

Česká zemědělská univerzita v Praze



Česká
zemědělská
univerzita
v Praze

Fakulta životního prostředí

Katedra prostorových věd

**Doplnění chybějící obrazové informace
fragmentované UAV ortomozaiky pomocí
satelitních dat**

Diplomová práce

Vedoucí diplomové práce: Ing. Jan Komárek, Ph.D.

Autor diplomové práce: Bc. Ondřej Sejk

2024

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Ondřej Sejk

Prostorové vědy v životním prostředí

Název práce

Doplnění chybějící obrazové informace fragmentované UAV ortomozaiky pomocí satelitních dat

Název anglicky

Supplementing missing image information of fragmented UAV orthomosaics using satellite data

Cíle práce

Cílem práce je ověřit využitelnost satelitních dat pro doplnění obrazové informace fragmentované UAV ortomozaiky, resp. zjištění konzistentnosti a interoperability obrazových dat pořízených UAV a optickými satelity.

1906

Metodika

Autor práce zajistí potřebná vstupní obrazová data. Provede jejich nutné předzpracování, mozaikování, georeferencování a další nezbytné kroky. Autor nasimuluje fragmentaci UAV ortomozaiky s ohledem na rozdílné typy krajinného pokryvu. Doplní chybějící UAV data satelitními snímky a statisticky vyhodnotí jejich shodu, resp. míru vzájemného vztahu s ohledem na odlišné prostorové a spektrální rozlišení dat. Autor stanoví závěry stran konzistence a možné interoperability obou datových zdrojů, kriticky zhodnotí známé i potencionální nejistoty a konstatuje aplikovatelné závěry.

Doporučený rozsah práce

40-60 stran

Klíčová slova

UAV, Planet, obrazová korelace, fragmentace obrazu, datová konzistence

Doporučené zdroje informací

- Chen, J., Zhu, X., Vogelmann, J. E., Gao, F., & Jin, S. (2011). A simple and effective method for filling gaps in Landsat ETM+ SLC-off images. *Remote sensing of environment*, 115(4), 1053-1064.
- Jiang, J., Johansen, K., Tu, Y. H., & McCabe, M. F. (2022). Multi-sensor and multi-platform consistency and interoperability between UAV, Planet CubeSat, Sentinel-2, and Landsat reflectance data. *GIScience & Remote Sensing*, 59(1), 936-958.
- Kandasamy, S., Baret, F., Verger, A., Neveux, P., & Weiss, M. (2013). A comparison of methods for smoothing and gap filling time series of remote sensing observations—application to MODIS LAI products. *Biogeosciences*, 10(6), 4055-4071.
- Pereira, F. R. D. S., Dos Reis, A. A., Freitas, R. G., Oliveira, S. R. D. M., Amaral, L. R. D., Figueiredo, G. K., ... & Magalhães, P. S. (2023). Imputation of Missing Parts in UAV Orthomosaics Using PlanetScope and Sentinel-2 Data: A Case Study in a Grass-Dominated Area. *ISPRS International Journal of Geo-Information*, 12(2), 41.
- Rossi, R. E., Dungan, J. L., & Beck, L. R. (1994). Kriging in the shadows: geostatistical interpolation for remote sensing. *Remote Sensing of Environment*, 49(1), 32-40.
- Siabi, N., Sanaeinejad, S. H., & Ghahraman, B. (2022). Effective method for filling gaps in time series of environmental remote sensing data: An example on evapotranspiration and land surface temperature images. *Computers and Electronics in Agriculture*, 193, 106619.

Předběžný termín obhajoby

2023/24 LS – FŽP

Vedoucí práce

Ing. Jan Komárek, Ph.D.

Garantující pracoviště

Katedra prostorových věd

Elektronicky schváleno dne 6. 3. 2024

prof. Ing. Petra Šimová, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 7. 3. 2024

prof. RNDr. Michael Komárek, Ph.D.

Děkan

V Praze dne 28. 03. 2024

Prohlášení

Prohlašuji, že jsem diplomovou/závěrečnou práci na téma: Doplnění chybějící obrazové informace fragmentované UAV ortomozaiky pomocí satelitních dat, vypracoval samostatně a citoval jsem všechny informační zdroje, které jsem v práci použil a které jsem rovněž uvedl na konci práce v seznamu použitých informačních zdrojů.

Jsem si vědom, že na moji diplomovou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů, ve znění pozdějších předpisů, především ustanovení § 35 odst. 3 tohoto zákona, tj. o užití tohoto díla.

Jsem si vědom, že odevzdáním diplomové práce souhlasím s jejím zveřejněním podle zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů, ve znění pozdějších předpisů, a to i bez ohledu na výsledek její obhajoby.

Svým podpisem rovněž prohlašuji, že elektronická verze práce je totožná s verzí tištěnou a že s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR.

V Praze dne: 28.03.2024

.....

Podpis autora

Poděkování

Na tomto místě bych rád poděkoval všem, kteří mě během psaní této práce podporovali. Zvláštní poděkování si pak zaslouží můj vedoucí Ing. Jan Komárek, Ph.D. především za trpělivost a poskytování cenných rad a připomínek.

Abstrakt: Diplomová práce zkoumá použití prostorového maskování pro doplnění chybějících obrazových informací v UAV ortomozaikách s pomocí dat z družice PlanetScope, s cílem ověřit přesnost a efektivitu této metody. Hlavní zaměření spočívá v analyzování shody mezi původními a doplněnými daty, což zahrnuje porovnání spektrálních kanálů a vegetačního indexu NDVI a využívá statistické metody pro kvantitativní hodnocení, včetně RMSE, Pearsonova korelačního koeficientu a Willmottova indexu shody. Výsledky potvrzují téměř dokonalou shodu mezi srovnávanými daty s výjimečně vysokou Pearsonovou korelací až 0,99 a Willmottovým indexem 0,98, přičemž nejvíce pozoruhodná shoda byla zaznamenána v modrém a zeleném spektrálním pásmu. Tento fakt ukazuje na významný potenciál integrace dat z UAV a PlanetScope pro doplnění chybějících obrazových dat, která jsou klíčová pro širokou škálu aplikací v dálkovém průzkumu Země a monitorování životního prostředí. V práci je rovněž představen přehled existujících metod integrace dat a jsou zdůrazněny klíčové aspekty prostorového maskování. Metodika demonstруje na praktických příkladech s reálnými datovými sadami důkaz o kompatibilitě mezi UAV a satelitními snímky. Práce také upozorňuje na oblasti, kde je prostor pro další zlepšení, zejména v NIR spektrálním pásmu, a zdůrazňuje potřebu dalšího výzkumu pro rozvoj pokročilých algoritmů, které by efektivně řešily rozdíly ve spektrálních odezvách a dále zvyšovaly přesnost integrace dat. Celkově tato práce přináší nový pohled na využití kombinace UAV a satelitních dat pro zlepšení informační hodnoty obrazových dat, což má důležité implikace pro dálkový průzkum Země a environmentální studie.

Klíčová slova: Bezpilotní letouny (UAV), PlanetScope, dálkový průzkum Země, integrace dat, obrazová informace

Supplementing missing image information of fragmented UAV orthomosaics using satellite data

Abstract: The diploma thesis examines the use of spatial masking to supplement missing image information in UAV orthomosaics using data from the PlanetScope satellite, aiming to verify the accuracy and effectiveness of this method. The main focus lies in analyzing the agreement between original and supplemented data, including the comparison of spectral channels and the NDVI vegetation index, employing statistical methods for quantitative evaluation, such as RMSE, Pearson correlation coefficient, and Willmott's index of agreement. The results confirm almost perfect agreement between the compared data, with exceptionally high Pearson correlation of up to 0.99 and a Willmott index of 0.98, with the most notable agreement observed in the blue and green spectral bands. This finding underscores the significant potential of integrating UAV and PlanetScope data to supplement missing image data, crucial for a wide range of applications in remote sensing and environmental monitoring. The thesis also provides an overview of existing data integration methods, emphasizing key aspects of spatial masking. The methodology demonstrates, through practical examples with real datasets, evidence of compatibility between UAV and satellite images. Additionally, the thesis highlights areas for further improvement, especially in the NIR spectral band, and underscores the need for further research to develop advanced algorithms that effectively address differences in spectral responses and further enhance data integration accuracy. Overall, this work offers a new perspective on the combined use of UAV and satellite data to improve the informational value of image data, with important implications for Earth remote sensing and environmental studies.

Keywords: Unmanned Aerial Vehicles (UAV), PlanetScope, Remote sensing, data integration, imagery information

Obsah

1. Úvod	10
2. Cíl práce	11
3. Rešeršní část.....	12
3.1. Sběr dat pomocí DPZ.....	12
3.1.1. Historie DPZ	12
3.1.2. Metody sběru dat pomocí DPZ.....	14
3.1.3. Využití leteckého DPZ a UAV	17
3.1.4. Využití dat ze satelitů	24
3.2. Zpracování dat a jejich analýza	26
3.3. Metody doplnění chybějící obrazové informace do dat	29
3.4. Možné limity, chyby či nedostatky ve sběru dat	33
4. Metodika práce	34
4.1. Volba lokality	35
4.2. Použitá data	36
4.3. Pre-processing dat	43
4.4. Simulace chyb v UAV ortomozaice.....	45
4.4.1. Simulace chybějících dat	46
4.4.2. Aplikace masky na UAV data.....	46
4.5. Modelování a doplnění dat	48
4.5.1. Extrakce satelitních dat pro doplnění	48
4.5.2. Interpolace a doplnění chybějících dat pomocí snímků Planet	49
4.6. Hodnocení modelu a analýza shody.....	51
4.6.1. Validace doplněných dat Planet do UAV ortomozaiky	51
5. Výsledky práce	56
6. Diskuse	61
7. Závěr a přínos práce.....	64

8. Seznam použitých zdrojů	66
9. Přílohy	79

1. Úvod

Problematika chybějících obrazových informací z bezpilotních letounů (UAV – Unmanned Aerial Vehicle) představuje významnou výzvu pro přesné zkoumání a mapování zemského povrchu. Absence úplných a přesných obrazových dat může být způsobena technickými omezeními UAV, jako jsou nedokonalý překryv snímků, ovlivnění kvality obrazu větrem, který může způsobit rozostření vegetace, a další chyby v pořizování a zpracování dat, což negativně ovlivňuje kvalitu datových sad a má zásadní dopad na analýzu a rozhodovací procesy. V této souvislosti se nabízí otázka, jak efektivně integrovat a využívat informace pocházející z různorodých zdrojů, zejména když se jedná o data s odlišným prostorovým, spektrálním a časovým rozlišením.

Tato diplomová práce se zabývá hodnocením a ověřením možnosti využití družicových dat, konkrétně dat od společnosti Planet a jejích satelitů PlanetScope, pro účely doplnění chybějících obrazových informací v datech získaných pomocí UAV. Přestože data získaná pomocí PlanetScope a UAV jsou obvykle využívána pro podobné účely, existující rozdíly v jejich prostorovém, spektrálním a časovém rozlišení, které mohou významně ovlivnit kvalitu a přesnost výsledných analýz. Cílem práce je proto navrhnout a ověřit metodiku, která by umožnila efektivní kombinaci těchto dvou datových zdrojů a poskytla by komplexnější pohled na sledovanou oblast.

Do základní struktury diplomové práce je zahrnuta rešeršní část, která pojednává o možných metodách sběru a zpracování dat a kombinaci dvou rozdílných dat do jednoho datasetu. Praktická část práce je věnována aplikaci vlastního metodického řešení pro kombinaci a analýzu dat získaných UAV a PlanetScope. Tato práce se ale nezaměřuje na metody tvorby ortomozaiky a radiometrických kalibrací pro UAV data, neboť tyto aspekty nejsou předmětem zkoumání.

Získané výsledky jsou následně analyzovány a diskutovány s důrazem na porovnání s existujícími vědeckými poznatkami v dané oblasti. Diskuse se zaměřuje na hodnocení efektivity navržené metodiky, identifikaci hlavních výhod a potenciálních omezení při využití kombinace UAV a satelitních dat pro doplnování chybějících obrazových informací. Cílem je poskytnout ucelený pohled na možnosti a výzvy spojené s integrací rozdílných typů obrazových dat a přispět tak k dalšímu rozvoji metod a technik v oblasti průzkumu a mapování zemského povrchu.

2. Cíl práce

Cílem práce je ověřit využitelnost satelitních dat pro doplnění obrazové informace fragmentované UAV ortomozaiky, resp. zjištění konzistentnosti a interoperability obrazových dat pořízených UAV a optickými satelity. Dílčí cíle závěrečné práce souvisí s těmito výzkumnými otázkami:

- a) Jsou data pořízená družicemi PlanetScope vhodná k nahrazení chybějících dat z UAV?
- b) Jaké jsou metody sběru dat pomocí UAV či satelitů a jaké chyby mohou nastat při pořizování a zpracování dat z dronů či z družic?
- c) Jaké jsou metody simulace chyb například v UAV ortomozaice?
- d) Jaké jsou metody doplňování obrazové informace například pomocí dat PlanetScope?
- e) Jaké jsou výhody a nevýhody metody prostorového maskování v praxi (např. z hlediska přesnosti, nejistoty metod, typu krajinného pokryvu, nákladů na pořízení vstupních dat a času zpracování)?

3. Rešeršní část

Tato část poskytuje přehled historie a využití různých metod sběru a zpracování dat v dálkovém průzkumu Země (DPZ). Zahrnuje vývoj leteckých a satelitních technologií a jejich aplikace v praxi, včetně využití bezpilotních letounů (UAV). Dále se zaměřuje na metody předzpracování obrazových dat, extrakci dat pro doplnění, metody imputace chybějící obrazové informace a analýzu výsledků. Obsahuje také možné limity, chyby a nedostatky ve sběru a zpracování dat v dálkovém průzkumu Země.

3.1. Sběr dat pomocí DPZ

Tato část práce zahrnuje historický vývoj dálkového průzkumu Země od počátků až po moderní technologie využívané v současnosti jako jsou například UAV nebo satelity s vysokým prostorovým rozlišením. Využití leteckého dálkového průzkumu Země v kombinaci s novější UAV technologií se stalo nedílnou součástí moderního geografického výzkumu a mapování. Zároveň využití dat ze satelitů je klíčové pro dálkový průzkum Země, jelikož poskytuje široký, pravidelný a konzistentní záběr Země z vesmíru.

3.1.1. Historie DPZ

Dálkový průzkum Země je disciplína zahrnující získávání informací o Zemi bez přímého kontaktu s objektem. Historie DPZ sahá již do první poloviny 19. století s vynálezem fotografie (Cohen, 2000). První fotografie pořízená Josephem Nicéphorem Niépcem v roce 1826 předznamenala začátek této oblasti (Lillesand et al., 2004). Rozvoj letecké fotografie pak začal s první úspěšnou leteckou fotografií pořízenou francouzským fotografem a novinářem Gaspardem Félixem Tournachonem, známým jako Nadar, z horkovzdušného balónu v roce 1858 (Jensen, 2007). Dále se například umisťovaly fotoaparáty na draky, malé rakety na stlačený vzduch, či dokonce holuby (Cracknell, 2018).

V průběhu první a druhé světové války se letecká fotografie stala klíčovým nástrojem pro vojenské účely, což přispělo k jejímu rychlému technologickému rozvoji (Griffin, 2010; Aspinwall, 2021). Po skončení válek se dálkový průzkum Země stal dostupnějším i pro civilní sektor, což vedlo k rozvoji leteckého a následně satelitního

snímkování (Campbell, 2011). To potvrzuje první snímek Země z vesmíru pořízený z rakety V2 v roce 1946 (Dornberger, 1963).

V období studené války došlo k rozvoji špionážních letadel a družicových optických systémů s vysokým rozlišením. Programy jako CORONA a Hexagon v USA a Kometa v SSSR přinesly pokrok ve výzvědných technologiích (Day, Logsdon a Latell, 1998; Hoover, 1991; Heaps, 1978).

Éra satelitního dálkového průzkumu byla zahájena vypuštěním první umělé družice Země Sputniku ze Sovětského svazu v roce 1957, či amerického Exploreru 1 (Yadav, 2023). V roce 1959 byl pořízen první snímek Země ze zemské orbity zachycený družicí Explorer 6 a v roce 1960 byl vypuštěn první meteorologický satelit TIROS-1 (Yadav, 2023).

Program Landsat zahájený v roce 1972 a další satelitní programy jako SPOT a SeaSat umožnily systematické mapování Země a vznik družicové oceánografie. Mise jako Shuttle Radar Topography Mission (SRTM) přinesly detailní digitální modely povrchu (Yadav, 2023).

V posledních desetiletích došlo k rozvoji komerčních systémů s velmi vysokým rozlišením (VHR - Very high resolution), jako jsou Ikonos-2 a programů EU Copernicus s družicemi Sentinel, které poskytují data s vysokým rozlišením pro různé vědecké a aplikované účely (Sefercik a Ozendi, 2013; Eugenio a Marcelllo, 2019).

Budoucnost DPZ naznačuje pokračující inovace a rozvoj nových technologií, jako jsou UAV, P-Band sately, pseudosateli a video sately, které otevírají nové možnosti pro sběr dat a monitorování Země. Projekty jako Biomass a Zephyr S HAPS naznačují směr k ještě přesnějšímu a detailnějšímu průzkumu naší planety (Esa, 2024; Airbus, 2024; Xu et al., 2023).

Kombinace různých typů dat a senzorů, včetně integrace dat z radaru, hyperspektrálních snímků a LiDARu, poskytuje bohatší informace o zemském povrchu a jeho vlastnostech. Využití umělé inteligence a strojového učení pro automatizovanou analýzu a interpretaci obrazových dat přináší nové možnosti pro efektivní využití zdrojů a přesnější analýzy (Li et al., 2018). Tato automatizovaná analýza dat zrychluje proces získávání informací a umožňuje rychlejší a efektivnější reakci na environmentální změny, monitorování zemědělství, urbanistické plánování a řadu dalších aplikací. Výzvy, jako je ochrana soukromí, zajištění bezpečnosti dat a interoperabilita, zůstávají klíčovými aspekty, které vyžadují další pozornost a mezinárodní spolupráci (Foody, 2002).

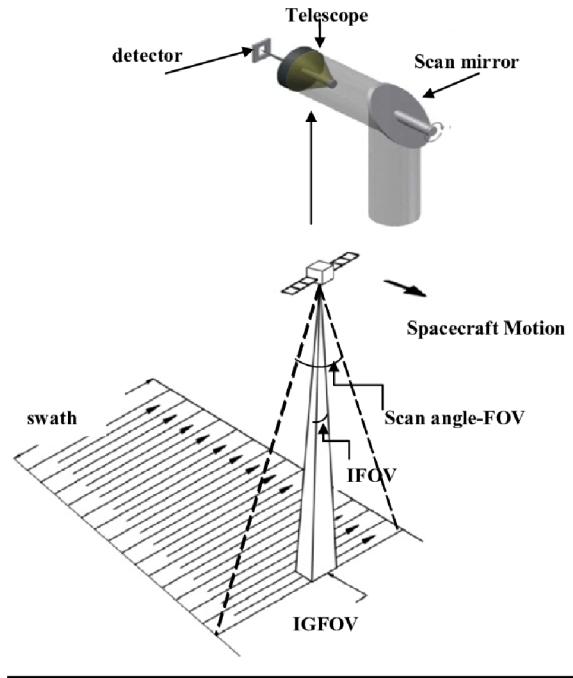
V současné době je dálkový průzkum Země nezbytným nástrojem pro pochopení a ochranu planety umožňující efektivní ochranu životního prostředí (Coppin a Bauer, 1996). S neustálým technologickým pokrokem a inovacemi je zde schopnost sledovat a analyzovat jak globální, tak lokální environmentální změny. To umožňuje se lépe připravit na budoucnost a řešit současné výzvy (Pettorelli et al., 2014). Pokračující výzkum a rozvoj v oblasti dálkového průzkumu Země tak otevírá nové cesty k hlubšímu porozumění dynamiky planety a posiluje schopnosti chránit a udržovat její zdraví pro budoucí generace (Moore, 1979).

3.1.2. Metody sběru dat pomocí DPZ

V dálkovém průzkumu a sběru dat se používají různé typy senzorů, mezi které patří mechanické (line-scan) senzory a digitální senzory s globální závěrkou (Joseph, 2016; Li et al., 2013).

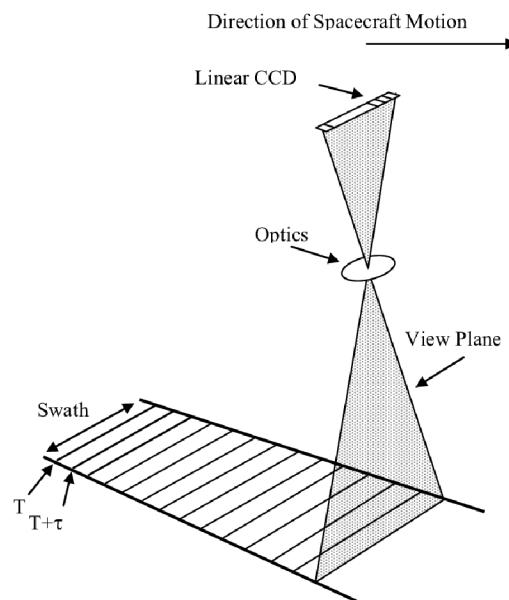
Mechanické senzory (line-scan)

Whiskbroom senzory jsou někdy označované jako across-track nebo spotlight senzory, jelikož skenují povrch Země pruh po pruhu. Používají rotující zrcadlo jako optický hranol k odrazu světla na jediný detektor, což umožňuje sběr dat z jednoho pixelu najednou (Li et al, 2013). Přestože je tato technologie vhodná na sběr dat z velkých ploch a nabízí vysoké rozlišení obrazu, její mechanická složitost zvyšuje náklady a pravděpodobnost opotřebení (Li et al, 2013). Tato metoda je také citlivá na pohybové distorze způsobené rychlým pohybem nosné platformy, jako jsou družice nebo UAV (Joseph, 2016; Shippert, 2013). Byly využívány například v misích Landsat MSS/TM a poskytovaly vysoké rozlišení obrazu díky zmíněné metodě (Joseph, 2016).



