky na intuitivní přístup k rozsáhlým klasifikačním výstupům.

Frontend aplikace je implementován pomocí HTML, CSS, JavaScript a EJS, zatímco backend běží na Node.js/Express. Aplikace je plně responzivní, optimalizovaná pro desktop i mobilní zařízení a využívá moderní prvky UI/UX jako glassmorphism efekty, vlastní typografii, hardwarovou akceleraci a pokročilou správu paměti (lazy loading, image cache, automatické čištění).

Každá případová studie je reprezentována samostatnou složkou obsahující výstupy jednotlivých metod klasifikace včetně spektrálních zvýraznění, příslušné tabulky metrik a přehledové obrázky pro lepší orientaci v území.

FOTODOKUMENTACE TERÉNNÍHO PRŮZKUMU ÚZEMÍ



Obrázek 92: Terénní průzkum ZÚ – Vraclav

Zdroj: [vlastní zpracování]



Obrázek 93: Terénní průzkum ZÚ – Albánie

Zdroj: [vlastní zpracování]



Obrázek 94: Terénní průzkum ZÚ – Loučky

Zdroj: [vlastní zpracování]



Obrázek 95: Letecký průzkum ZÚ (DJI Mini 3 Pro) – Čestice

Zdroj: [vlastní zpracování]



Obrázek 96: DJI Phantom 4 PRO v misi

Zdroj: [vlastní zpracování]