Obrázek 1: Whiskbroom senzor (Joseph, 2016)

Pushbroom senzory, někdy označované jako along-track senzory, využívají řadu detektorů uspořádaných kolmo ke směru letu družice nebo letadla, což umožňuje simultánní sběr dat pro celý rádek obrazu najednou a nevznikají tam žádné pixelové distenze (Joseph, 2016). Výhodou pushbroom senzorů je silnější signál díky delší expozici každé oblasti, ale jejich citlivost na variabilitu detektorů může vést k nekonzistentní kvalitě dat (Li et al, 2013; Joseph, 2016).



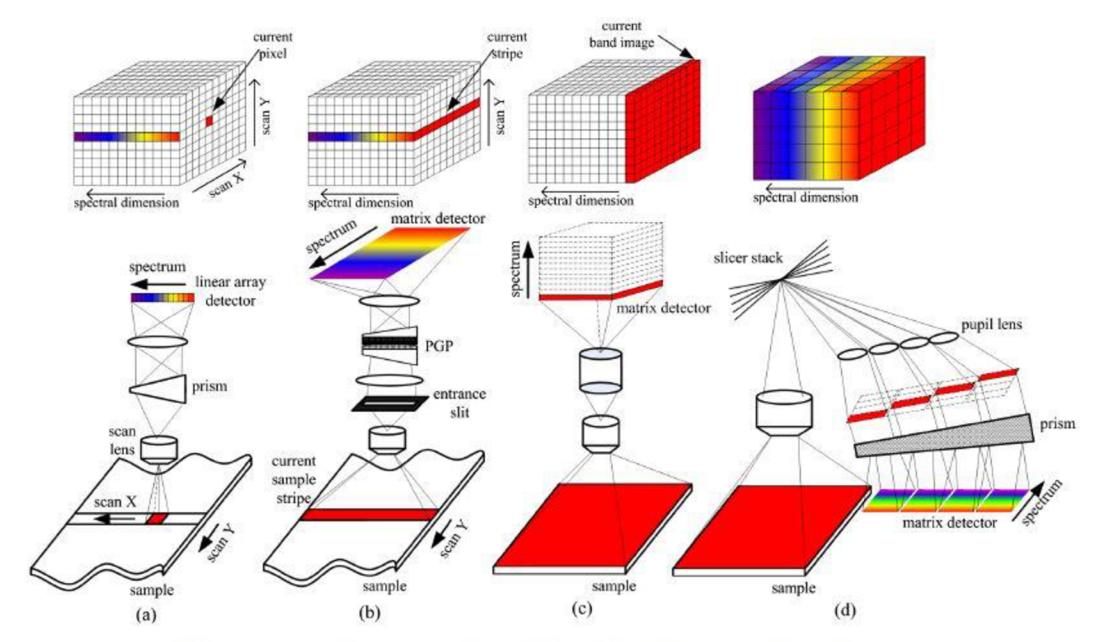
Obrázek 2: Pushbroom senzor (Joseph, 2016)

Digitální senzory s globální závěrkou

Tento typ senzorů současně zachycuje celý obraz, což eliminuje distorze způsobené pohybem. Jsou ideální pro aplikace, kde je potřeba zachytit rychlé pohyby nebo když je snímkovací zařízení, například dron, v pohybu (Jafarbiglu a Pourreza, 2022). Globální závěrka umožňuje senzoru zachytit celý obraz v jednom okamžiku, což je výhodné pro získávání ostrých a přesných snímků.

Staring přístup, také známý jako metoda band sequential, je spektrální skenovací metoda, která získává jednobarevný 2D obraz (x, y) s plnou prostorovou informací najednou. Tento režim obvykle používá filtry (jako jsou filtry s pevnými průchodovými filtry, lineární variabilní filtry, proměnlivé interferenční filtry a laditelné filtry) místo mřížky nebo hranolu před maticovým detektorem. Sleduje celou scénu na jednotlivých spektrálních pásmech po jednom a prochází spektrálními vlnovými délkami, což je odlišné od přístupů whiskbroom a pushbroom. Celkový počet spektrálních pásem závisí na uživateli. Výhodou je, že lze zachovat dynamický rozsah, protože lze použít různé expozice při různých vlnových délkách (Li et al., 2013).

Snapshot, který je známý také jako single-shot, je metodou určenou k záznamu jak prostorových, tak spektrálních informací na plošném detektoru jedním expozičním časem. Na rozdíl od přístupů whiskbroom, pushbroom a staring, které vyžadují skenování buď ve směru prostorovém, nebo ve směru spektrálním, a tím omezují jejich temporální rozlišení, režim snapshot je obrazovou technikou bez nutnosti skenování. Tento režim může získat kompletní spektrální datovou kostku v jednom integračním čase tím, že přímo odrazí rozptýlené oblasti obrazu na CCD (Charge-Coupled Device; Zařízení s vázanými náboji) detektor současně. CCD detektory mají schopnost zachytit světelné signály a převést je na elektrické signály, které jsou následně digitálně zpracovány a uloženy jako obrazová data (Zhang, 2010). I když tento režim může získat data přímo s minimálním postprocessingem k vytvoření 3D datové kostky, jeho prostorová a spektrální rozlišení jsou omezena, protože celkový počet voxelů, což je základní jednotka prostorového datování reprezentující objemový prvek dat, například v trojrozměrných snímcích, nemůže přesáhnout celkový počet pixelů na CCD kameře (Li et al., 2013; Lindquist, 2008).



Obrázek 3: Typické metody spektrálního zobrazování. (a) Whiskbroom, (b) Pushbroom, (c) Staring, (d) Snapshot (Li et al., 2013)

Komerční systémy s velmi vysokým rozlišením (VHR)

V oblasti dálkového průzkumu Země byly vyvinuty také komerční systémy s velmi vysokým rozlišením (VHR), jako je Ikonos-2, které poskytují data s vysokým rozlišením v panchromatickém i multispektrálním módu. Používají pushbroom skenery k získávání dat v panchromatickém módu s rozlišením přibližně 1 metr a v multispektrálním módu s rozlišením přibližně 4 metry (Esa, 2024). Tato technologie umožňuje detailní sběr dat pro různé aplikace, včetně monitoringu životního prostředí a plánování městského rozvoje (Sefercik a Ozendi, 2013).

3.1.3. Využití leteckého DPZ a UAV

Využití leteckého dálkového průzkumu Země a bezpilotních prostředků poskytuje širokou škálu možností pro sběr obrazových dat o Zemi (Manfreda et al., 2018). Letecký DPZ a UAV mají schopnost snímat zemský povrch z různých výšek a úhlů (viz obr. 4), což umožňuje získávání informací o terénu, vegetaci, zemědělských plochách, stavbách a mnoha dalších objektech s vysokým rozlišením (Manfreda et al., 2018; Sishodia, Ray a Singh, 2020).

Sběr dat pomocí UAV

Letecké snímky z dronů poskytují detailní a přesné informace o geografickém prostředí a umožňují mapování a monitorování změn v krajině (Manfreda et al., 2018). UAV představují flexibilní a nákladově efektivní alternativu k tradičním leteckým systémům DPZ, jako jsou především satelity (Wavrek et al., 2023). UAV v dálkovém průzkumu Země mají schopnost zachytit obrazová data z různých perspektiv, nízkých výšek a za pomocí řady různých senzorů, což umožňuje komplexní a multidimensionální analýzu zemského povrchu, jako je tvorba digitálních map či modelů reliéfu. Letecké snímky umožňují mapování a monitorování změn v krajině s vysokou přesností a aktualitou (Manfreda et al., 2018).

V zemědělství jsou UAV využívány pro monitorování růstu plodin, odhalování chorob a škůdců, optimalizaci zavlažování a hnojení a plánování sklizní. V lesnictví mohou být tyto technologie využity k monitorování stavu lesních porostů, odhadu dřevní zásoby a detekci lesních škůdců (Radoglou-Grammatikis et al., 2020). Environmentální monitoring je další oblastí, kde má letecký DPZ a UAV zásadní význam. Pomáhají sledovat změny v životním prostředí, jako je tání ledovců, změny v rozložení vegetace, eroze půdy a znečištění vodních zdrojů či monitoring přírodních katastrof (Manfreda et al., 2018). V urbanismu a plánování městského rozvoje mohou být tyto technologie využity pro analýzu rozložení zástavby, infrastruktury a zelených ploch, a také pro plánování dopravních sítí a zón (Wavrek et al., 2023).

Jednou z klíčových výhod DPZ pomocí UAV je schopnost provádět snímkování a měření i v obtížně přístupných oblastech, kde je získání dat jinými způsoby obtížné nebo nemožné. Tímto způsobem mohou být studovány i izolované regiony, jako jsou například arktické oblasti, horské masivy nebo deštné pralesy (Almeida et al., 2021). Například studie, která se zaměřuje na aplikaci dronů pro hodnocení zdravotního stavu městských lesů pomocí spektrálních vegetačních indexů jako je NDVI pomohla odhalit několik oblastí, které vyžadují ochranu, včetně invaze nepůvodních druhů a úbytku stromového patra (Wavrek, et al., 2023). Zjištění naznačuje, že dronový průzkum nabízí nízkonákladový a efektivní nástroj pro správu městských lesů (Wavrek, et al., 2023).

Typy UAV v DPZ

Multirotorové UAV jsou oblíbené pro svou manévrovatelnost a schopnost vertikálního vzletu a přistání. Tyto UAV jsou ideální pro detailní mapování menších oblastí a provádění přesných měření (Guimarães et al., 2020; Jafarbiglu a Pourreza, 2022).

UAV s pevným křídlem jsou dalším typem bezpilotních prostředků, které mají podobu tradičních letadel s křídly. Jsou schopny pokrýt větší oblasti s vyšší rychlostí a efektivitou, což je ideální pro rozsáhlá mapování a průzkumy. Zde je především velkou výhodou, že senzory mají globální závěrku, která umožňuje zachycení detailních a přesných snímků i při pohybu (Guimarães et al., 2020; Jafarbiglu a Pourreza, 2022).

Vertikálně startující a přistávající (VTOL – Vertical Take-Off and Landing) UAV jsou bezpilotní letouny, které kombinují vlastnosti multirotorových UAV s výhodou pevných křídel. Jsou schopny vertikálního vzletu a přistání, ale mohou také létat jako tradiční letadla s křídly, což je ideální pro různorodé aplikace v DPZ (Guimarães et al., 2020; Jafarbiglu a Pourreza, 2022).

Typy senzorů využívané UAV

Běžné RGB (Red, Green, Blue; červená, zelená, modrá) kamery jsou schopny zachytit barevná obrazová data, což je užitečné pro vizuální mapování a monitorování změn v krajině (Guimarães et al., 2020; Jafarbiglu a Pourreza, 2022). Například RGB senzor SenseFly SODA (Herrero-Huerta et al., 2020).

Termální kamery jsou schopny zachytit tepelné signatury, což umožňuje detekci teplotních anomalií, jako jsou například požáry, tepelné ztráty budov nebo živočišné populace (Guimarães et al., 2020; Jafarbiglu a Pourreza, 2022).

Multispektrální či hyperspektrální senzory umožňují zachytit obrazy ve více spektrálních pásmech, což je užitečné pro analýzu vegetace, zemědělského růstu a dalších biologických procesů. Například multispektrální senzor MicaSense RedEdge MX (Guimarães et al., 2020; Jafarbiglu a Pourreza, 2022; Manfreda et al., 2018).

LiDAR (Light Detection and Ranging; Detekce a měření světla) senzory měří vzdálenosti pomocí laserových paprsků, což umožňuje vytváření detailních digitálních modelů terénu a analýzu reliéfu povrchu Země (Guimarães et al., 2020; Jafarbiglu a Pourreza, 2022).

Sběr dat pomocí letadel

Podobně jako u sběru dat pomocí dronů, je sběr dat pomocí letadel nedílnou součástí DPZ. Avšak je třeba vždy zvážit, zda-li se vyplatí tento způsob sběru dat použít pro konkrétní velikost či typ území atď už z hlediska finančního, ale i časového.

Typy letadel v DPZ

Běžná tradiční letadla, jako jsou například dopravní letadla komerčního charakteru, jsou často využívána pro velké průzkumné mise díky své schopnosti pokrýt rozsáhlé oblasti a dosáhnout vysokých rychlostí. Jsou vybavena speciálními senzory pro sběr různých typů dat (Mastelic et al., 2020).

Některá letadla menší velikosti jsou upravena speciálně pro účely DPZ, s instalovanými senzory a vybavením pro efektivní sběr dat. Tyto letouny mohou být optimalizovány pro konkrétní aplikace, jako je například monitorování lesů, zemědělství nebo geologickému průzkumu (Sugita et al., 2020). Pro detekci a monitorování z atmosféry se používají různá letadla, včetně Beechcraft King Air, Casa, Cessna Cardinal, DeHaviland Twin Otter, Partenavia Observer, Piper Seminole a Rockwell Aerocommander (Sugita et al., 2020). Tyto letouny jsou vybírány na základě jejich schopnosti nést specifické nástroje a vybavení, jako jsou lidary a multispektrální kamery, které jsou klíčové pro sběr dat v rámci vědeckých projektů. Každý typ letounu nabízí unikátní vlastnosti, jako jsou speciální otvory pro lidary nebo přizpůsobení pro efektivní provoz v různých environmentálních podmínkách.

Helikoptéry se v dálkovém průzkumu Země stávají stále důležitějším nástrojem díky své schopnosti létat ve velmi nízkých výškách a přesnému řízení nad určitými oblastmi. Jejich schopnost vertikálního vzletu a přistání umožňuje provádět měření a sběr dat i na místech s omezeným přistávacím prostorem. Díky tomu jsou ideální pro detailní mapování terénu, sledování změn v krajině, monitorování lesních porostů nebo průzkum míst obtížně dostupných jinými prostředky. Jejich manévrovatelnost a schopnost zůstat na místě umožňuje provádět i specifické úkoly, jako je například sledování života divokých zvířat či průzkum v místech postižených přírodními katastrofami. Helikoptéry pro dálkový průzkum Země jsou proto důležitým prostředkem pro získávání detailních geografických informací a monitorování změn v životním prostředí (Luo et al., 2019).

Vysokorychlostní stratosférická letadla mají schopnost letět ve velkých výškách a rychlostech a jsou často využívána pro průzkum atmosféry a meteorologické studie. Mohou být také využita pro sběr dat o zemském povrchu pomocí speciálních senzorů.

Například letadla WB-57 jsou široce využívána pro vědecké a výzkumné účely, včetně mapování Země a průzkumu atmosféry (Caspi et al., 2020).

Senzory používané v letadlovém DPZ

Fotogrammetrické kamery jsou schopny zachytit obrazová data o zemském povrchu s vysokým rozlišením, což umožňuje vytváření detailních map a modelů terénu (Jafarbiglu a Pourreza, 2022).

Lidarové senzory měří vzdálenosti pomocí laserových paprsků a umožňují vytváření přesných digitálních modelů terénu a analýzu reliéfu povrchu Země (Jafarbiglu a Pourreza, 2022).

Multispektrální a hyperspektrální kamery zachycují obrazy ve více spektrálních pásmech, což je užitečné pro analýzu vegetace, geologických formací a dalších biologických a geografických procesů (Jafarbiglu a Pourreza, 2022).

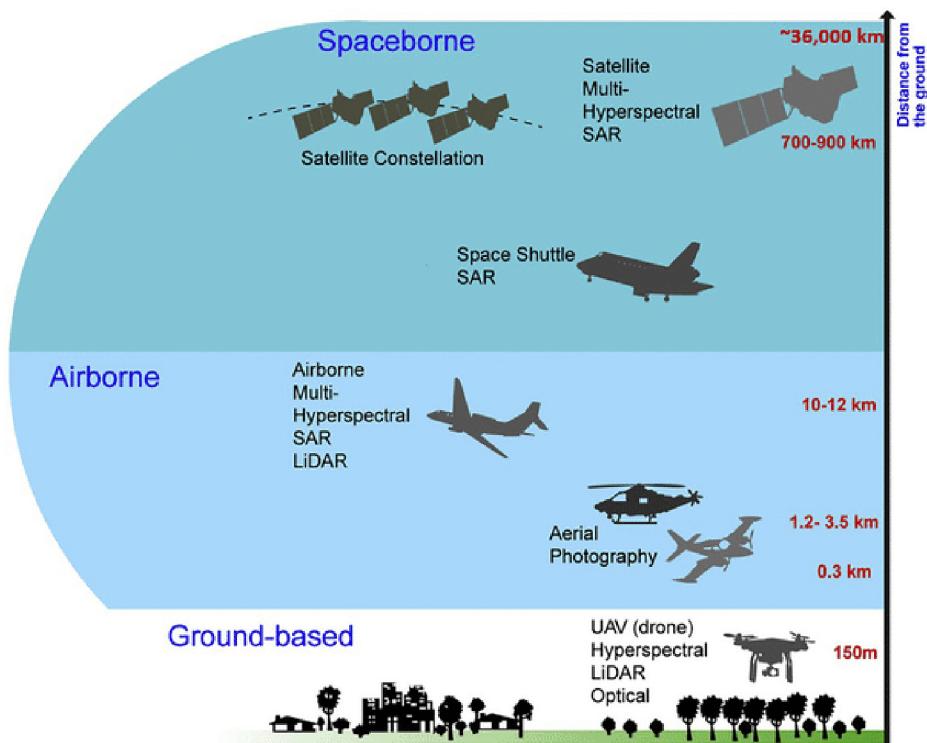
Termokamery na letadlech detekují teplotní rozdíly a jsou využívány pro monitorování životního prostředí a identifikaci tepelných anomalií. Umožňují efektivnější mapování a analýzu terénu, což je klíčové pro ekologický výzkum a sledování klimatických změn (Štumper a Kraus, 2015).

Lze konstatovat, že letadla jsou důležitým nástrojem v dálkovém průzkumu Země díky své rychlosti, dosahu a nosnosti. Nicméně, je důležité zvážit jejich výhody a nevýhody i v rámci UAV při plánování a provádění průzkumných misí v této oblasti (Tabulka 1).

Tabulka 1: Výhody a nevýhody UAV a letadel v DPZ

Vlastnost	Výhody UAV	Nevýhody UAV	Výhody letadel	Nevýhody letadel
Flexibilita	Drony mohou létat do těžko dostupných nebo nebezpečných oblastí (Fan & Saadeghvaziri, 2019).	Omezený dolet a nosnost dronů může omezit rozsah mise (Qin et al., 2023).	Letadla mohou být nasazena pro různé průzkumné mise (Caspi et al., 2020).	Používání letadel vyžaduje letiště a je závislé na dostupnosti vzdušných prostorů (Shakirova et al., 2022).
Náklady	Nižší provozní náklady umožňují častější a levnější mise (Scher et al., 2020).	-	-	Vysoké náklady na pohonné hmoty, údržbu a personál (Sugita et al., 2020)
Rychlosť a efektivita	Drony pokrývají velké oblasti rychle a efektivně (Jafarbiglu a Pourreza, 2022).	Závislost na povětrnostních podmínkách může ovlivnit schopnost létat (Qin et al., 2023).	Letadla mají vysoký dosah a jsou schopna rychle pokrýt rozsáhlá teritoria (Caspi et al., 2020).	-
Nosnost a stabilita	-	Omezená nosnost (Qin et al., 2023).	Vyšší nosnost letadel umožňuje použití více senzorů (Caspi et al., 2020).	-
Bezpečnostní a regulační aspekty	-	Používání dronů podléhá regulačním omezením, což může být překážkou pro mise (Clarke & Bennett Moses, 2014).	-	Letadla musí splňovat přísné bezpečnostní a regulační normy, což může omezovat flexibilitu operací (Shakirova et al., 2022).

Na obrázku č. 4 jsou znázorněny různé platformy používané pro dálkový průzkum Země, které jsou rozděleny podle jejich umístění vzhledem k zemskému povrchu. Každá platforma má specifické schopnosti a používá různé druhy senzorů k získávání obrazových dat. Ground-based (pozemní) jsou systémy umístěné přímo na zemském povrchu nebo v jeho blízkosti. Tyto systémy mohou zahrnovat UAV, které jsou schopny nést hyperspektrální, LiDAR a optické senzory. Výška, ve které tyto systémy operují, je zhruba do 150 metrů nad zemí. Airborne (letecké) systémy zahrnují letadla a helikoptéry, které mohou nést různé senzory, včetně multispektrálních, hyperspektrálních, SAR (Synthetic Aperture Radar; Radar se syntetickou aperturou) a LiDAR. Letadla mohou operovat ve výškách od 0,3 km do 12 km. Nižší hladina této kategorie může zahrnovat i leteckou fotografii. Do třídy spaceborne (kosmické) patří satelity a vesmírná letadla umístěná na oběžné dráze. Mohou být vybaveny různými senzory, jako jsou multispektrální, hyperspektrální, SAR a další. Satelity mohou být umístěny ve výškách od 700 km až po geostacionární orbitu, která je přibližně 36 000 km nad zemí. Konstelace satelitů jsou skupiny satelitů navržené ke společné práci.



Obrázek 4: Metody sběru dat v DPZ (LECHNER et al., 2020)

3.1.4. Využití dat ze satelitů

Využití dat ze satelitů je klíčové pro dálkový průzkum Země a poskytuje možnost získávání obrazových informací o velkých geografických oblastech díky jejich globálnímu pokrytí. S pomocí těchto satelitních systémů lze získávat snímky Země z vesmíru s vysokým rozlišením, opakovatelností a pro člověka těžko přístupných oblastí (Nagel, Darby a Leyland, 2023; Campbell, 2011).

Satelitní data jsou široce využívána v mnoha odvětvích, včetně meteorologie, geologie, geografie, ochrany životního prostředí, dopravy a telekomunikací. V meteorologii jsou satelitní snímky využívány k monitorování počasí, sledování tropických cyklón, předpovídání povodní nebo období sucha a dalších meteorologických jevů. V geologii jsou data ze satelitů využívána k mapování geologických struktur, identifikaci ložisek nerostných surovin a sledování geologických procesů (Campbell, 2011; Zhao et al., 2023).

V oblasti ochrany životního prostředí jsou satelitní data klíčovým nástrojem pro monitorování stavu lesů, oceánů, řek a jezer, sledování znečištění ovzduší a vody či identifikaci a monitorování přírodních katastrof, jako jsou lesní požáry, povodně a zemětřesení. V dopravě a telekomunikacích jsou satelitní systémy využívány k navigaci, sledování pohybu vozidel a lodí či poskytování globálního spojení a komunikace (Faisal et al., 2012). Využití dat ze satelitů má obrovský význam pro mnoho odvětví lidské činnosti, které jsou zmíněny v této práci.

Dálkový průzkum Země pomocí satelitů se rozděluje do několika kategorií na základě jejich účelu a vlnových délek, které mohou zachytit. Mezi tyto kategorie patří optické a radarové (SAR) satelity (Faisal et al., 2012; Joshi et al., 2016). Optické satelity zachycují obrazy buď ve viditelném spektru, multispektrálním či hyperspektrálním, zatímco SAR satelity využívají mikrovlnný radar k průzkumu povrchu Země bez ohledu na oblačnost nebo denní světlo (Faisal et al., 2012; Joshi et al., 2016). Multispektrální satelity zase snímají v různých vlnových délkách, což umožňuje analýzu vegetace, vodních těles a dalších povrchových charakteristik (Joshi et al., 2016).

Typy satelitů v DPZ

Družice obíhající na geostacionární orbitě (GEO – Geostationary Orbit) obíhají nad rovnikem Země a pohybují se ve stejném směru a rychlosti jako Země. To způsobuje, že družice zdánlivě zůstávají nad pevným bodem na Zemi, což je ideální pro telekomunikaci a pozorování počasí (Booysen et al., 2021).

Družice obíhající na nízké oběžné dráze (LEO – Low Earth Orbit) jsou umístěny relativně blízko k povrchu Země a mají rychlý pohyb kolem planety. Jsou vhodné pro satelitní snímání Země s vysokým rozlišením a pro mise, jako je Mezinárodní vesmírná stanice (ISS) (Booysen et al., 2021).

Středně vysoká oběžná dráha (MEO – Medium Earth Orbit) je oblast mezi LEO a GEO. Je často využívána pro navigační sately, jako je systém Galileo, který poskytuje globální polohové informace (Booysen et al., 2021).

Polární družice obíhají Zemi z pólu na pól, zatímco družice obíhající na heliosynchronní orbitě (SSO – Sun-Synchronous Orbit) jsou synchronizovány s pohybem Slunce, což umožňuje konzistentní pozorování stejných oblastí Země ve stejném čase. Jsou užitečné pro vědecké pozorování a sledování změn v čase (Booysen et al., 2021).

Přechodové dráhy a geostacionární přechodová oběžná dráha (GTO – Geostationary Transfer Orbit) jsou speciální dráhy používané pro přesun satelitů z jejich výchozího místa do cílové oběžné dráhy. GTO je typickým příkladem přechodové dráhy, která umožňuje satelitům dosáhnout GEO s minimálním množstvím paliva (Booysen et al., 2021).

Lagrangeovy body (L-body) jsou speciální body v gravitačním poli Země a Slunce, kde je možné udržovat stabilní oběžné dráhy. Jsou využívány pro umístění observatoří a vesmírných misí, které vyžadují stabilitu a minimální rušení od Země (Booysen et al., 2021).

Senzory používané v satelitním DPZ

Optické senzory zachycují obrazy Země ve viditelném spektru, ale také ve více spektrálních kanálech. Mohou poskytovat vysoké rozlišení obrazu a jsou vhodné pro analýzu vegetace, vodních zdrojů a měření povrchové teploty (Joshi et al., 2016).

Radarové senzory pracují na základě vysílání radarových signálů na zemský povrch a analýzy odraženého signálu. Jsou schopny pracovat v jakýchkoli povětrnostních podmínkách a jsou vhodné pro analýzu reliéfu terénu, detekci změn a sledování povrchových vod (Joshi et al., 2016).

Hyperspektrální senzory zachycují obrazy Země ve velkém počtu úzkých spektrálních pásů. Jsou užitečné pro analýzu chemického složení půdy, detekci znečištění a sledování biologických procesů (Li et al., 2018; Jafarbiglu a Pourreza, 2022).

Sateliity pro DPZ jsou klíčovým nástrojem pro monitorování Země a jejího životního prostředí. Přestože mají své výhody a nevýhody, poskytují nepostradatelné informace pro vědu, průmysl a vládní instituce v celosvětovém měřítku (viz tabula 2).

Tabulka 2: Výhody a nevýhody použití satelitů v DPZ

Výhody satelitů v DPZ	Nevýhody satelitů v DPZ
Sateliity poskytují pokrytí celé planety, což umožňuje monitorování bez ohledu na teritoriální hranice (Millan et al., 2019).	Satelitní senzory mají omezené rozlišení, což může snižovat detailnost informací o zemském povrchu (Bucay et al., 2021).
Sateliity umožňují dlouhodobé sledování trendů a sezónních změn v krajině a klimatu (Narayanasamy, Ahmad a Othman, 2017).	Optické senzory mohou být ovlivněny oblačností a mlhou, což snižuje jejich efektivitu (Nagel, Darby a Leyland, 2023).
Satelitní data se využívají v mnoha oblastech, od životního prostředí po urbanismus (Zhao et al., 2023; Faisal et al., 2012).	Vývoj a provoz satelitních misí jsou finančně náročné (Nagel, Darby a Leyland, 2023; Sozzi et al., 2021).

3.2. Zpracování dat a jejich analýza

Zpracování dat je zásadním prvkem v analýze obrazových informací získaných z dálkového průzkumu Země. Tato podkapitola se zaměřuje na různé techniky a postupy používané ke zpracování a interpretaci obrazových dat z různých zdrojů, včetně leteckého dálkového průzkumu Země, bezpilotních prostředků a satelitních systémů.

Pre-processing obrazových dat

Pre-processing je nezbytným prvním krokem pro práci s obrazovými daty. Jeho hlavním účelem je připravit surové snímky pro další detailní analýzu. Tento komplexní proces zahrnuje různé operace a úpravy, které mají za cíl vylepšit kvalitu obrazu a eliminovat případné zkreslení.

Radiometrická kalibrace je zásadní pro převod surových digitálních čísel na smysluplné fyzikální jednotky jako odrazivost nebo teplotu. Tento proces odstraňuje chyby a šum způsobené senzorovými vlastnostmi, atmosférickými podmínkami a dalšími externími faktory, jako jsou úpravy jasu a kontrastu obrazových dat. Správná

kalibrace zahrnuje korekce jako je například vinětace a další senzorové šumy. (Jafarbiglu a Pourreza, 2022; Vane et al., 1987; Jiang et al., 2022).

Důležitým krokem je také korekce geometrických zkreslení. Geometrické korekce opravují deformace způsobené perspektivou snímání, rotací Země a dalšími faktory (Jafarbiglu a Pourreza, 2022).

Georeferencování je proces přiřazení geografických souřadnic obrazovým datům, což umožňuje jejich přesnou lokalizaci na Zemi. Tento krok je zvláště důležitý, protože zajišťuje, že každý pixel obrazu odpovídá specifickému bodu na terénu. Georeferencování může využívat například referenčních bodů na zemi s přesně známými souřadnicemi pro zarovnání snímků (Jafarbiglu a Pourreza, 2022).

Tvorba ortomozaiky a kompozice obrazu jsou procesy spojování více snímků do jednoho celistvého obrazu. To je nezbytné pro získání kontinuálního pokrytí sledované oblasti, zejména při použití UAV technologií, kde jednotlivé snímky pokrývají pouze malé části celkového území. Pro vytvoření ortomozaiky je nezbytné využít techniky pro zarovnání snímků, aby se správně určila například jejich vzájemná orientace a metody pro určení vzájemné polohy snímků, ke které většinou slouží vlícovací body. Tyto body změřené na Zemi v určité snímané lokalitě, pomáhají minimalizovat nesrovnalosti a přerušení v oblastech, kde se snímky překrývají. (Jafarbiglu a Pourreza, 2022).

Generování bodových mračen a digitálních modelů povrchu (DSM - Digital Surface Model) umožňuje rekonstrukci trojrozměrných struktur z obrazových dat. Lidar a fotogrammetrie jsou klíčové metody pro tuto transformaci, poskytující podrobné informace o tvaru, velikosti a orientaci objektů na Zemi. Z DSM lze dále odvodit digitální modely terénu (DTM - Digital Terrain Model), které představují pouze terén bez objektů nad ním. Odečtením DTM od DSM lze získat modely výšky porostu (CHM - Canopy Height Model), což je klíčové pro studium vegetačního krytu (Jafarbiglu a Pourreza, 2022).

Prostorové rozlišení se zabývá úpravou nebo zlepšením prostorového rozlišení snímků, což může zahrnovat změnu měřítka nebo aplikaci technik pro zvýšení detailu (Lahiri, 2003).

Spektrální rozlišení a jeho kalibrace je klíčovou operací, která upravuje nebo vylepšuje schopnost senzoru rozlišovat mezi různými spektrálními pásmi. To je zásadní pro identifikaci a klasifikaci různých typů povrchů na Zemi (Vane et al, 1987; Gao et al., 2024).

Resampling je proces, při kterém jsou obrazová data interpolována nebo transformována do nového rozlišení nebo geometrie, často v souvislosti s georeferencováním nebo přechodem mezi různými měřítky či rozlišeními (Pereira et al., 2023).

Normalizace spektrálních rozsahů je dalším důležitým krokem, který sjednocuje spektrální charakteristiky u různých snímků nebo senzorů pro usnadnění srovnávací analýzy (Jafarbiglu a Pourreza, 2022; Pereira et al., 2023).

Nakonec je možné upravit data pouze na velikost zájmové oblasti, což umožňuje redukci velikosti datasetu odstraněním nepotřebných částí snímku a zaměření se pouze na specifikovanou oblast. Tako pečlivý pre-processing obrazových dat je klíčem k získání přesných a užitečných informací o povrchu Země.

Simulace chybějící části, segmentace a klasifikace dat

Simulace chybějících částí dat je proces, který se zabývá simulací chybějících částí v obrazových datech proto, aby bylo možné ověřit a testovat různé metody nahrazování dat v případě reálných potřeb. V reálném světě takové chyby a nedostatky v datech mohou nastat například z důvodu zakrytí Země mraky, vytvořením stínů, špatným překryvem snímků či rozmazáním vlivem větru (viz kapitola 3.4.). Dále mohou nastat i technické problémy senzorů (Pereira et al., 2023; Cheng et al., 2019).

Segmentace obrazu rozděluje obraz na jednotlivé části či segmenty na základě určitých kritérií, jako jsou barva, textura, nebo intenzita. Cílem segmentace je identifikovat a izolovat jednotlivé objekty nebo regiony zájmu v obraze, což umožňuje detailnější analýzu a interpretaci dat (Pereira et al., 2023; Jafarbiglu a Pourreza, 2022).

Klasifikace přiřazuje jednotlivým objektům nebo segmentům obrazu různé třídy nebo kategorie. Tento proces umožňuje rozlišovat mezi různými typy objektů a povrchů na základě jejich charakteristik, jako jsou jejich spektrální vlastnosti, což je klíčové pro kvantifikaci a interpretaci obrazových dat (Böhler, Schaepman a Kneubühler, 2018).

Doplnění chybějící obrazové informace

Metoda "filling gaps", neboli doplňování chybějících obrazových informací, se používá v dálkovém průzkumu Země k řešení problémů s chybějícími daty ve snímcích, jak už práce zmínila (Zhang a Travis, 2007). Tato metoda je zásadní pro zajištění kontinuity a kvality datových sad, což je klíčové pro monitorování pozorovaných jevů na Zemi. "Filling gaps" spočívá v aplikaci algoritmů a metod, které odhadují

a nahrazují chybějící pixely v obrazu na základě informací z okolních pixelů nebo z dalších časových úseků (Sarafanov et al., 2020). Používají se různé přístupy, včetně interpolace, statistického modelování nebo třeba využití časových řad (Singh a Prasad, 2014; Weiss et al., 2014; Kandasamy et al., 2013). Tato metoda umožňuje získat kompletní a spolehlivé obrazové sady pro další účely analýzy povrchu.

Analýza výsledků a interpretace

Tato část je poslední fází zpracování obrazových dat, která se zaměřuje na popis získaných výsledků a jejich srovnání například s predikovanými výsledky. Tato fáze zahrnuje statistickou analýzu dat, vizualizaci výsledků a interpretaci jejich významu pro daný výzkumný problém.

Analýza výsledků a jejich interpretace jsou klíčovými složkami každého vědeckého výzkumu. Například v rámci výzkumu o efektivní metodě doplňování chybějící informace v časových řadách dat bylo provedeno přímé porovnání odhadovaných hodnot s reálnými daty, čímž byla ověřena přesnost a spolehlivost metody (Siabi, Sanaeinejad a Ghahraman, 2022). Výsledky byly kvantifikovány pomocí kořenového středního kvadrátu chyby (RMSE – Root Mean Square Error), což je standardní metrika pro hodnocení přesnosti predikcí v environmentálních vědách. Nízké hodnoty RMSE získané v této studii potvrzují, že navrhovaná metoda poskytuje velmi přesné odhady pro doplnění chybějících dat. Díky své paralelizovatelné struktuře a nízké výpočetní náročnosti je zároveň vhodná pro zpracování velkých objemů dat.

3.3. Metody doplnění chybějící obrazové informace do dat

Interpolace

Interpolace je jednou z nejběžnějších metod doplňování chybějících obrazových informací. Tato technika využívá existující data k odhadu chybějících hodnot na základě hodnot okolních pixelů. Existuje několik různých metod interpolace, včetně lineární interpolace, kde jsou chybějící hodnoty odhadnuty lineárně mezi dvěma známými body, a interpolačních metod vyššího řádu, které zahrnují složitější matematické modely pro odhad chybějících dat (Pringle, Schmidt a Muir, 2009; Singh a Prasad, 2014).

Regresní analýza

Regresní analýza je statistická metoda, která se používá k predikci hodnoty jedné proměnné na základě hodnoty jedné nebo více jiných proměnných. V kontextu

doplňování chybějících obrazových informací může regresní analýza být použita k odhadu chybějících hodnot na základě známých vztahů mezi různými oblastmi obrazu (Sarafanov et al., 2020; Zhang, Li a Civco, 2014). Tato metoda je často používána, pokud existuje silná korelace mezi chybějícími a dostupnými hodnotami (Moreno-Martínez et al., 2020).

Neuronové sítě

Neuronové sítě jsou sofistikované matematické modely inspirované strukturou lidského mozku. Tyto sítě jsou schopny naučit se složité vztahy v datech a provádět predikce a klasifikace na základě těchto vztahů. V kontextu doplňování chybějících obrazových informací mohou být neuronové sítě použity k vytvoření modelů, které se naučí vzory v datech a odhadnou chybějící hodnoty na základě těchto vzorů (Sarafanov et al., 2020).

Random Forest

Random Forest (RF) je další metoda strojového učení, která je často používána k doplňování chybějících obrazových informací. Tato metoda využívá soubor stromů rozhodování, které jsou trénovány na různých podmnožinách dat (Belgiu a Drăguț, 2016). V kontextu zpracování obrazových dat z UAV a satelitu každý strom v Random Forest modelu přispívá svým odhadem chybějících oblastí, a finální hodnota je stanovena prostřednictvím agregace odhadů ze všech stromů. Model využívá množství rozhodovacích stromů k předpovědi chybějících pixelů na základě vzorů identifikovaných v dostupných datech. Každý strom se specializuje na odlišnou podmnožinu atributů a prostorových vztahů, což umožňuje modelu efektivně modelovat a nahradit chybějící informace v různých typologických a spektrálních charakteristikách krajiny.

Metoda prostorového maskování

Metoda prostorového maskování je technika v oblasti zpracování obrazových dat, která se používá k identifikaci a vyloučení určitých oblastí nebo hodnot z rastrových dat na základě masky. Maska je rastrová vrstva, která určuje, které části rastrového souboru budou zachovány a které budou vyloučeny. Tato metoda maskování se používá například k extrakci nevhodných, chybějících či nechtěných dat v rastrovém snímku, které jsou potřeba nahradit. Tato místa jsou vytvořena pomocí GPS souřadnic nebo pomocí například definování začátku a konce určitého pruhu a vytvořením rastrové masky, která obsahuje hodnoty NA (neplatné hodnoty) v těchto

pruzích. Tato maska je pak aplikována na požadovaný rastrový snímek pomocí funkce *mask*, čímž se vytvoří nový snímek s chybějícími daty.

Poté jsou vyříznuty odpovídající části z rastrových dat sloužící k doplnění chybějících úseků v rastrovém snímku UAV. Nakonec jsou chybějící úseky v rastrovém snímku doplněny pomocí funkcí *cover* nebo *overlay*. Funkce *mask*, *cover* a *overlay* jsou dostupné v balíčku *raster* z programu RStudio, který je široce používán pro analýzu a manipulaci s rastrovými geoprostorovými daty. Tento proces umožňuje integrovat informace z jiných zdrojů nebo snímků do rastrových dat, čímž se eliminují chybějící nebo vadné úseky a zlepšuje se celková kvalita dat pro další analýzy a interpretaci. Výhodou této metody je schopnost zachovat prostorové charakteristiky dat a minimalizovat chyby spojené s interpolací.

Metoda strojového učení

Metoda strojového učení představuje pokročilý přístup k doplňování chybějících obrazových informací v rámci analýzy dat získaných dálkovým průzkumem Země. Strojové učení, včetně algoritmů, jako jsou neuronové sítě a Random Forest, umožňuje modelovat složité vzorce a vztahy v datech, což vede k vysoké přesnosti při predikci chybějících hodnot.

Metoda strojového učení využívá rozsáhlých datových sad k trénování modelů, které jsou schopné identifikovat a naučit se specifické vzorce v datech (Sarafanov et al., 2020). Tato schopnost umožňuje efektivní odhad chybějících hodnot, a to i v komplexních a heterogenních datových sadách. Jednou z hlavních výhod této metody je její flexibilita a adaptabilita, která umožňuje její použití v široké škále aplikací od klasifikace vegetace až po monitorování změn v krajině (Xie a Niculescu, 2022; Stournaras et al., 2022).

Kriging

Kriging je geostatistická metoda používaná k interpolaci nebo odhadu hodnot v geoprostorových datech. Základem je modelování prostorových korelací mezi měřenými body pomocí variogramu, který kvantifikuje, jak se podobnost (nebo korelace) mezi datovými body mění se vzdáleností (Pringle, Schmidt a Muir, 2009). Kriging používá tyto informace k vytvoření odhadů pro neznámé hodnoty v rámci určité oblasti, a to tak, že minimalizuje odhadovanou varianci chyb, což z něj činí „nejlepší lineární nezávislý prediktor“ (Rossi, Dungan a Beck, 1994).

Výsledky a aplikace

Studie a články zkoumající metody doplňování chybějících obrazových informací uvádějí různé výsledky a aplikace těchto metod v praxi. Například, výzkum provedený na satelitních snímcích ukazuje, že metody založené na neuronových sítích dosahují významně lepších výsledků v doplňování chybějících hodnot ve srovnání s tradičními metodami, jako je lineární interpolační technika (Sarafanov et al., 2020). Random Forest také vykazuje vysokou přesnost a robustnost v predikci chybějících informací a byl úspěšně použit v mnoha aplikacích zpracování obrazových dat, včetně analýzy vegetačního pokryvu a monitorování změn v krajině (Belgiu a Drăguț, 2016).

Příklady výsledků metody doplňování dat

Prvním příkladem je studie, která zdůrazňuje důležitost přesného monitorování sněhové pokrývky v horských oblastech Asie (Deng et al., 2024). Ve studii používají metodiku doplňování mezer v datech, které jsou způsobené mraky, Cloud-Gap-Filled (CGF), která kombinuje kubickou spline interpolaci, což je metoda pro nalezení přibližné hodnoty funkce v nějakém intervalu a prostorově-časově váženou metodu pro doplnění chybějících dat. CGF metoda dosáhla celkové přesnosti 93,54 – 98,08 %, což ukazuje její vysokou spolehlivost pro mapování sněhové pokrývky. Srovnání s pozemními pozorováními a snímky z Landsat-8 OLI potvrdilo vysokou shodu CGF produktu s reálnými daty, přestože zde porovnávali data různého rozlišení.

Druhým příkladem je studie, která řeší problém vyplňování datových mezer v Landsat 7 ETM+ snímcích způsobených selháním scan-line correctoru v roce 2003 (Chen et al., 2011). Autoři vyvinuli metodu Neighborhood Similar Pixel Interpolator (NSPI), která na základě spektrální podobnosti sousedních pixelů interpoluje hodnoty v mezerách. NSPI se ukázala jako velmi efektivní, s vysokou přesností obnovy dat, a to i v heterogenních oblastech a při dlouhých časových intervalech mezi snímky. Přesnost metody NSPI byla vysoká, což bylo potvrzeno srovnáním s původními daty bez mezer, kde klasifikační výsledky byly velmi srovnatelné. Vyplněné snímky neztrácely na vizuální kontinuitě, nebyly pozorovány žádné pruhy. Metoda NSPI je vhodná pro zpracování velkých objemů dat, díky své jednoduchosti a vysoké výpočetní efektivitě.

Třetím příkladem je studie, která představuje metodu pro doplňování chybějících částí v UAV ortomosaikách pomocí dat z družic PlanetScope (PS) a Sentinel-2 (S2) a algoritmu Random Forest (Pereira et al., 2023). Tento přístup nabízí zlepšení přesnosti a prostorové shody mezi rekonstruovanými a původními daty, což je klíčové

pro zemědělské aplikace. Nejlepší výsledky modelu RF byly dosaženy kombinací PS a S2 dat s chybou (RMSE) v rozmezí 6,77 – 17,33 %. Koeficienty korelace (r) a indexy shody Willmotta (d) mezi imputovanými a původními daty se pohybovaly od 0,62 do 0,73, což potvrzuje poměrně vysokou míru shody. Nejdůležitějšími prediktory pro doplnění dat byla spektrální pásmo Sentinel-2, především NIR (Near Infra Red; Blízké infračervené záření) a další pásmo jako RE4 (RedEdge4; Červené okrajové záření) a SWIR1 (Short Wave Infra Red1; Krátkovlnné infračervené záření).

3.4. Možné limity, chyby či nedostatky ve sběru dat

Přestože dálkový průzkum Země a použití moderních technologií poskytuje mnoho výhod při sběru obrazových dat, existují také určité limity, chyby a nedostatky, které je třeba brát v úvahu.

Při využívání dálkového průzkumu Země a moderních technologií pro sběr obrazových dat nastává řada výzev a omezení. Jedním z klíčových aspektů, který je třeba pečlivě zvážit, jsou atmosférické podmínky, jako jsou oblaka, mlha, aerosoly či atmosférický prach, které mohou významně ovlivnit kvalitu a čitelnost obrazových dat (Nagel, Darby a Leyland, 2023; Tafazoli, 2009). Tyto jevy mohou vést k nejasnostem a zkreslením ve snímcích, což komplikuje jejich další zpracování a interpretaci. Pro minimalizaci těchto vlivů je nutné v procesu zpracování dat aplikovat speciální algoritmy pro korekci nebo odstranění narušených dat (Hao et al., 2023).

Dalším významným problémem jsou geometrická zkreslení, která mohou vzniknout v důsledku nerovnosti terénu nebo odlišných perspektiv při snímání obrazu (Liu et al., 2018). Tato zkreslení je nutné korigovat pomocí pokročilých geometrických korekcí, jako jsou kontrolní body na zemi, aby obrazová data přesně odpovídala skutečnému stavu na zemském povrchu. Stejně tak je třeba řešit radiometrická zkreslení, která vznikají kvůli nepřesnosti v měření odraženého světla, což může být způsobeno nedokonalou kalibrací senzorů nebo variabilitou světelných podmínek (Jenerowicz, Wierzbicki a Kedzierski, 2023). Efektivní radiometrické korekce jsou proto nezbytné pro zajištění věrohodnosti získaných dat (Jenerowicz, Wierzbicki a Kedzierski, 2023).

Nelze opomenout ani chyby spojené s terénními daty, jako jsou nepřesnosti v digitálním modelu terénu nebo georeferencování, které mohou významně ovlivnit analýzu obrazových dat (Jafarbiglu a Pourreza, 2022). Použití kvalitních terénních modelů a metod georeferencování je klíčem k minimalizaci těchto zdrojů chyb.

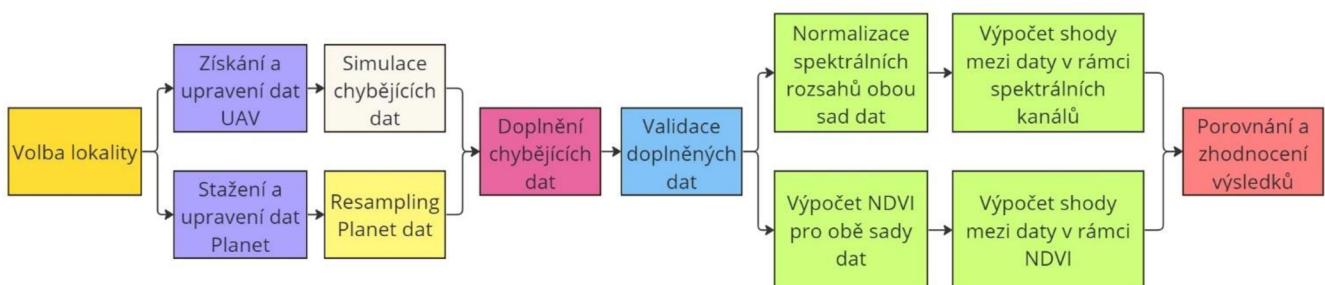
Každá metoda dálkového průzkumu Země má svá specifická omezení, včetně omezeného rozsahu pokrytí, rozlišení a schopnosti detekce určitých typů objektů či jevů. Pochopení těchto omezení je klíčové pro správnou volbu metodologie a následnou interpretaci získaných dat.

V neposlední řadě je třeba zmínit časová a finanční omezení, která mohou omezit dostupnost a kvalitu získaných dat. Může se stát, že sběr a zpracování obrazových dat bude časově i finančně náročný proces (Nagel, Darby a Leyland, 2023; Sozzi et al., 2021).

Jedním z omezení, je například vliv větru na vegetaci. Tento jev může způsobit, že vegetace na snímcích získaných pomocí bezpilotních letounů bude rozostřená (Sieberth, Wackrow a Chandler, 2014). V takových případech je nezbytné využít například optickou stabilizaci obrazu nebo elektronickou stabilizaci pro korekci pohybového zkreslení, aby bylo možné získat kvalitní a použitelná data pro další analýzu. To ne vždy však pomůže zabránit vzniku chyb při sběru dat.

4. Metodika práce

Metodika práce je strukturována do několika klíčových podkapitol, které postupně provádějí proces doplňování chybějící obrazové informace do UAV dat pomocí dat z družice PlanetScope. Vybere vhodnou lokalitu pro zpracování a analýzu potřebných dat. Poté se věnuje přípravě a pre-processingu obrazových dat, který zahrnuje převedení na stejné souřadnicové systémy, georeferencování či resampling satelitních dat. Dále se provádí oříznutí dat na oblast zájmu, aby se zmenšila celková výpočetní náročnost operace. Následuje ověření shody dat ještě před zahájením dalších operací. Poté se začne s vytvořením masky, která určí oblast pro simulaci chyb v datech. Dále se maska aplikuje na data, a nakonec se v těchto datech nahradí aplikovaná maska satelitními daty. Nakonec se provede zhodnocení modelu a analýza prostorové shody mezi původními a doplněnými daty.



Obrázek 5: Schéma metodického postupu práce

4.1. Volba lokality

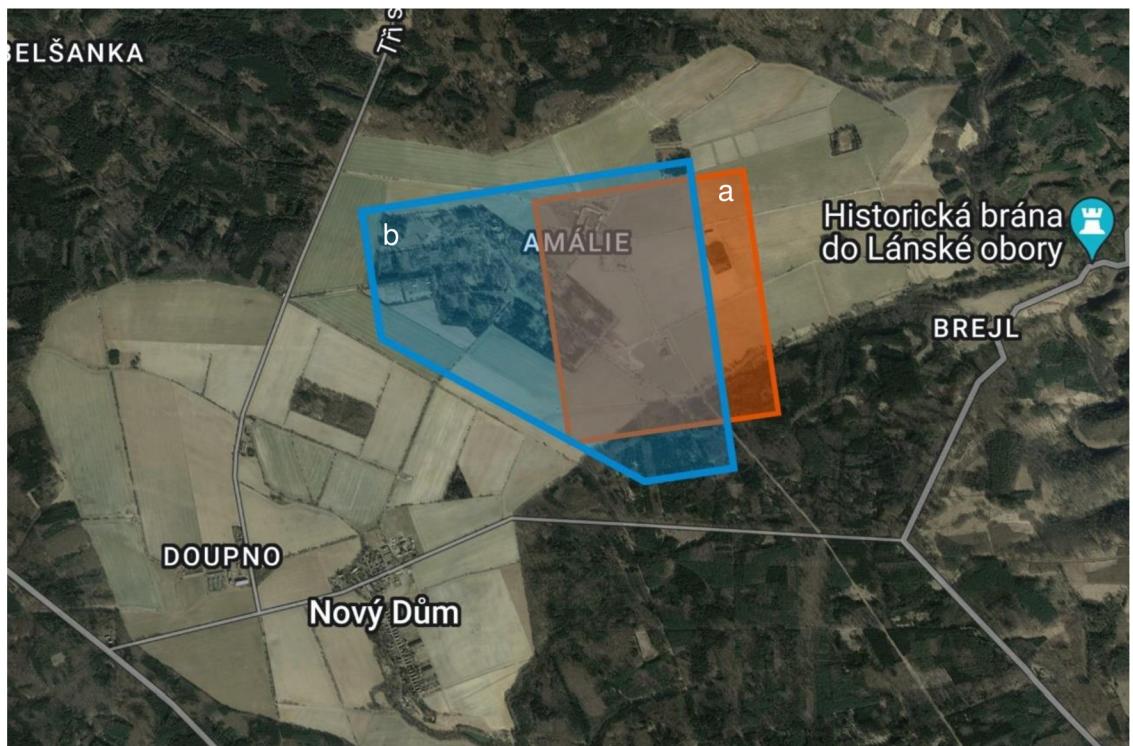
Pro zahájení analýzy a procesu doplňování chybějící obrazové informace je nezbytné zajistit přístup k vhodným datům z UAV a z družice PlanetScope. Klíčovým kritériem pro výběr satelitních snímků je minimalizace oblačnosti, což zajišťuje optimální podmínky pro kvalitní a přesné snímky. Dalším důležitým faktorem je volba studijní lokality s dostatečným výskytem relevantních jevů a objektů, které budou analyzovány. Ideálně, aby území vykazovalo větší variabilitu v typu povrchu. Tento proces zajistí, že vstupní data jsou vhodná a připravená k dalšímu zpracování a analýze.

Pro účely této práce se zvolila oblast Amálie, lokalizovaná v blízkosti Rakovníka. Tato oblast se rozkládá v mírně zvlněné krajině, charakteristické pro střední Čechy, a je obklopena převážně zemědělskými pozemky, lesy a malými vodními toky. Zvolené souřadnice naznačují existenci dvou primárních zájmových oblastí, každá s unikátními charakteristikami terénu a využitím půdy.

První oblast zájmu (viz obr. 6) se nachází v rovinatém až mírně zvlněném terénu (425 – 437 m.n.m.), kde převládá zemědělská činnost. Tato oblast je typická svou otevřenou krajinou s minimální vegetací a rozptýlenými malými lesními plochami. Zemědělské pozemky zde tvoří mozaiku různých plodin, což může ovlivnit uniformitu a interpretaci obrazových dat získaných z UAV a satelitů. Tato lokalita je v práci použita pro simulaci pruhů (viz kapitola 4.4.).

Druhá oblast zájmu (viz obr.6), umístěná jihozápadně od první, se vyznačuje větším zastoupením lesních porostů a přírodní vegetace. Tato oblast představuje výzvu pro analýzu obrazových dat z UAV a satelitů díky vyšší komplexnosti terénu a variabilitě vegetačního pokryvu. Lesní a vegetační plochy zde představují rozmanité spektrální charakteristiky, které vyžadují detailní analýzu a interpretaci. Proto je tato oblast v práci využita pro simulaci specifických výrezů různých typů ploch (viz kapitola 4.4.).

Z hlediska hodnocení prostorové shody a účinnosti metody prostorového maskování je Amálie ideálním místem pro ověření této metody na různých vegetačních pokryvech. Povrchová skladba a diverzita terénu umožňují provádět komplexní analýzy využívající data z UAV a satelitů.



Obrázek 6: (a) První lokalita zájmu $1,5 \text{ km}^2$, (b) Druhá lokalita zájmu $2,3 \text{ km}^2$ (Mapy Google, 2024)

4.2. Použitá data

Pro účely této práce byly zvoleny UAV snímky pořízené 8.9.2021 Katedrou prostorových věd na České zemědělské univerzitě v Praze. Jedná se už o hotovou a radiometricky kalibrovanou ortomozaiku získanou dronem s pevným křídlem eBee X vybaveným multispektrální kamerou MicaSense RedEdge MX (AgEagle, 2024). Tento optický senzor umožňuje zachytit detailní obraz terénu a zároveň poskytuje bohaté spektrální informace pro další analýzu vegetace a krajiny. Disponuje pěti spektrálními kanály, přičemž každý kanál má rozlišení 1,2 megapixelu (AgEagle, 2024).



Obrázek 7: UAV ortomozaika zájmové lokality

Mica Sense RedEdge MX

Tabulka 3: Spektrální rozsahy MicaSense RedEdge MX (AgEagle, 2024)

Pásma	Číslo pásma	Střední vlnová délka (nm)	Šířka pásma (nm)
Modré (Blue)	1	475	32
Zelené (Green)	2	560	27
Červené (Red)	3	668	16
Red edge	4	717	12
NIR	5	842	57

Konkrétní rozlišení snímku, co používá tato studie je $0,238 \times 0,238$ metru na pixel, což bylo zjištěno v RStudiu za pomocí funkce `res`.



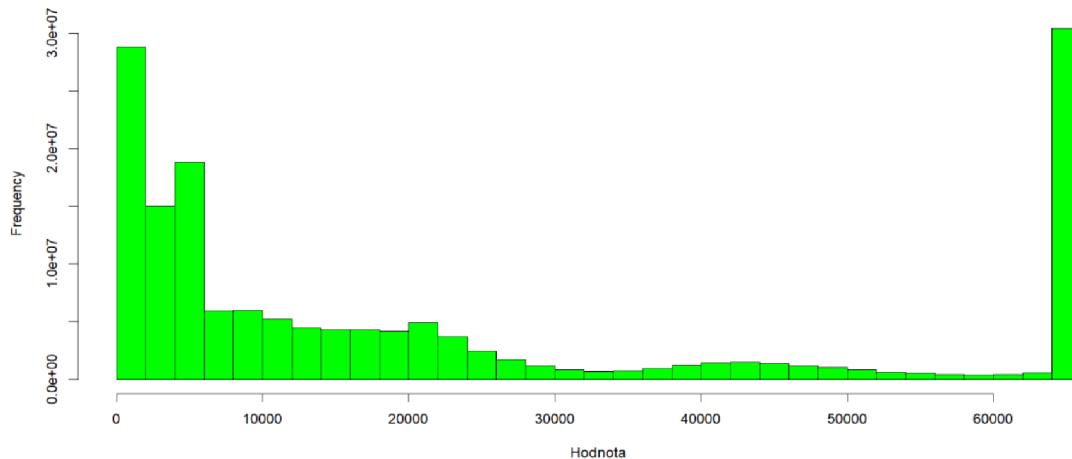
Obrázek 8: Dron eBee X (AgEagle, 2012)



Obrázek 9: Multispektrální kamera MicaSense RedEdge MX (AgEagle, 2024)

Tabulka 4: Parametry multispektrální kamery MicaSense RedEdge MX (AgEagle, 2024)

Parametr	Multispektrální
Velikost pixelu	3,75 µm
Rozlišení	1280 x 960 (1,2 MP x 5 snímačů)
Poměr stran	4:3
Velikost snímače	4,8 mm x 3,6 mm
Ohnisková vzdálenost	5,4 mm
Zorné pole	47,2 stupně horizontálně, 35,4 stupně vertikálně
Hloubka bitového výstupu	12-bit
GSD @ 120 m	8 cm/pixel na pásmo
GSD @ 60 m	4 cm/pixel na pásmo



Obrázek 10: Histogram multispektrálních UAV dat na zájmové území

V tabulce č. 5 jsou získané rozsahy spektrálních kanálů z metadat z programu QGIS.

Tabulka 5: Rozsahy spektrálních kanálů multispektrálních UAV dat zájmového území

Číslo	Kanál	Min	Max
1	Kanál 1	209	35617
2	Kanál 2	290	52691
3	Kanál 3	96	65345
4	Kanál 4	531	65535
5	Kanál 5	3191	65535

Dále byl pro srovnání využit bezoblačný snímek z družice PlanetScope, pořízený o den později tedy 9.9.2021. Konkrétně ze satelitu SuperDove, který má charakteristiky viz tabulka č. 6 a je provozován od roku 2020 (Safyan, 2020). Vyznačuje se rozlišením 3 metry na pixel a nabízí široké spektrální pokrytí, a to osmi spektrálními pásmi (viz tabulka 6).

Planet data byla stažena na webových stránkách Planet Explorer (Planet Explorer, 2024). Tento snímek byl vybrán pro svou vysokou kvalitu a absenci oblačnosti, což je klíčové pro efektivní provádění simulací a porovnání s daty z dronu. Snímek PlanetScope poskytuje široký přehled o zájmové oblasti s dostatečným rozlišením pro komplementární analýzu k datům získaným dronem.



Obrázek 11: Snímek PlanetScope PSB.SD zájmové lokality

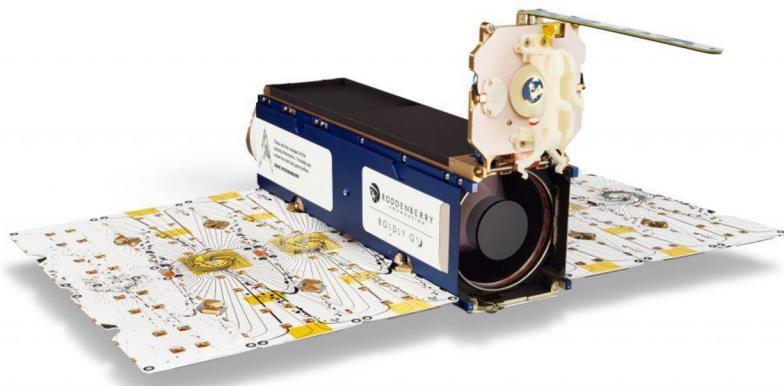
PlanetScope – SuperDove

Tabulka 6: Rozsahy spektrálních pásem u PlanetScope SuperDove (PlanetScope – Earth Online, 2024)

Pásma	Číslo pásma	Rozsah (nm)
Pobřežní modrá (Coastal Blue)	1	431 - 452
Modrá (Blue)	2	465 – 515
Zelená I (Green I)	3	513 - 549
Zelená II (Green II)	4	547 – 583
Žlutá (Yellow)	5	600 - 620
Červená (Red)	6	650 – 680
RedEdge	7	697 – 713
NIR	8	845 – 885

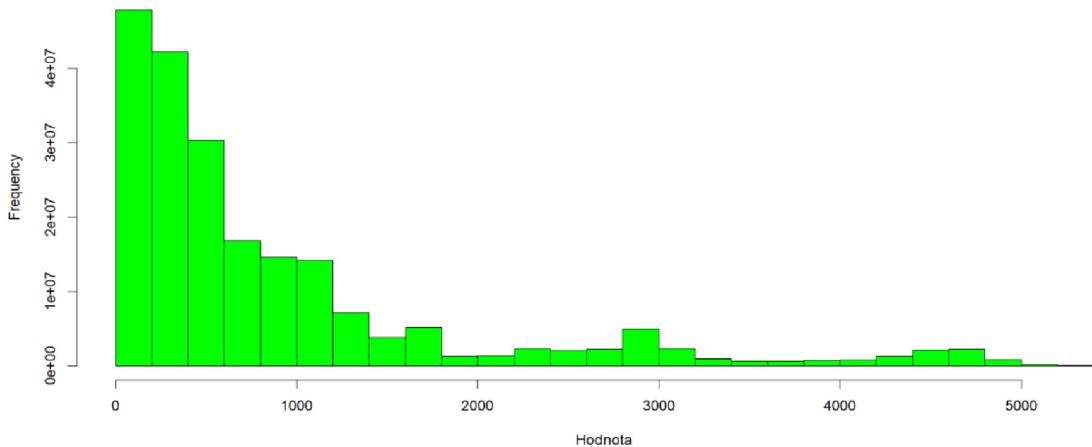
Tabulka 7: (PlanetScope – Earth Online, 2024; PlanetScope, 2024; Planet, 2023)

Parametr	Hodnota
Název satelitu (formát)	SuperDove (PSB.SD)
Orbitální výška	475 km - 525 km
Typ oběžné dráhy	Helio-synchronní
Inklinace	98°
Opakovací cyklus	Denně
Čas přechodu přes rovník	9:30 - 11:30 (místní solární čas)
GSD (nadir)	3,7 m - dodáváno ve 3,0 m
Velikost snímku	32,5 km x 19,6 km (přibližně)
Maximální délka pruhu na oběžné dráze	20,000 km ²
Revisit Time (opakovací cyklus)	Denně v nadiru
Kapacita snímání obrazu	200 milionů km ² /den



Obrázek 12: Satelit SuperDove (Planet, 2022)

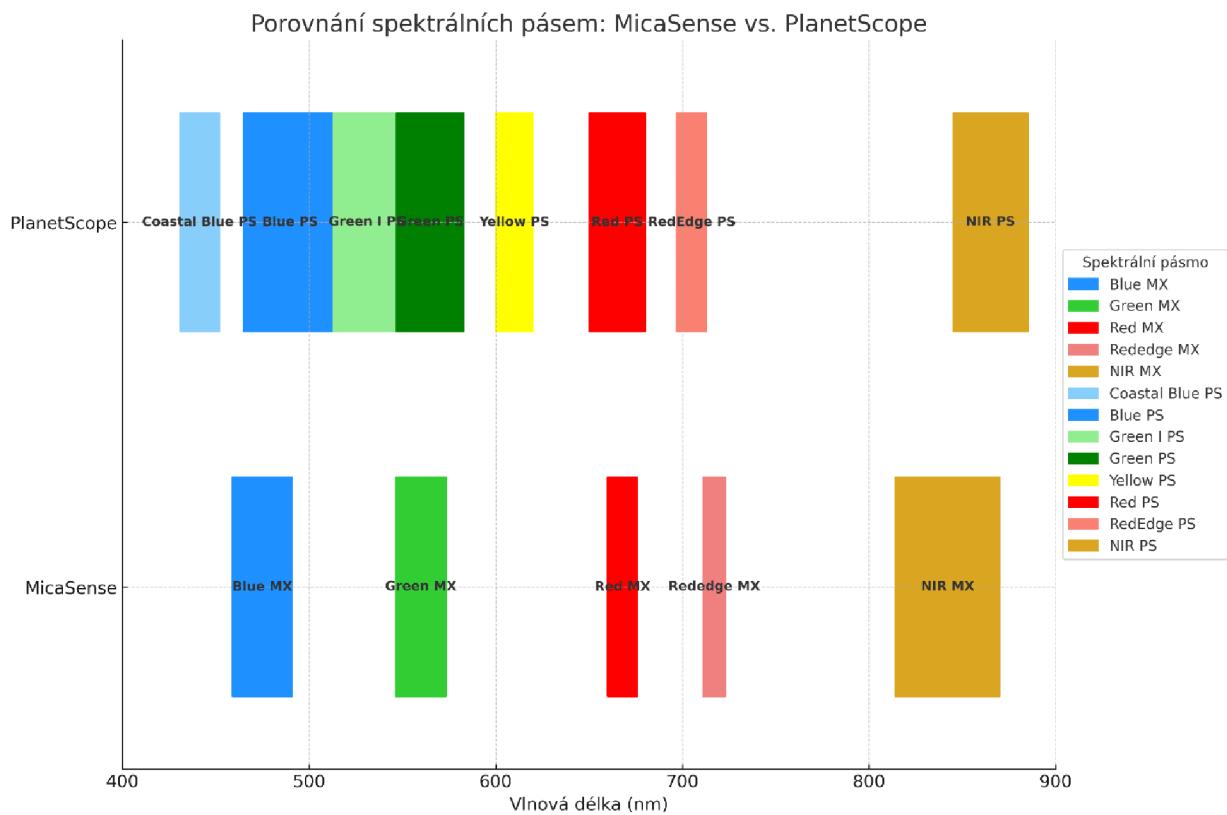
Konkrétní rozlišení původního snímku, co používá tato studie je $3,36 \times 2,61$ metru na pixel, což bylo zjištěno v RStudiu za pomocí funkce `res`. Resamplování na stejně rozlišení jako mají UAV data je popsáno v kapitole 4.3.



Obrázek 13: Histogram resamplovaných Planet dat zájmového území

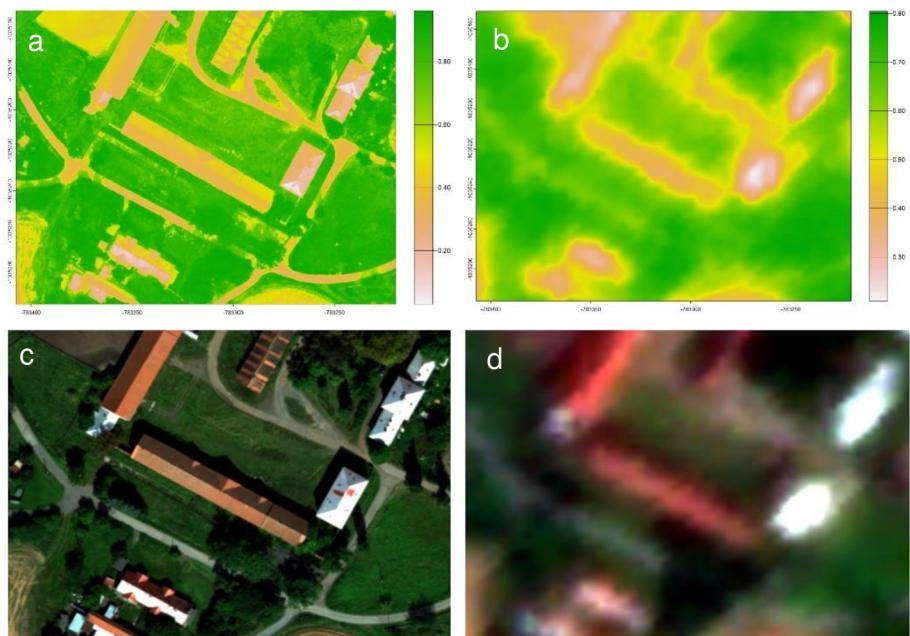
Tabulka 8: Rozsahy spektrálních kanálů u Planet dat po resamplingu na UAV rozlišení zájmového území

Cílo	Kanál	Min	Max
1	Kanál 1	1	1381
2	Kanál 2	20	1565
3	Kanál 3	77	1641
4	Kanál 4	118	1752
5	Kanál 5	109	2006
6	Kanál 6	82	2117
7	Kanál 7	204	2419
8	Kanál 8	705	5220



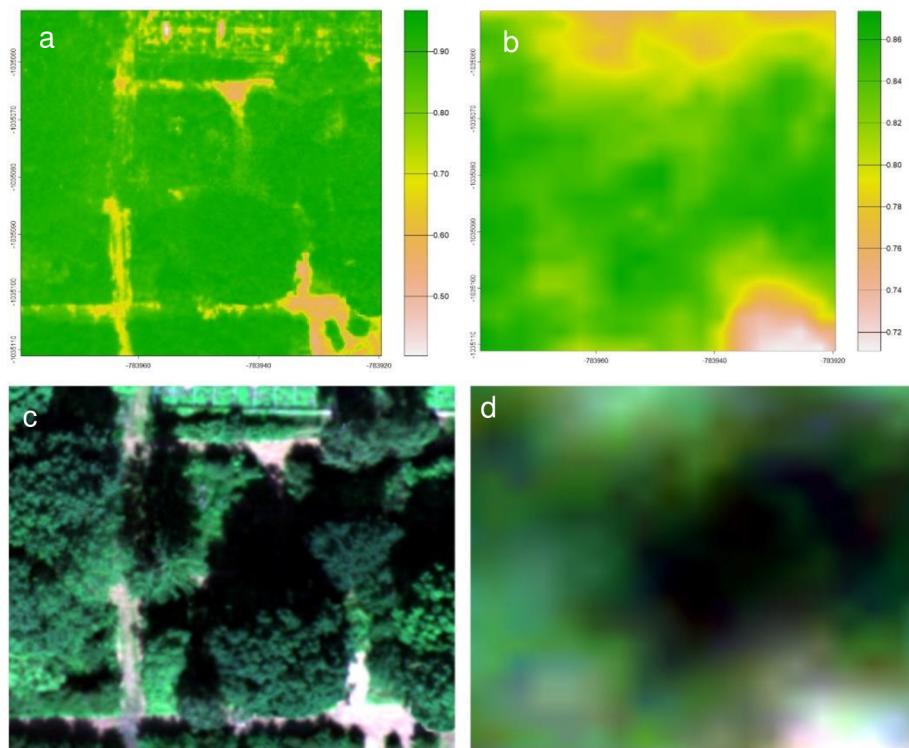
Obrázek 14: Porovnání rozsahů spektrálních pásem: MicaSense vs. PlanetScope

Srovnání rozlišení obou dat v projekci NDVI a RGB čtvercového charakteru o rozměrech 60x60 metrů (viz obr. 15).



Obrázek 15: Srovnání rozlišení v projekci NDVI a RGB. (a) NDVI UAV, (b) NDVI Planet, (c) RGB UAV, (d) RGB Planet

Zde je příklad toho, jak vypadá rozdíl na vzorku členité vegetace (viz obr. 16).



Obrázek 16: Srovnání rozlišení v projekci NDVI a RGB. (a) NDVI UAV, (b) NDVI Planet, (c) RGB UAV, (d) RGB Planet

4.3. Pre-processing dat

Předzpracování dat představuje zásadní fázi v procesu analýzy geoprostorových dat, která zahrnuje řadu kroků zaměřených na přípravu a optimalizaci dat pro následné zpracování. V kontextu této studie, zaměřené na integraci Planet dat do UAV, se práce setkává s několika klíčovými úkoly předzpracování, které jsou nezbytné pro dosažení kvalitních a spolehlivých výsledků.

Prvním krokem je převedení získaných dat do správných souřadnicových systémů. Vzhledem k tomu, že data z UAV jsou již ve vybraném souřadnicovém systému S - JTSK/Krovak East North - SJTSK - EPSG:5514, zatímco data Planet jsou ve formátu EPSG:32633 – WGS 84/UTM zone 33N, tak je nutné zajistit, aby všechna data byla v jednotném souřadnicovém systému. Pro harmonizaci souřadnicových systémů poslouží open-source program QGIS, který umožňuje efektivní transformaci prostorových dat.

Druhým krokem je georeferencování obou dat, které zahrnuje přiřazení konkrétních geografických souřadnic snímkům získaným z UAV, což umožňuje jejich správné

umístění v rámci geografického prostoru. Tento krok byl proveden vůči ověřené podkladové ortofotomapě z ČÚZK v programu ArcGIS Pro. Pokud by se tento krok vynechal, data by po doplnění na sebe nemusela správně „pasovat“ a byla by tím pádem vůči sobě prostorově posunutá.

Následná registrace dat pak zajišťuje, že snímky z UAV a snímky získané z družice Planet jsou vzájemně přesně zarovnané. To je dosaženo porovnáním referenčních bodů, které jsou společné pro oba typy snímků, a jejich následným upravením tak, aby odpovídaly stejným lokacím. Tento proces je zásadní pro zajištění, že doplnění dat z družice Planet do oblastí chybějících na snímcích UAV bude co nejpřesnější.

Dalším klíčovým krokem je resamplování Planet dat na stejné rozlišení jako data z UAV. Tento postup zahrnuje použití metody "bilinear" v RStudiu (viz skript 1), což je technika, která umožňuje jemnou lineární interpolaci hodnot mezi pixely a zajišťuje zachování kvality dat při změně rozlišení. Tímto způsobem je možné zajistit, že obě sady dat budou mít stejné rozlišení a budou tak vhodné pro přímé porovnání. V této studii je provedeno resamplování dat ze satelitu na základě rozlišení UAV snímků, aby byla zachována co nejvyšší kvalita výstupních dat.

Skript 1: Resamplování Planet dat na rozlišení UAV

```
planet_resampled <- resample(planet_data, uav_data, method="bilinear")
```

Zásadním krokem předzpracování je také oříznutí dat na zájmovou oblast podle specificky vybraných souřadnic. Tento proces umožňuje eliminaci nadbytečných dat mimo zájmovou lokalitu, což vede k zjednodušení a zrychlení následného zpracování v RStudiu. Provedení ořezu je realizováno v programu QGIS, kde funkce pro ořezávání („oříznout rastr podle rozsahu“) podle souřadnic umožní přesné vymezení a extrakci zájmové oblasti z celkových datových sad.

Implementace těchto kroků pre-processingu je nezbytná pro zajištění kompatibility, přesnosti a efektivity při zpracování a analýze kombinovaných dat z UAV a Planet. Díky pečlivému předzpracování je pak možné efektivně využít dostupné výpočetní zdroje a zaměřit se na hloubkovou analýzu dat s vysokou přidanou hodnotou. Předzpracování dat představuje klíčový krok pro úspěšné provádění dalších analýz a získání spolehlivých výsledků, které přinášejí nové poznatky o sledovaných jevech.

4.4. Simulace chyb v UAV ortomozaice

V rámci této studie je kladen velký důraz na ověření schopnosti navrhnuté metody prostorového maskování pro doplňování chybějících dat v UAV ortomozaikách. Klíčovým prvkem je nasimulovat chyby ve formě pruhů nebo výrezů, které by mohly odpovídat potenciálním chybějícím oblastem v reálných UAV snímcích, způsobené například technickými problémy UAV, špatným počasím nebo překážkami v terénu, které zabraňují úplnému pokrytí oblasti snímkování. Tento postup umožňuje testovat účinnost různých metod doplnění dat a posoudit jejich přesnost a spolehlivost.

Proces simulace chyb (viz kapitola 4.4.1.) je realizován v prostředí RStudio, kde je možné využít GPS souřadnic pro definování lokalit chybějících dat. Tento přístup umožňuje vytvoření přesně vymezených oblastí chyb, které jsou následně v ortomozaikách vyjmuty. Výběr konkrétních souřadnic pro simulaci je motivován touhou zaměřit se na specifické zájmové území, což je klíčové pro testování metod doplnění na relevantních datech. Zároveň to zajistí vyšší validitu zjištěných výsledků a jejich aplikovatelnost v reálných podmírkách. Práce provádí celkem třicet kombinací simulace chybějící části pomocí svislých pruhů (viz kapitola 9). Simulace jsou definovány od jednoho až po pět pruhů, s tím že ke každé variantě je simulováno vždy 5 %, 25 % a 50 % z celkového území. Jako dalším současným cílem je ověření nahrazování chybějící informace na různých typech LULC (Land Use Land Cover; Využití a pokryv půdy). Studie se zaměřuje na pět odlišných povrchů se stejnými rozlohami pro extrakci dat. Vždy to je čtverec o rozloze 60x60 metrů, který odebírá 0,12 % z celkového území rastru. Ta území jsou výrez se zástavbou, členitým povrchem tráva-stromy, smíšeným lesem, polem s vyrašenou setbou a zelenou loukou. Tato fáze projektu je zásadní pro pochopení limitů a potenciálu zvolené metody doplnění UAV dat.

Prvním krokem je načtení a příprava UAV ortomozaik pro simulaci chyb. Data jsou importována do prostředí RStudio, kde jsou připraveny pro další zpracování. Tento proces zahrnuje určení a definování oblastí, kde jsou simulovány chyby, s využitím přesných GPS souřadnic.

Skript 2: Definování souřadnic a vytvoření polygonu pro simulaci chyby v UAV datech

```
# Souřadnice pro simulaci chybějící části v UAV datech
coords_missing_part <- matrix(c(
  -783367.33, -1035150.64, # Souřadnice 1
  -783407.50, -1035252.61, # Souřadnice 2
  -783254.56, -1035295.98, # Souřadnice 3
  -783219.82, -1035191.74 # Souřadnice 4
), byrow = TRUE, ncol = 2)

# Vytvoření polygonu pro simulovalou chybějící část
missing_part_poly <- vect(coords_missing_part, type="polygons",
  crs="+init=epsg:5514")
```

4.4.1. Simulace chybějících dat

Proces simulace chyb je realizován s cílem vytvořit v ortomozaikách přesně definované výřezy, které by simulovaly chybějící data. Pro tento krok se používají specifické nástroje v RStudiu, které umožňují vyjmutí určených oblastí z celkového snímku. Simulace takto vytvořených chyb následně poslouží jako základ pro testování zvolené metody a posouzení její schopnosti efektivně obnovit chybějící informace.

Vytvoření masky chybějících dat

Pomocí funkce *rast* z balíčku *terra* se vytvoří maska s hodnotou 1 (představující přítomná data) pro celý snímek a následně se určitá oblast (definovaná šírkou pruhu a jeho umístěním v rámci snímku) nastaví na NA (hodnota představující chybějící data). Tento krok vytvoří masku, která poslouží k tomu, aby mohla být aplikována na UAV data.

Skript 3: Vytvoření maskovacího rastru pomocí definovaného polygonu

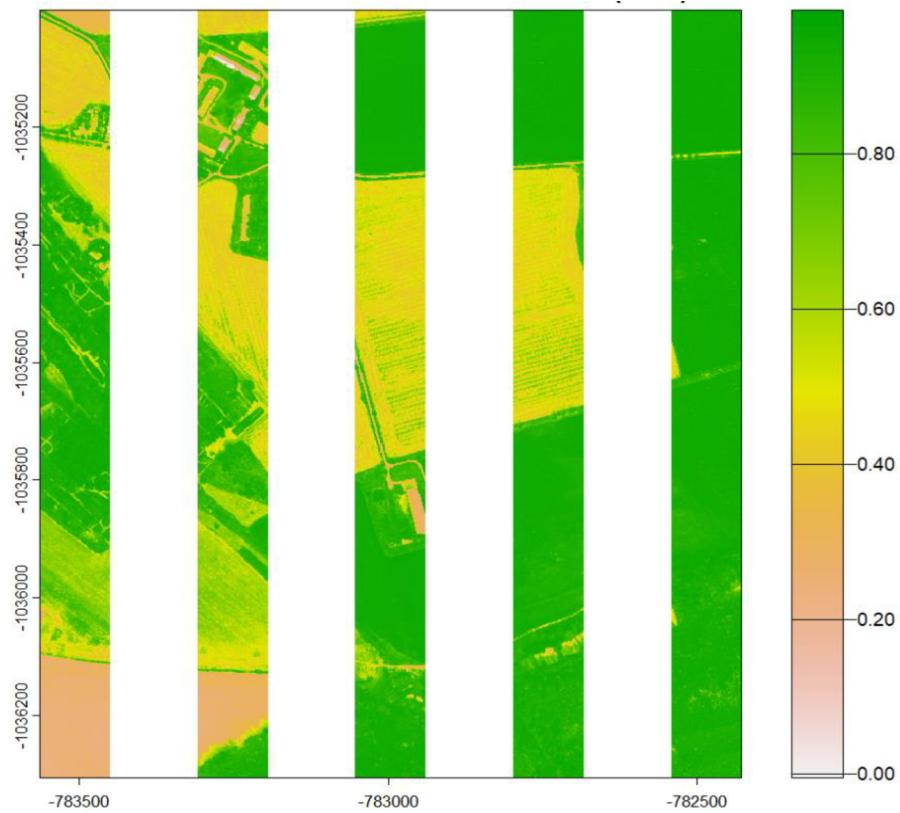
```
# Vytvoření maskovacího rastru s hodnotou NA uvnitř polygonu a 1 mimo něj
mask_raster <- rasterize(missing_part_poly, uav_data_povrchy, field=1,
  background=NA)
```

4.4.2. Aplikace masky na UAV data

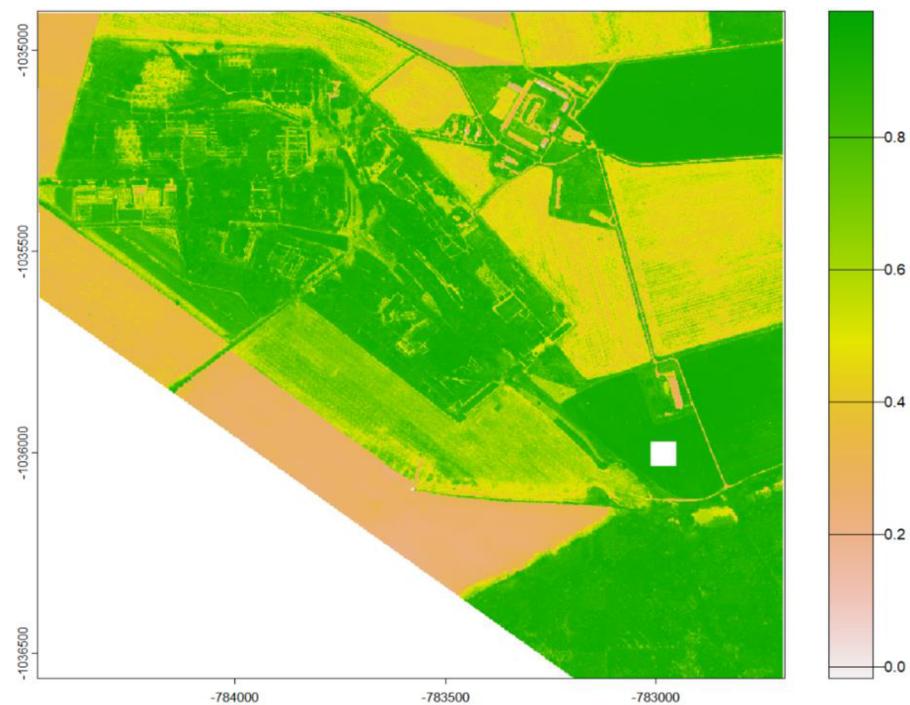
Aplikací masky chybějících dat na původní snímek UAV pomocí funkce *mask* se vytvoří nový snímek, kde jsou místa určená maskou vyneschána, čímž vznikne chyba ve snímku. Tato metoda simulace chybějících dat umožňuje testování a demonstraci procesů doplnování dat.

Skript 4: Aplikace masky na UAV data

```
# Aplikace masky tak, aby data uvnitř polygonu byla chybějící  
uav_missing_part <- mask(uav_data_povrchy, mask_raster, maskvalue=1)
```



Obrázek 17: Příklad aplikace masky na UAV data ve formě pruhů (50 % chyby)



Obrázek 18: Příklad aplikace masky pro specifické LULC na UAV data (0,12 % chyby)

4.5. Modelování a doplnění dat

Tato práce provádí několik klíčových kroků zaměřených na modelování a doplnění dat. Tyto procesy jsou zásadní pro zajištění kontinuity a kvality snímků získaných z UAV, které mohou být ovlivněny různými faktory, jako jsou technické chyby, nepříznivé povětrnostní podmínky nebo překážky v terénu.

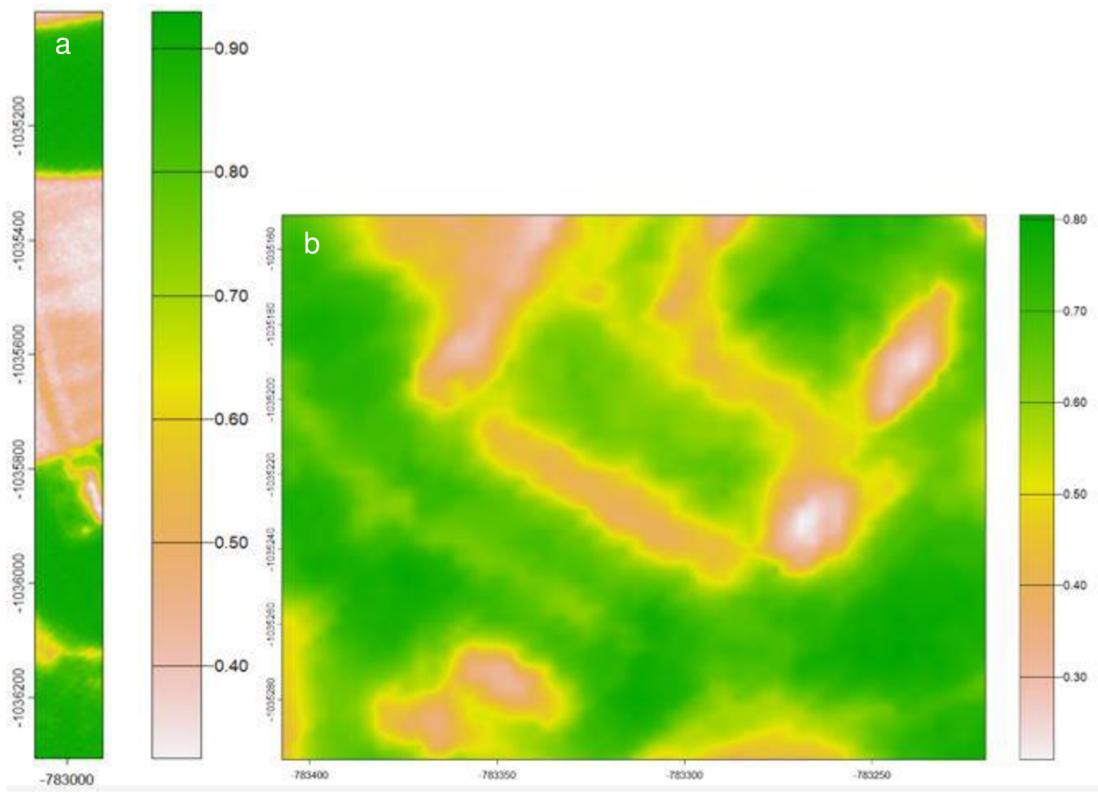
4.5.1. Extrakce satelitních dat pro doplnění

Skript 5: Vyříznutí části Planet dat, odpovídající chybějící části v UAV datech

```
# Vyříznutí části z Planet datasetu odpovídající chybějící části v UAV datasetu  
planet_strips <- crop(planet_data_povrchy, missing_part_poly)
```

V tomto konkrétním případě se používá funkce *crop* z balíčku *raster* pro práci s rastrovými daty v RStudiu. Funkce *crop* je navržena tak, aby z většího datasetu (zde Planet dataset) vyřízla menší specifickou část, která přesně odpovídá definovanému geografickému rozsahu. Vstupem pro tuto funkci je polygon, který reprezentuje geografický rozsah chybějící části v UAV datasetu, označený zde jako *missing_part_poly*. Tento polygon slouží jako maska, která určuje, jaká specifická část dat Planet má být vyříznuta a následně použita pro doplnění odpovídajících chybějících částí v UAV datasetu.

Výsledkem této operace je subset dat Planet, zvaný *planet_strips*, který obsahuje pouze ty oblasti satelitních dat, které jsou potřebné pro doplnění chybějících částí v UAV snímcích. Data *planet_strips* slouží v kapitole 4.6.1. pro validaci. Tento proces je klíčovým krokem v metodologii doplnění chybějících dat, protože umožňuje přesné a cílené zaplnění mezer v datech získaných z UAV pomocí vysoce kvalitních a aktuálních satelitních snímků poskytovaných satelity Planet.



Obrázek 19: (a) Výřez Planet dat pro doplnění UAV dat – verze doplnění výřezu daného pruhu, (b) Výřez Planet dat pro doplnění UAV dat – verze doplnění výřezu daného LULC (Land Use Land Cover; Využití a pokryv půdy)

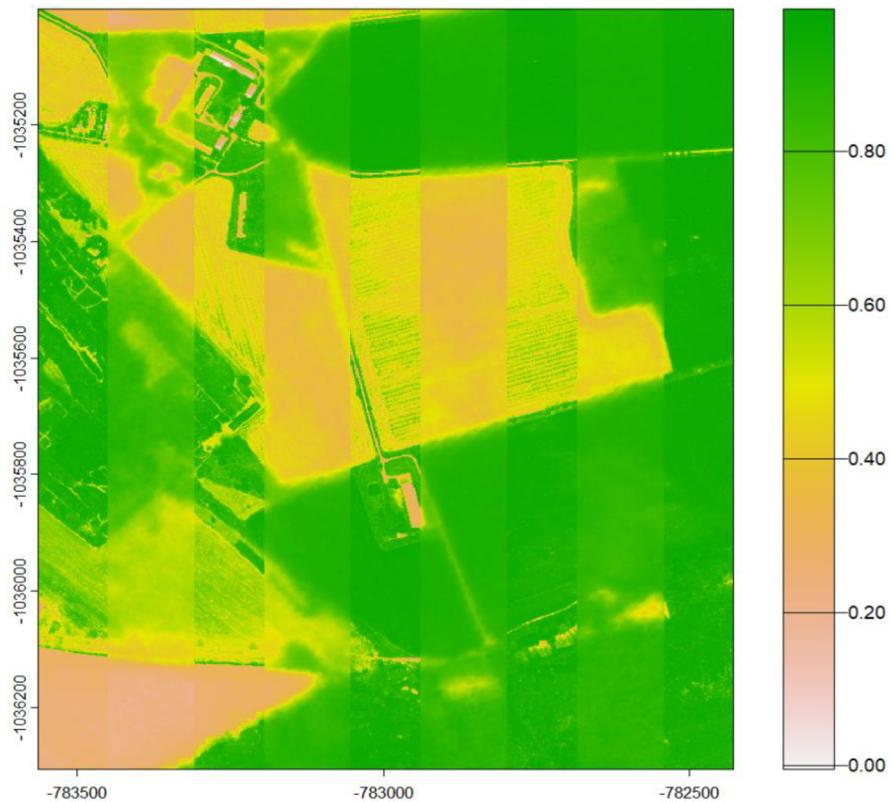
4.5.2. Interpolace a doplnění chybějících dat pomocí snímků Planet

Interpolace představuje metodu, která na základě dostupných dat z okolních nepoškozených oblastí vytváří odhady pro chybějící či poškozené segmenty obrazu, což v případě této práce reprezentují simulované NA hodnoty. V tomto projektu se pro doplnění chybějících dat využívají snímky vysokého rozlišení z družic Planet. Tyto snímky poskytují dostatečně detailní informace umožňující efektivní rekonstrukci chybějících částí v UAV snímcích.

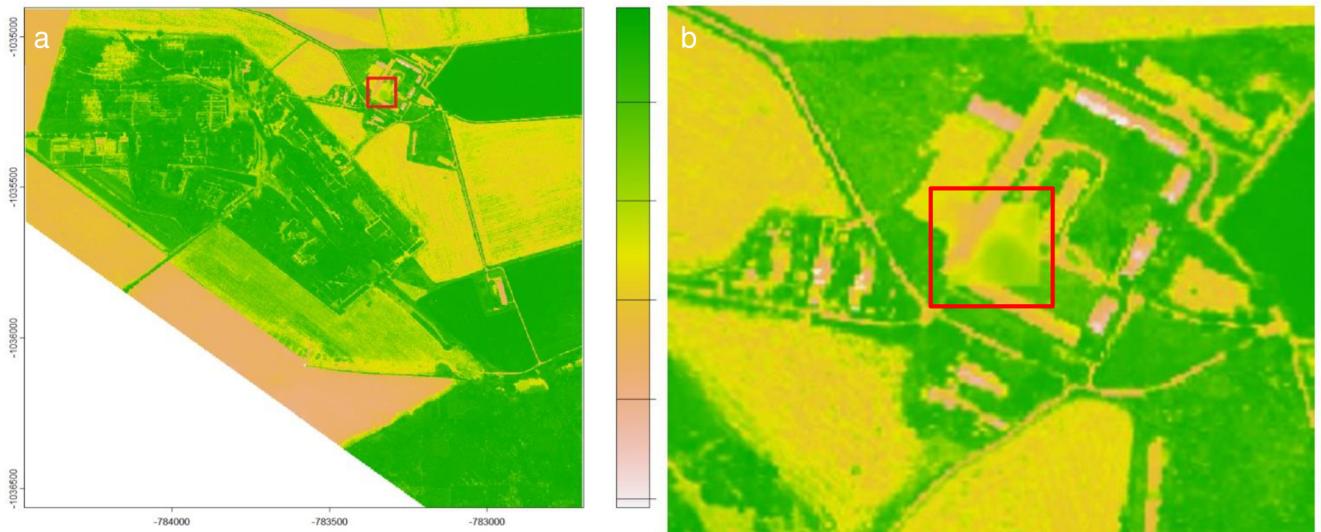
Pomocí funkce *cover* se doplní chybějící data ve snímku UAV z vyříznutého pruhu Planet dat. Tato funkce sloučí původní snímek UAV s vyříznutým pruhem z dat Planet tak, že chybějící hodnoty (NA) ve snímku UAV jsou nahrazeny odpovídajícími hodnotami z pruhu družicových dat (viz skript 6). Tuto operaci lze také provést pomocí neoříznutých Planet dat. Funkce *cover* totiž nejprve prověří pro každý pixel v hlavní vrstvě, zda hodnota existuje. Pokud je hodnota NA, funkce vyhledá hodnotu ve stejné lokaci v překryvné vrstvě (Planet data). První náhradní hodnota (která není NA) z překryvné vrstvy je použita k nahrazení chybějící hodnoty v hlavní vrstvě.

Skript 6: Vyříznutí části Planet dat odpovídající chybějící části v UAV datech

```
# Nahrazení chybějící části v UAV datasetu odpovídajícími daty z Planet datasetu  
uav_filled_with_planet <- cover(uav_missing_part, planet_strips)
```



Obrázek 20: Výsledek metody doplnění UAV dat Planet daty – zobrazení NDVI (50 % chyby, doplnění čtyřech pruhů)



Obrázek 21: (a) Výsledek metody doplnění UAV dat Planet daty – NDVI zobrazení (0,12 % chyby, doplnění výrezu zástavby), (b) Detail doplnění části zástavby (rozměry 60x60 metrů)

4.6. Hodnocení modelu a analýza shody

Hodnocení modelu a analýza shody jsou klíčové kroky k zajištění spolehlivosti a přesnosti procesu doplnění chybějících dat v UAV ortomozaikách pomocí dat z družice Planet. Tato fáze projektu se zaměřuje na ověření, že doplněná data odpovídají reálným podmínkám a že model efektivně obnovil chybějící informace bez větší ztráty na kvalitě.

4.6.1. Validace doplněných dat Planet do UAV ortomozaiky

Proces validace zahrnuje srovnání doplněných oblastí s jejich skutečnými, původními protějšky zájmové oblasti. Cílem je identifikovat a kvantifikovat jakékoli rozdíly mezi původními UAV snímky a doplněnými daty a určit míru shody mezi nimi.

Hodnocení shody na základě statistických koeficientů

RMSE (Root Mean Square Error)

Je to statistická metrika používaná k hodnocení rozdílů mezi hodnotami predikovanými modely a skutečně pozorovanými hodnotami. Vyjadřuje průměrnou velikost chyby v jednotkách proměnné. RMSE je definována jako odmocnina ze středního kvadratického rozdílu mezi predikovanými a skutečnými hodnotami. Hodnota RMSE je vždy nezáporná, a čím je nižší, tím přesnější model je. Tento model potřebuje normalizaci dat, jelikož bez normalizace může být RMSE ovlivněno rozdíly v rozsahu hodnot mezi dvěma soubory dat. Tedy pomáhá zajistit, že RMSE bere v úvahu relativní velikost odchylek mezi daty (Chai a Draxler, 2014; Pereira et al., 2023).

Pearsonův koeficient korelace

Ukazuje míru lineární závislosti mezi dvěma proměnnými. Jeho hodnota se pohybuje od -1 do 1, kde 1 znamená dokonalou pozitivní korelací, -1 znamená dokonalou negativní korelací a 0 znamená žádnou korelací. Tento koeficient nemá vliv na rozsah hodnot. Proto normalizace není potřebná, protože hodnoty jsou již v poměrném měřítku (Kleijnen, 1999; Nettleton, 2014).

Willmottův index

Je to metrika podobná koeficientu determinace R^2 , která měří podobnost mezi dvěma soubory hodnot. Hodnota Willmottova indexu blízká 1 naznačuje vysokou podobnost mezi daty. Bez normalizace může být index ovlivněn rozdíly v rozsahu hodnot mezi

soubory dat, což může vést k nepřesné interpretaci míry podobnosti (Willmott, Robeson a Matsuura, 2012).

MAE (Mean Absolute Error)

Udává průměrnou absolutní odchylku mezi dvěma soubory hodnot. Stejně jako u RMSE, i zde se jedná o absolutní odchylku, která závisí na rozsahu vstupních dat. Bez normalizace může být MAE ovlivněno rozdíly v rozsahu hodnot mezi soubory dat, což může vést k nepřesné interpretaci míry chyby (Chai a Draxler, 2014).

Koeficient determinace R²

Je alternativní způsob vyjádření koeficientu determinace, který je kvadrátem Pearsonova koeficientu. Opět ukazuje, jak dobře jsou data modelována lineárním modelem. Protože Pearsonův koeficient korelace není ovlivněn rozsahem hodnot, normalizace není nutná (Romeo, 2020; Pereira et al., 2023).

RMSE %

RMSE v procentech vyjadřuje RMSE jako procento z rozsahu hodnot mezi dvěma soubory dat. Protože se RMSE v procentech již vyjadřuje relativně k rozsahu dat, normalizace není potřebná (Chai a Draxler, 2014).

Tyto metriky poskytují různé pohledy na kvalitu shody mezi satelitními a UAV daty v různých kanálech. Jejich rozdílné hodnoty mezi kanály mohou naznačovat různé úrovně kvality nebo úrovně shody dat v různých spektrálních oblastech.

Hodnocení shody na základě NDVI

Normalizovaný rozdílový vegetační index, známý pod zkratkou NDVI (Normalized Difference Vegetation Index; Normalizovaný rozdílový vegetační index), představuje klíčový nástroj pro hodnocení vitality zdraví vegetace pomocí DPZ (Xue a Su, 2017). Tato metoda spočívá v aplikaci jednoduchého vzorce, který umožňuje zjištění zdravotního stavu vegetace na základě odrazivosti ve dvou specifických spektrálních pásmech. Červeném pásmu a blízkém infračerveném. Základní rovnice tohoto indexu, jehož hodnoty se pohybují v rozmezí od -1 do 1, slouží k identifikaci husté a vitální vegetace, kde vyšší hodnoty indikují zdravé rostlinstvo, zatímco nižší hodnoty naznačují vegetaci poškozenou nebo zcela chybějící (Huang et al., 2021).

Jedním z prvních a klíčových kroků je porovnat shodu předzpracovaných dat, abychom zjistili míru jejich vzájemného souladu či rozdílů ještě před samotným procesem doplňování. Provedou se statistické výpočty mezi UAV daty a satelitními daty jak pro všechny pět spektrálních kanálů, které jsou společné, tak i pro vegetační

index NDVI. Po následném provedení nahrazení informace v UAV datech pomocí dat Planet se hodnotí účinnost použité metody prostorového maskování pomocí RMSE (Root Mean Square Error; Kořenová střední kvadratická chyba), koeficient determinace R^2 , RMSE % nebo MAE (Mean Absolute Error; Průměrná absolutní chyba). Dále se hodnotí prostorová shoda pomocí Pearsonova korelačního koeficientu a Willmottova indexu. Metody validace také zahrnují vizuální porovnání, kde se posuzuje kvalita a kontinuita doplněných oblastí.

Analýza shody následně umožňuje identifikovat oblasti, kde model exceluje a oblasti, které vyžadují další zlepšení. Tento proces nejenže poskytuje zpětnou vazbu pro iterativní zdokonalení modelu, ale také pomáhá stanovit omezení a nejlepší využití modelu pro budoucí aplikace.

Při porovnávání shody s využitím NDVI je zde výhoda, že data nepotřebují normalizaci díky charakteristice vzorce NDVI, který kompenzuje rozdíly ve spektrálních pásmech (Huang et al., 2021). Nicméně je nutné provést výpočet NDVI zvlášť pro oblasti, kde UAV data chybí a následně pro doplňující Planet data, jelikož by vznikly rozdíly na barevné škále právě z důvodu odlišnosti počtu kanálů a jejich rozdílnému pořadí. Tyto dvě sady výsledků je potom třeba opět sloučit zpět do jednotného datasetu. Je to stejná metoda pomocí funkce *cover* (viz skript 6).

Hodnocení shody na základě spektrálních kanálů

Jako první aspekt při hodnocení na základě spektrálních kanálů, na který je třeba pomyslet, je normalizace dat. Normalizace je klíčovým krokem při zpracování obrazových dat a má několik pádných důvodů.

Jak je vidět z minima a maxima jednotlivých pásem (viz tabulka 5), rozsahy hodnot se mezi UAV a satelitními daty značně liší. Bez normalizace by přímé porovnání těchto dat mohlo být zavádějící, protože stejné hodnoty by měly odlišný význam v kontextu každého zdroje (Pereira et al., 2023).

Různé senzory každého z porovnávaných datasetů zaznamenávají objekty na zemi s odlišnými intenzitami kvůli rozdílným spektrálním odezvám, což vede k variabilitě v reprezentaci fyzikálních veličin jako odrazivost nebo teplota. Normalizace těchto dat minimalizuje tyto rozdíly a umožňuje efektivnější porovnání a analýzu napříč různými zdroji (Pereira et al., 2023).

Postup pro normalizaci dat a kanálů

Jelikož má senzor MicaSense RedEdge MX pouze pět spektrálních kanálů a SuperDove jich má osm, tak lze porovnat pouze těch pět, které mají oba datasety společné. Nejdříve se získá informace o počtu kanálů a jejich rozsahu z poskytnutých dat od poskytovatele. U planet dat (PlanetScope - SuperDove) bylo pořadí kanálů 2, 4, 6, 7, 8 (Blue, Green, Red, Red-Edge, NIR) (viz tabulka 6), zatímco u UAV dat (Micasense RedEdge MX) bylo pořadí kanálů 1, 2, 3, 4, 5 (Blue, Green, Red, Red-Edge, NIR) (viz tabulka 3). Protože pořadí kanálů je odlišné mezi PlanetScope SuperDove a Micasense RedEdge MX, je nutné přeuspřádat kanály tak, aby odpovídaly pořadí kanálů v očekávaném výstupu.

Normalizace dat představuje úpravu hodnot v jednotlivých kanálech tak, aby se všechny nacházely v jednotném rozsahu (Leach, Coops a Obrknezev, 2019). Nejprve se z metadat každého z rastrů vezmou minimální a maximální hodnoty všech spektrálních pásem (viz tabulka 5). Po přeuspřádání kanálů se aplikuje technika lineární transformace k normalizaci dat. To znamená, že se aplikuje vzorec pro lineární transformaci hodnot v každém kanálu tak, aby nové minimální a maximální hodnoty byly v rozsahu 0 a 1 (Javaheri, Sepehri a Teimourpour, 2014). Konkrétně se použije následující vzorec (Pereira et al., 2023; Zheng a Casari, 2018; Leach, Coops a Obrknezev, 2019).

$$\text{Nová hodnota} = \frac{\text{Původní hodnota} - \text{Minimální hodnota}}{\text{Rozsah hodnot}}$$

Obrázek 22: Vzorec pro lineární transformaci hodnot

kde:

Nová hodnota.....normalizovaná hodnota,

Původní hodnota.....hodnota v původním kanálu,

Minimální hodnota.....minimální hodnota v kanálu,

Rozsah hodnot.....rozdíl mezi maximální a minimální hodnotou v kanálu.

Tímto způsobem se zajistí, že oba rastry se normalizovaly a připravily pro další analýzu a zpracování.

Skript 7: Definice minimálních a maximálních hodnot pro normalizaci

```
# Definice minimálních a maximálních hodnot pro normalizaci  
# Pro UAV data (Micasense RedEdge MX)  
uav_min <- c(209, 290, 96, 531, 3191) # Minimální hodnoty v jednotlivých kanálech  
uav_max <- c(35617, 52691, 65345, 65535, 65535) # Maximální hodnoty  
v jednotlivých kanálech  
  
# Pro PlanetScope SuperDove data  
planet_min <- c(20.1119403839, 77.2180480957, 82.5505065918, 204.2849578857,  
705.6512451172) # Minimální hodnoty v jednotlivých kanálech  
planet_max <- c(1565.7326660156, 1641.4481201172, 2117.80078125,  
2419.3127441406, 5220.5219726562) # Maximální hodnoty v jednotlivých kanálech
```

5. Výsledky práce

V této kapitole jsou prezentovány klíčové výsledky projektu zaměřeného na doplnění chybějících obrazových informací v UAV ortomozaikách s využitím dat z družice Planet. Cílem bylo ověřit efektivitu a přesnost použité metody doplnění na základě komplexního srovnání mezi původními a doplněnými daty. Výsledky jsou prezentovány v kontextu několika klíčových metrik, včetně vizuální kvality obrazu NDVI (viz kapitola 4.5.2.), statistických měření shody a analýzy specifických vlastností terénu.

Analýza vizuální kvality doplněných dat odhalila docela pozitivní výsledky při nahrazení fragmentované obrazové informace UAV ortomozaiky, přičemž bylo dosaženo poměrně dobré míry vizuální shody s okolním terénem. Toto zjištění je podpořeno porovnáním vybraných oblastí zájmu před a po doplnění (viz obr. 15 a 16).

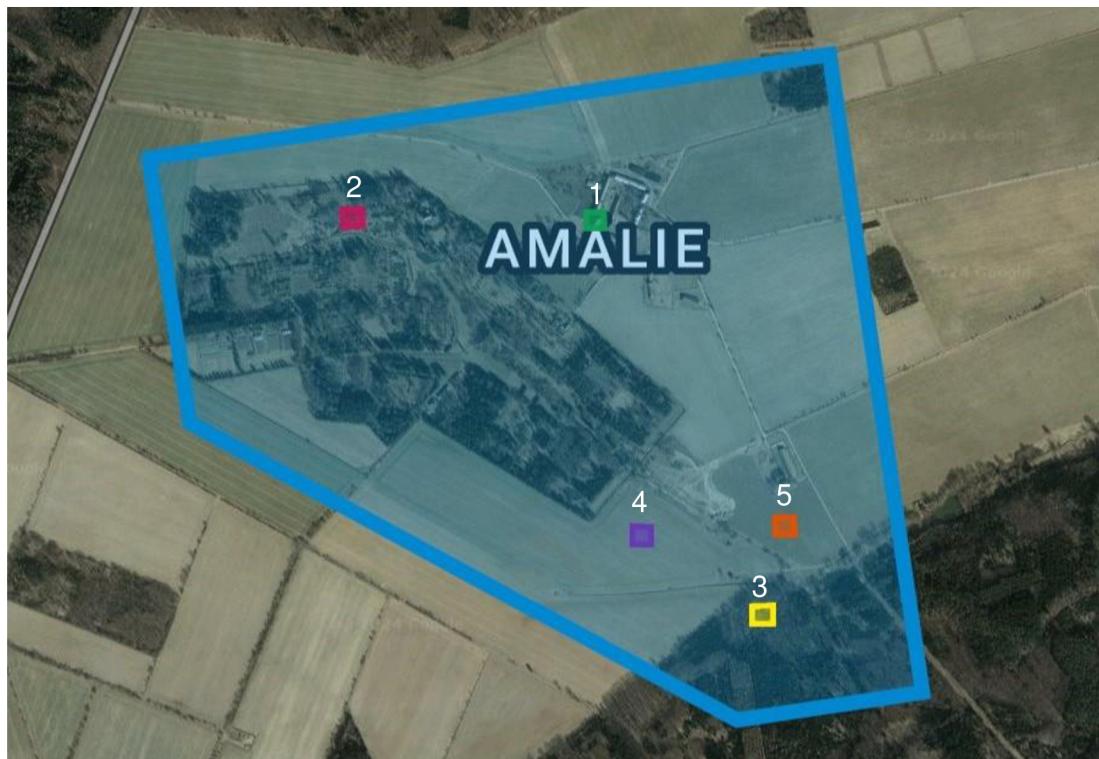
Koefficient korelace, RMSE a další metriky shody ukázaly poměrně uspokojivé hodnoty v rámci doplněných dat a referenčních snímků. Tyto výsledky naznačují, že použitá metoda doplňování je účinná pro obnovu chybějících informací v UAV snímcích s relativně vysokou mírou přesnosti.

V tabulkách v této kapitole a přílohách (viz kapitola 9) jsou prezentovány různé metriky pro hodnocení výkonnosti a srovnání NDVI výsledků získaných z UAV a Planet dat, jak pro celé povrchy, tak pro specifické výřezy (zástavba, členitá vegetace, les, pole, travnatá louka) a různé varianty doplnění chybějících částí v podobě pruhů.

Porovnání NDVI hodnot z UAV a PlanetScope dat pro zájmová území před simulací chyb ukazuje na vysokou míru shody mezi oběma datovými sadami, což je klíčové pro validaci jejich použitelnosti v geografických a environmentálních studiích. Analýza pro druhé zájmové území odhalila RMSE hodnotu 14,53 % a koefficient determinace R^2 0,81, což naznačuje silnou korelaci mezi srovnávanými daty. Pearsonova korelační hodnota 0,94 a Willmottův index shody 0,98 dále podtrhují vysokou míru shody mezi datovými sadami. Toto potvrzuje i MAE ve výši 0,08084. Výsledky jsou podrobně prezentovány v tabulce č. 9. Před simulací chyb v podobě pruhů vykazuje první zájmové území srovnatelnou míru shody, což potvrzuje statistické výsledky uvedené v tabulce č. 10.

Tabulka 9: Druhé zájmové území - srovnání shody dat podle NDVI - UAV a Planet data bez simulace chyby - výřezy

NDVI - původní data pro specifické výřezy	RMSE	RMSE %	R ²	Pearsonova korelace	Willmottův index	MAE
UAV data VS Planet data bez simulace chyby	0,1007	14,53	0,81	0,94	0,98	0,08084



Obrázek 23: Přehledová mapa výřezů pro jednotlivá místa druhého zájmového území. (1) Zástavba, (2) Členitá vegetace, (3) Les, (4) Pole, (5) Travnatá louka

Tabulka 10: První zájmové území - srovnání shody dat podle NDVI - UAV a Planet data bez simulace chyby - pruhy

NDVI - původní data pro simulaci pruhů	RMSE	RMSE %	R ²	Pearsonova korelace	Willmottův index	MAE
UAV data VS Planet data bez simulace chyby	0,0972	13,06	0,80	0,93	0,98	0,07339

Porovnání spektrálních kanálů

Porovnání spektrálních pásem z UAV a PlanetScope dat před aplikací simulovaných chyb odhaluje významné rozdíly mezi oběma datovými sadami, zejména v NIR spektru. V rámci druhého zájmového území bylo zjištěno, že RMSE % hodnoty narůstají s přechodem od modrého k NIR pásmu, což poukazuje na to, že největší nepřesnosti se vyskytují právě v NIR spektru. Koeficient determinace R^2 a Pearsonova korelace klesají od červeného k NIR pásmu. Stejný trend je reflektován také ve Willmottově indexu a v MAE, jak je detailně prezentováno v tabulce č. 11. Pro první zájmové území analýza před simulací chyb v podobě pruhů odhalila velmi podobné výsledky jako u druhého zájmového území, což lze vidět tabulce č. 12.

Tabulka 11: Druhé zájmové území - srovnání shody dat podle spektrálních kanálů - UAV a Planet data bez simulace chyby – specifické výřezy

Původní data pro specifické výřezy		Modrá	Zelená	Červená	Red-Edge	NIR
UAV data VS Planet data bez simulace chyby	RMSE	0,0627	0,1029	0,1259	0,1349	0,5875
	RMSE %	9,82	12,09	13,19	26,59	60,96
	R^2	0,6330	0,6525	0,6678	0,3635	0,0004
	Pearsonova korelace	0,79	0,80	0,81	0,60	0,02
	Willmottův index	0,83	0,74	0,77	0,73	0,62
	MAE	0,03889	0,07428	0,1013	0,10735	0,51834

Tabulka 12: První zájmové území - srovnání shody dat podle spektrálních kanálů - UAV a Planet data bez simulace chyby - pruhy

Původní data pro simulaci pruhů		Modrá	Zelená	Červená	Red-Edge	NIR
UAV data VS Planet data bez simulace chyby	RMSE	0,0469	0,0788	0,1147	0,1394	0,6960
	RMSE %	5,84	8,42	15,78	17,69	62,39
	R^2	0,5787	0,6197	0,6672	0,3566	0,0141
	Pearsonova korelace	0,76	0,78	0,81	0,59	0,11
	Willmottův index	0,84	0,78	0,77	0,73	0,70
	MAE	0,02998	0,06220	0,09885	0,11617	0,62591

Ze statistických dat srovnání UAV a PlanetScope výrezů v NDVI zobrazení lze vyvodit následující trendy a zjištění pro různé typy povrchů. RMSE a procentní hodnoty RMSE ukazují výrazné variace mezi jednotlivými typy povrchů, což odráží variabilitu a odlišnosti ve spektrálních charakteristikách každého z LULC. Tyto hodnoty

poskytují přímý ukazatel kvality shody mezi UAV a PlanetScope daty na takto rozdílných typech povrchů. Hodnoty R^2 jsou celkově nízké, což naznačuje, že modely NDVI mezi UAV a PlanetScope daty mají omezenou predikční schopnost pro všechny typy povrchů. To může být důsledkem značných rozdílů ve spektrálních charakteristikách mezi oběma zdroji dat. Pearsonova korelace a Willmottův index ukazují na určitou míru shody mezi UAV a daty pro doplnění, avšak rozdíly v těchto hodnotách mezi jednotlivými povrhy zdůrazňují, že některé typy LULC se lépe hodí pro nahrazování dat než jiné. Výřez travnaté louky vykazuje nejlepší výsledky shody s nejnižší RMSE (0,0303), RMSE % (3,22), ale naopak hodně nízkou Pearsonovou korelací (0,21). Přestože Pearsonova korelace není vysoká, nízké hodnoty RMSE a RMSE % naznačují, že travnaté louky jsou relativně dobře reprezentovány v datech pro doplnění PlanetScope ve srovnání s původními UAV daty. Jako nejhorší výřez z hlediska RMSE se jeví výřez zástavby s nejvyšším RMSE (0,1797), RMSE % (29,01). Naproti tomu Pearsonova korelace je poměrně dobrá (0,74), což ukazuje na relativně dobrou prostorovou shodu v nahrazení dat pro urbanizované oblasti (viz tabulka 13). Lze tedy říci, že i když Pearsonova korelace naznačuje určitou míru lineární shody, vysoké hodnoty RMSE a RMSE % poukazují na výrazné nepřesnosti v hodnocení účinnosti použité metody.

Tabulka 13: Srovnání shody dat podle NDVI - UAV a Planet data bez simulace chyby – specifické výřezy

NDVI pro výřezy	RMSE	RMSE %	R^2	Pearsonova korelace	Willmottův index	MAE
Výřez zástavby	0,1797	29,01	0,15	0,74	0,91	0,15086
Výřez členité vegetace	0,0894	10,04	0,27	0,52	0,98	0,08168
Výřez les	0,0418	4,61	0,11	0,34	0,99	0,03656
Výřez pole s klíčící vegetací	0,0706	10,96	0,10	0,32	0,98	0,06243
Výřez travnaté louky	0,0303	3,22	0,04	0,21	0,99	0,02946

Na základě výsledků NDVI pro různé počty pruhů a procenta odebírání dat lze identifikovat několik klíčových trendů a odhalit, jak variace v procentech odebraných dat a počtu pruhů ovlivňují shodu statistických výsledků mezi UAV a PlanetScope daty. RMSE hodnoty a korelační koeficienty (Pearsonova korelace a Willmottův index) ukazují relativně stabilní výsledky napříč různými procenty odebraných dat (5 %, 25 %, 50 %). To naznačuje, že množství odebraných dat nemá drastický dopad na přesnost nebo shodu NDVI mezi srovnávanými datovými sadami. Srovnání NDVI pro tři pruhy ukazuje nejnižší RMSE hodnoty (0,0970, 0,0968, 0,0972 pro 5 %, 25 %, 50 % odebraných dat) ve srovnání s ostatními kategoriemi (jeden, dva, čtyři, pět pruhů). To by mohlo naznačovat, že střední počet pruhů (tři) nabízí nejlepší kompromis mezi odebranými daty a schopností modelu zachovat shodu NDVI. Naopak s rostoucím počtem pruhů, zejména u čtyř a pěti pruhů, se objevuje trend zvyšujících se RMSE hodnot, což naznačuje sníženou přesnost v důsledku vyššího procenta chybějících dat. To je patrné především u 50 % odebraných dat, kde RMSE dosahuje hodnot 0,1138 a 0,1129 pro čtyři a pět pruhů, což jsou nejvyšší zaznamenané hodnoty. Nejvyšší míra shody je dosažena u tří pruhů, což naznačuje, že tento počet zajíšťuje optimální kompromis mezi uchováním informací a zpracováním chybějících dat. Menší dopad na statistické výsledky je patrný při nižším procentu odebírání dat, bez ohledu na počet pruhů (viz příloha 2).

Z dat o srovnání spektrálních charakteristik mezi UAV a PlanetScope daty pro různé typy povrchů (LULC) lze pozorovat několik trendů týkajících se rozdílností v různých spektrálních pásmech. Tato data umožňují identifikovat, které spektrální pásmo má dobrou shodu, a ve kterém dochází k významným rozdílům mezi srovnávanými výřezy. U všech typů povrchů byly zaznamenány nejvyšší RMSE hodnoty v NIR pásmu, což naznačuje nejmenší shodu mezi UAV a PlanetScope daty v tomto kanálu. To je zvláště patrné u výřezu travnaté louky (RMSE 0,8060) a členité vegetace (RMSE 0,7566), kde NIR spektrum vykazuje výrazné rozdíly. Hodnoty Pearsonovy korelace v NIR spektru jsou také výrazně nižší ve srovnání s ostatními spektrálními pásmi, což potvrzuje slabou shodu v NIR mezi UAV a PlanetScope daty. Pro modré a zelené spektrum jsou hodnoty RMSE nižší a jsou zde naopak vyšší Pearsonovy korelace ve srovnání s NIR spektrem. To naznačuje lepší shodu mezi UAV a PlanetScope daty v těchto spektrálních pásmech, zejména u výřezu lesa, kde modré a zelené spektrum ukazuje na lepší korelací a menší chyby. Celkově lepší shoda je pozorována v modré a zeleném spektru napříč většinou typů povrchů, což značí, že tato spektrální pásmá mají lepší konzistenci a přesnost mezi UAV a PlanetScope daty. Nejhorší shoda se vyskytuje v NIR pásmu (viz příloha 3).

6. Diskuse

Analýza vizuální kvality a statistické analýzy poskytly kvantitativní potvrzení úspěšnosti doplnění dat, kde koeficient korelace RMSE a další metriky shody ukázaly poměrně uspokojivé hodnoty. Při srovnávání původních dat UAV a Planet mezi sebou v rámci NDVI byla zjištěna relativně vysoká míra konzistence. Tato míra shody byla nejspíše zajištěna normalizací dat pomocí výpočtu NDVI v daných spektrálních kanálech. Obecně lze říci, že toto zjištění je pozitivním ukazatelem pro využití dat v praxi. Zdá se, že nedostatečný překryv rozsahu v NIR pásmu mezi oběma senzory nepředstavuje zásadní omezení pro přesnost vypočtených hodnot NDVI, což potvrzuje jejich význam pro analýzu (viz obr. 14).

Při porovnání spektrálních charakteristik mezi UAV a PlanetScope daty pro různé typy povrchů byly zaznamenány nejvyšší RMSE hodnoty v NIR spektru, což naznačuje nejmenší shodu v tomto kanálu. Hodnoty Pearsonovy korelace v NIR pásmu jsou také nižší ve srovnání s ostatními spektrálními kanály, což potvrzuje slabou shodu v NIR pásmu mezi UAV a PlanetScope daty i po normalizaci. Naopak, modré a zelené spektrum ukázaly na lepší shodu mezi daty, zejména u výrezu lesa. To bylo způsobeno díky lepší shodě v rozsazích těchto dvou pásem.

V kontextu dalších studií, jako je práce zabývající se doplněním chybějících částí v UAV ortomozaikách s využitím dat z PlanetScope, Sentinel-2 a metodou Random Forest a studie, která se věnuje jednoduché a účinné metodě pro vyplňování mezer v obrazových datech Landsat ETM+ SLC-off, lze výsledky této práce vnímat jako potvrzení účinnosti integrovaného přístupu k doplnění dat (Pereira et al., 2023; Chen et al., 2011). Obě tyto studie ukazují na možnosti využití různých druhů satelitních dat a algoritmů pro zlepšení kvality a přesnosti obrazových dat v případech, kdy jsou původní data neúplná nebo poškozená.

Tento přístup, založený na metodě prostorového maskování, je podobně jako u jiných studií orientován na překonání výzev spojených s chybějícími daty v důsledku oblaků, atmosférických jevů nebo selhání senzoru (Pereira et al., 2023; Chen et al., 2011). Tyto studie se věnují různým metodám vyplňování mezer v obrazových datech od jednoduchých interpolací až po komplexní algoritmy využívající strojové učení (Siabi et al., 2022). Jeden z algoritmů ukazuje efektivitu časoprostorového vyplňování mezer pro údaje o evapotranspiraci a teplotě zemského povrchu (Siabi et al., 2022). Při porovnání metody této studie s přístupy z dalších studií, například s výzkumem doplnění chybějících dat, který používá metodu Random Forest, je metoda prostorového maskování poměrně obecnou metodou pro vyplňování mezer

v obrazových datech ať už z UAV či z družic. Zatímco metoda se zaměřením na časoprostorovou interpolaci doplňuje chybějící části pro data satelitu MODIS, tato studie rozšiřuje možnosti doplňování dat o UAV ortomozaiky. Aplikace metody časoprostorové interpolace na osmidenní datové sady MODIS LST a ET s 1 km rozlišením ukázala, že může velmi přesně predikovat chybějící hodnoty, dokonce i v případě mezer s heterogenním povrchem (Siabi et al., 2022). Tento výzkum podtrhuje potenciál a flexibilitu algoritmu pro zpracování velkých objemů datových sad s vynikající přesností a minimálním časem běhu.

Podle výsledků další studie o doplňování mezer se zdá, že přístup *Temporal Smoothing and Gap Filling* (TSGF) poskytuje nejspolehlivější interpolační schopnost vzhledem ke schopnosti poskytovat realistické interpolace mezi skutečnými pozorováními pro případy s nepřetržitými časovými řadami až do 128 dnů chybějících dat (Kandasamy et al., 2013). Pro delší období bez pozorování se metoda *Climatologie* (Clim) ukázala jako nejlepší, pokud je k dispozici dostatečné množství dat za celou časovou řadu let použitých k vytvoření klimatologie. Metody, které byly upravovány pro celou časovou řadu (například ICSSA, EMD, LPF, Whit a Clim), neukázaly systematicky lepší výsledky než metody založené na omezeném časovém okně (například AGF, SGF, TSGF), i když byly očekávány pro vyplnění dlouhých mezer se zkušenostmi získanými napříč několika lety dostupnými v časové řadě. Místní metody byly obecně věrnější, ale měly omezenou kapacitu vyplnit dlouhé mezery. Většina metod vykazovala horší výkonnost než Clim pro mezery delší než asi 100 dnů (Kandasamy et al., 2013).

Co se týče dat pro tuto práci, UAV data byla získána poměrně snadno, a to skrz databázi Katedry prostorových věd na ČZU. Data z družice PlanetScope, která představují komerční zdroj, je možné získat pro vědecké účely, ale pouze v omezeném množství. Přesto cena pro standardního uživatele není přemrštěná a celý projekt je dynamicky rozvíjen, což zároveň přináší široké spektrum možností. To zahrnuje nejenom rozvoj nových družicových platform, ale také online nástroje umožňující úpravu a přizpůsobení dat ještě před jejich stažením, včetně ořezávání podle polygonů či synchronizace s dalšími datovými systémy. Aktuálně je zaveden speciální program pro vzdělávací instituce a výzkumné týmy, který poskytuje přístup k těmto datům. Studentům a výzkumníkům umožňuje využít až 5 000 km² dat měsíčně pro jejich projekty (Planet, 2024). Obě platformy nabízejí svým uživatelům hlavní výhodu v podobě dat již podrobených základním úpravám, jako jsou atmosférické a radiometrické korekce, často doplněných o masky mraků a georeferencování.

Sateliity Planet poskytují denně nový snímek identické lokality (Esa, 2024). Právě v tom je výhoda doplňování družicových dat do UAV snímků.

Ve studii představovalo výzvu práce s velkými daty jako byla UAV ortomozaika, která měla přes 2 GB. Proto jí bylo nutné zmenšit pouze na zájmové území. Pokud člověk nedisponuje moderní výpočetní technikou s výkonným procesorem, může se stát, že bude mít při pre-processingu a zpracování dat potíže s rychlosí výpočtů. Pre-processing představuje pro metodu imputace družicových dat do dat z UAV podstatný krok v zajištění přesnosti provedení a synchronizaci dat pro finální výsledky. Vzhledem k časové náročnosti tohoto procesu není tato metoda příliš efektivní. Dlouhý proces také představovaly výpočty všech statistických metrik, které bylo náročné získat. Tato metodika má opodstatnění především pro účely s omezeným rozsahem nebo specifické aplikace a představuje významný krok v situacích, kde je zapotřebí analyzovat konkrétní období na určených lokalitách, které mohou být náchylné k chybám při sběru dat. Hypoteticky lze též zvážit alternativní přístup, kterým je doplnění chybějících dat ze satelitních snímků pomocí dat z bezpilotních letounů.

7. Závěr a přínos práce

Studie se zabývala analýzou prostorové shody a účinnosti metody prostorového maskování při integraci UAV a PlanetScope dat. Cílem bylo ověřit efektivitu a přesnost použité metody doplnění na základě komplexního srovnání mezi původními a doplněnými daty, s ohledem na různé typy povrchů a specifické výřezy terénu. Přístup použitý v tomto výzkumu je triviálnějšího charakteru, a proto se odlišuje od složitějších metod jako je například metoda Random Forest (Pereira et al., 2023).

Pomocí kvantitativních metrik jako jsou RMSE, Pearsonův koeficient korelace a Willmottův index shody byla prokázána značná shoda v doplněných datech. Například v oblastech zástavby a vegetace byly zaznamenány RMSE hodnoty 0,1797 a 0,0303, což odráží vysokou míru shody s původními UAV daty a potvrzuje účinnost metody prostorového maskování pro doplnění dat. Tato zlepšení jsou zásadní pro lepší porozumění a monitorování vegetace, vodních těles a urbanizovaných oblastí.

Například srovnání UAV a Planet dat v projekci NDVI poskytuje cenné poznatky o tom, jaký povrch má problémy při nahrazování a jaký je na tom relativně dobře v kontextu nahrazování dat nižší kvality. Výsledky naznačují, že při pokusech o nahrazení chybějících nebo poškozených UAV dat pomocí PlanetScope dat, bude efektivita silně záviset na typu LULC. Urbanizované oblasti (zástavba) představují značné výzvy pro přesné doplnění, zatímco přírodní ekosystémy, jako jsou travnaté louky, jsou méně problematické (díky homogennímu typu prostředí) a ukazují lepší výsledky shody.

Optimální shody v rámci statistických metrik dosahuje varianta tří pruhů, což naznačuje, že tento počet pruhů poskytuje nejlepší vyvážení mezi uchováním původních informací a imputací chybějících dat. Zvýšením procenta chybějící informace v datech a počtu pruhů vede k větším RMSE hodnotám, což značí sníženou přesnost. Největší dopad na statistické výsledky byl pozorován u čtyř a pěti pruhů, zejména při 50 % odebírání dat, kde je přesnost výrazně nižší. Menší dopad na statistické výsledky je patrný při nižším procentu odebírání dat bez ohledu na počet pruhů. Z těchto pozorování lze vyvodit, že při modelování NDVI hodnot a jejich srovnávání mezi různými datovými sadami je důležité pečlivě zvážit jak množství odebíraných dat, tak i jejich rozložení na snímku.

Tato pozorování naznačují, že při srovnávání dat z různých senzorů je klíčové zohlednit spektrální charakteristiky a možné rozdíly ve spektrální shodě, zejména pro

aplikace v oblastech, jako je monitorování vegetace nebo klasifikace pozemního krytu, kde spektrální informace hrají klíčovou roli. Významné rozdíly v NIR spektru mohou mít značný dopad na interpretaci vegetačních indexů a odhad biomasy, zatímco lepší shoda ve viditelných spektrálních pásech (modré a zelené) může být využita pro aplikace, kde jsou tyto spektrální informace dostačující.

Z těchto výsledků je zřejmé, že pro účely, kde je důležitá vysoká přesnost a kvalita spektrálních dat, mohou být data získaná z UAV preferována pro modré a zelené spektrální pásmo, zatímco NIR spektrum vyžaduje zvýšenou opatrnost při využívání dat z různých zdrojů. Další výzkum a vývoj metod pro zlepšení shody v NIR spektru mezi různými platformami dálkového průzkumu Země by mohl přinést lepší integraci a využití dat pro širokou škálu aplikací v oblasti environmentálního monitoringu, zemědělství a lesnictví.

Studie také identifikuje určité limitace, zejména ve vztahu k rozsahu a různorodosti testovaných scénářů. Budoucí výzkum by se měl zaměřit na rozšíření aplikace a validace metod na další typy krajinných struktur a podmínek, jakož i na vývoj pokročilejších algoritmů, včetně použití strojového učení a umělé inteligence pro automatizovanou analýzu a interpretaci dat. Tímto způsobem lze lépe pochopit omezení metodiky a identifikovat oblasti, kde je potřeba dalšího vývoje nebo úprav. Navzdory těmto výzvám výsledky práce poskytují solidní základ pro další rozvoj v této dynamicky se rozvíjející disciplíně a nabízí nové možnosti pro zlepšení kvality a užitečnosti geografických dat.

Závěrem lze říci, že přínos studie je dvojí. Poskytuje praktické nástroje pro zlepšení kvality UAV ortomozaik prostřednictvím praktického doplňování chybějících dat a zároveň přispívá k teoretickému porozumění možnostem a omezením současných metod vyplňování mezer v kontextu dálkového průzkumu Země. Přestože výzkum v této oblasti je stále v plenkách, je jasné, že spojení UAV a satelitních dat představuje slibnou cestu k dosažení hlubších vědeckých poznatků a praktických řešení pro environmentální a geografické studie v budoucnosti.

8. Seznam použitých zdrojů

- 1) Planet Explorer. Planet [online]. [vid. 2024-03-24]. Dostupné z: <https://www.planet.com/explorer/> Planet | Homepage. Planet [online]. [vid. 2024-03-20]. Dostupné z: <https://www.planet.com/>
- 2) LILLESAND, Thomas M., Ralph W. KIEFER a Jonathan W. CHIPMAN. *Remote sensing and image interpretation*. 5th ed. New York: Wiley, 2004. ISBN 9780471152279
- 3) JENSEN, John R. *Remote sensing of the environment: an earth resource perspective*. 2nd ed. Upper Saddle River, NJ: Pearson Prentice Hall, 2007. Prentice Hall series in geographic information science. ISBN 9780131889507
- 4) CRACKNELL, Arthur P. *The development of remote sensing in the last 40 years*. International Journal of Remote Sensing [online]. 2018, 39(23), 8387–8427 [vid. 2024-03-23]. ISSN 0143-1161, 1366-5901. Dostupné z: doi:10.1080/01431161.2018.1550919
- 5) COHEN, C.J. *Early history of remote sensing*. In: *Proceedings 29th Applied Imagery Pattern Recognition Workshop* [online]. Washington, DC, USA: IEEE Comput. Soc, 2000, s. 3–9 [vid. 2024-03-23]. ISBN 9780769509785. Dostupné z: doi:10.1109/AIPRW.2000.953595
- 6) GRIFFIN, Michael. *Media images of war*. Media, War & Conflict [online]. 2010, 3(1), 7–41 [vid. 2024-03-23]. ISSN 1750-6352, 1750-6360. Dostupné z: doi:10.1177/1750635210356813
- 7) ASPINWALL, Jane L. *'History From Their Viewpoint': Photography During World War I*. KC STUDIO [online]. 13. říjen 2021 [vid. 2024-03-23]. Dostupné z: <https://kcstudio.org/history-from-their-viewpoint-photography-during-world-war-i/>
- 8) CAMPBELL, James B. *Introduction to remote sensing*. Fifth edition. New York: Guilford Press, 2011. ISBN 9781462506750
- 9) DORNBURGER, Walter R. *The German V-2*. Technology and Culture [online]. 1963, 4(4), 393 [vid. 2024-03-23]. ISSN 0040165X. Dostupné z: doi:10.2307/3101376
- 10) DAY, Dwayne A., John M. LOGSDON a Brian LATELL, ed. *Eye in the sky: the story of the Corona spy satellites*. Washington, D.C: Smithsonian Institution Press, 1998. Smithsonian history of aviation series. ISBN 9781560988304
- 11) HOOVER, Robert A. *America's Secret Eyes in Space*: The U.S. Keyhole Spy Satellite Program. By Jeffrey T. Richelson. New York: Harper & Row, 1990. 375p. \$24.95. American Political Science Review [online]. 1991, 85(2), 692–

- 693 [vid. 2024-03-23]. ISSN 0003-0554, 1537-5943. Dostupné z: doi:10.2307/1963247
- 12) HEAPS, Leo. *Operation morning light: terror in our skies: the true story of Cosmos 954*. New York: Paddington Press : distributed by Grosset & Dunlap, 1978. ISBN 9780448224251
- 13) YADAV, Shubham. *History of Remote Sensing*. Geographic Book [online]. 1. březen 2023 [vid. 2024-03-23]. Dostupné z: <https://geographicbook.com/history-of-remote-sensing/>
- 14) SEFERCIK, Umut G. a Mustafa OZENDI. *Comprehensive comparison of VHR 3D spatial data acquired from IKONOS and TerraSAR-X imagery*. Advances in Space Research [online]. 2013, 52(9), 1655–1667 [vid. 2024-03-23]. ISSN 02731177. Dostupné z: doi:10.1016/j.asr.2013.07.044
- 15) EUGENIO, Francisco a Javier MARCELLO. *Very High Resolution (VHR) Satellite Imagery: Processing and Applications*. B.m.: [Erscheinungsort nicht ermittelbar] MDPI - Multidisciplinary Digital Publishing Institute 2019, 2019. ISBN 9783039217564.
- 16) Esa. *Biomass* [online]. 2024, [vid. 2024-03-23]. Dostupné z: https://www.esa.int/Applications/Observing_the_Earth/FutureEO/Biomass
- 17) Airbus. *Zephyr* [online]. 2024, [Vid. 2024-03-23]. Dostupné z: <https://www.airbus.com/en/products-services/defence/uas/uas-solutions/zephyr>
- 18) XU, Yuankun, Zhong LU, Roland BÜRGMANN, Scott HENSLEY, Eric FIELDING a Jinwoo KIM. *P-band SAR for ground deformation surveying: Advantages and challenges*. Remote Sensing of Environment [online]. 2023, 287, 113474 [vid. 2024-03-23]. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2023.113474
- 19) LI, Hao, Pedram GHAMISI, Uwe SOERGEL a Xiao ZHU. *Hyperspectral and LiDAR Fusion Using Deep Three-Stream Convolutional Neural Networks*. Remote Sensing [online]. 2018, 10(10), 1649 [vid. 2024-03-23]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs10101649
- 20) FOODY, Giles M. *Status of land cover classification accuracy assessment*. Remote Sensing of Environment [online]. 2002, 80(1), 185–201 [vid. 2024-03-23]. ISSN 00344257. Dostupné z: doi:10.1016/S0034-4257(01)00295-4
- 21) MOORE, Gerald K. *What is a picture worth? A history of remote sensing / Quelle est la valeur d'une image? Un tour d'horizon de télédétection*. Hydrological Sciences Bulletin [online]. 1979, 24(4), 477–485

- [vid. 2024-03-23]. ISSN 0303-6936. Dostupné z: doi:10.1080/02626667909491887
- 22) COPPIN, Pol R. a Marvin E. BAUER. *Digital change detection in forest ecosystems with remote sensing imagery*. Remote Sensing Reviews [online]. 1996, 13(3–4), 207–234 [vid. 2024-03-23]. ISSN 0275-7257. Dostupné z: doi:10.1080/02757259609532305
- 23) PETTORELLI, Nathalie, William F. LAURANCE, Timothy G. O'BRIEN, Martin WEGMANN, Harini NAGENDRA a Woody TURNER. *Satellite remote sensing for applied ecologists: opportunities and challenges*. Journal of Applied Ecology [online]. 2014, 51(4), 839–848 [vid. 2024-03-23]. ISSN 0021-8901. Dostupné z: <https://www.jstor.org/stable/24032484>
- 24) JOSEPH, George. *India's journey towards excellence in building earth observation cameras*. Chennai: Notion Press, 2016. ISBN 9789352069989
- 25) SHIPPERT, Peg. *Push Broom and Whisk Broom Sensors*. NV5 Geospatial [online]. [vid. 2024-03-23]. 2013 Dostupné z: <https://www.nv5geospatialsoftware.com/Support/Self-Help-Tools/Help-Articles/Help-Articles-Detail/ArtMID/10220/ArticleID/16262/Push-Broom-and-Whisk-Broom-Sensors>
- 26) LI, Qingli, Xiaofu HE, Yiting WANG, Hongying LIU, Dongrong XU a Fangmin GUO. *Review of spectral imaging technology in biomedical engineering: achievements and challenges*. Journal of Biomedical Optics [online]. 2013, 18(10), 100901 [vid. 2024-03-23]. ISSN 1083-3668. Dostupné z: doi:10.1117/1.JBO.18.10.100901
- 27) JAFARBIGLU, Hamid a Alireza POURREZA. *A comprehensive review of remote sensing platforms, sensors, and applications in nut crops*. Computers and Electronics in Agriculture [online]. 2022, 197, 106844 [vid. 2024-03-23]. ISSN 01681699. Dostupné z: doi:10.1016/j.compag.2022.106844
- 28) ZHANG, Peng. *Sensors and actuators*. In: Advanced Industrial Control Technology [online]. B.m.: Elsevier, 2010 [vid. 2024-03-23], s. 73–116. ISBN 9781437778076. Dostupné z: doi:10.1016/B978-1-4377-7807-6.10003-8
- 29) LINDQUIST, Martin A. *The Statistical Analysis of fMRI Data*. Statistical Science [online]. 2008, 23(4), 439–464 [vid. 2024-03-23]. ISSN 0883-4237. Dostupné z: <https://www.jstor.org/stable/20697652>
- 30) Esa. IKONOS-2 - Earth Online [online]. [vid. 2024-03-23]. Dostupné z: <https://earth.esa.int/eogateway/missions/ikonos-2>

- 31) MANFREDA, Salvatore, Matthew MCCABE, Pauline MILLER, Richard LUCAS, Victor PAJUELO MADRIGAL, Giorgos MALLINIS, Eyal BEN DOR, David HELMAN, Lyndon ESTES, Giuseppe CIRAOLO, Jana MÜLLEROVÁ, Flavia TAURO, M. DE LIMA, João DE LIMA, Antonino MALTESE, Felix FRANCES, Kelly CAYLOR, Marko KOHV, Matthew PERKS, Guiomar RUIZ-PÉREZ, Zhongbo SU, Giulia VICO a Brigitta TOTH. *On the Use of Unmanned Aerial Systems for Environmental Monitoring*. Remote Sensing [online]. 2018, 10(4), 641 [vid. 2024-03-23]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs10040641
- 32) SISHODIA, Rajendra P., Ram L. RAY a Sudhir K. SINGH. *Applications of Remote Sensing in Precision Agriculture: A Review*. Remote Sensing [online]. 2020, 12(19), 3136 [vid. 2024-03-23]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs12193136
- 33) WAVREK, Mia T., Eric CARR, Sharon JEAN-PHILIPPE a Michael L. MCKINNEY. *Drone remote sensing in urban forest management: A case study*. Urban Forestry & Urban Greening [online]. 2023, 86, 127978 [vid. 2024-03-23]. ISSN 16188667. Dostupné z: doi:10.1016/j.ufug.2023.127978
- 34) RADOGLOU-GRAMMATIKIS, Panagiotis, Panagiotis SARIGIANNIDIS, Thomas LAGKAS a Ioannis MOSCHOLIOS. *A compilation of UAV applications for precision agriculture*. Computer Networks [online]. 2020, 172, 107148 [vid. 2024-03-23]. ISSN 13891286. Dostupné z: doi:10.1016/j.comnet.2020.107148
- 35) ALMEIDA, Danilo Roberti Alves De, Eben North BROADBENT, Matheus Pinheiro FERREIRA, Paula MELI, Angelica Maria Almeyda ZAMBRANO, Eric Bastos GORGENS, Angelica Faria RESENDE, Catherine Torres DE ALMEIDA, Cibele Hummel DO AMARAL, Ana Paula Dalla CORTE, Carlos Alberto SILVA, João P. ROMANELLI, Gabriel Atticciati PRATA, Daniel DE ALMEIDA PAPA, Scott C. STARK, Ruben VALBUENA, Bruce Walker NELSON, Joannes GUILLEMOT, Jean-Baptiste FÉRET, Robin CHAZDON a Pedro H.S. BRANCALION. *Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion*. Remote Sensing of Environment [online]. 2021, 264, 112582 [vid. 2024-03-23]. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2021.112582
- 36) GUIMARÃES, Nathalie, Luís PÁDUA, Pedro MARQUES, Nuno SILVA, Emanuel PERES a Joaquim J. SOUSA. *Forestry Remote Sensing from Unmanned Aerial Vehicles: A Review Focusing on the Data, Processing and*

- Potentialities. *Remote Sensing* [online]. 2020, 12(6), 1046 [vid. 2024-03-23]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs12061046
- 37) HERRERO-HUERTA, Monica, Pablo RODRIGUEZ-GONZALVEZ a Katy M. RAINY. *Yield prediction by machine learning from UAS-based multi-sensor data fusion in soybean*. *Plant Methods* [online]. 2020, 16(1), 78 [vid. 2024-03-23]. ISSN 1746-4811. Dostupné z: doi:10.1186/s13007-020-00620-6
- 38) FAN, Jin a M. Ala SAADEGHVAZIRI. *Applications of Drones in Infrastructures: Challenges and Opportunities*. *International Journal of Mechanical, Industrial and Aerospace Sciences* [online]. 2019, 12.0(10) [vid. 2024-03-23]. Dostupné z: doi:10.5281/zenodo.3566281
- 39) SCHER, C. Lane, Nisa KARIMI, Mary-Claire GLASENHARDT, Ashley TUFFIN, Charles H. CANNON, Bryant C. SCHARENBROCH a Andrew L. HIPP. *Application of remote sensing technology to estimate productivity and assess phylogenetic heritability*. *Applications in Plant Sciences* [online]. 2020, 8(11), e11401 [vid. 2024-03-25]. ISSN 2168-0450, 2168-0450. Dostupné z: doi:10.1002/aps3.11401
- 40) QIN, Tianyi, Guangyu ZHANG, Liying YANG a Yuqing HE. *Research on the Endurance Optimisation of Multirotor UAVs for High-Altitude Environments*. *Drones* [online]. 2023, 7(7), 469 [vid. 2024-03-23]. ISSN 2504-446X. Dostupné z: doi:10.3390/drones7070469
- 41) CLARKE, Roger a Lyria BENNETT MOSES. *The regulation of civilian drones' impacts on public safety*. *Computer Law & Security Review* [online]. 2014, 30(3), 263–285 [vid. 2024-03-23]. ISSN 02673649. Dostupné z: doi:10.1016/j.clsr.2014.03.007
- 42) MASTELIC, Toni, Josip LORINCZ, Ivan IVANDIC a Matea BOBAN. *Aerial Imagery Based on Commercial Flights as Remote Sensing Platform*. *Sensors* [online]. 2020, 20(6), 1658 [vid. 2024-03-23]. ISSN 1424-8220. Dostupné z: doi:10.3390/s20061658
- 43) LECHNER, Alex M., Giles M. FOODY a Doreen S. BOYD. *Applications in Remote Sensing to Forest Ecology and Management*. *One Earth* [online]. 2020, 2(5), 405–412 [vid. 2024-03-23]. ISSN 25903322. Dostupné z: doi:10.1016/j.oneear.2020.05.001
- 44) CASPI, Amir, Daniel B. SEATON, Constantine C. C. TSANG, Craig E. DEFOREST, Paul BRYANS, Edward E. DELUCA, Steven TOMCZYK, Joan T. BURKEPILE, Thomas “Tony” CASEY, John COLLIER, Donald “Dd” DARROW, Dominic DEL ROSSO, Daniel D. DURDA, Peter T. GALLAGHER, Leon GOLUB, Matthew JACYNA, David “Dj” JOHNSON, Philip G. JUDGE,

- Cary "Diddle" KLEMM, Glenn T. LAURENT, Johanna LEWIS, Charles J. MALLINI, Thomas "Duster" PARENT, Timothy PROPP, Andrew J. STEFFL, Jeff WARNER, Matthew J. WEST, John WISEMAN, Mallory YATES, Andrei N. ZHUKOV, a THE NASA WB-57 2017 ECLIPSE OBSERVING TEAM. *A New Facility for Airborne Solar Astronomy*. NASA's WB-57 at the 2017 Total Solar Eclipse. *The Astrophysical Journal* [online]. 2020, 895(2), 131 [vid. 2024-03-23]. ISSN 0004-637X, 1538-4357. Dostupné z: doi:10.3847/1538-4357/ab89a8
- 45) LUO, Lei, Xinyuan WANG, Huadong GUO, Rosa LASAPONARA, Xin ZONG, Nicola MASINI, Guizhou WANG, Pilong SHI, Houcine KHATTELI, Fulong CHEN, Shahina TARIQ, Jie SHAO, Nabil BACHAGHA, Ruixia YANG a Ya YAO. *Airborne and spaceborne remote sensing for archaeological and cultural heritage applications: A review of the century (1907–2017)*. *Remote Sensing of Environment* [online]. 2019, 232, 111280 [vid. 2024-03-23]. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2019.111280
- 46) SHAKIROVA, Alia, Leonid NICHMAN, Nabil BELACEL, Cuong NGUYEN, Natalia BLIANKINSSTEIN, Mengistu WOLDE, Stephanie DIVITO, Ben BERNSTEIN a Yi HUANG. *Multivariable Characterization of Atmospheric Environment with Data Collected in Flight*. *Atmosphere* [online]. 2022, 13(10), 1715 [vid. 2024-03-23]. ISSN 2073-4433. Dostupné z: doi:10.3390/atmos13101715
- 47) SUGITA, S, H FUKUI, H INOUE, Y ASAHI a Y FURUSE. *Quick and low-cost high resolution remote sensing using UAV and aircraft to address initial stage of disaster response*. *IOP Conference Series: Earth and Environmental Science* [online]. 2020, 509(1), 012054 [vid. 2024-03-25]. ISSN 1755-1307, 1755-1315. Dostupné z: doi:10.1088/1755-1315/509/1/012054
- 48) NAGEL, Gustavo Willy, Stephen E. DARBY a Julian LEYLAND. *The use of satellite remote sensing for exploring river meander migration*. *Earth-Science Reviews* [online]. 2023, 247, 104607 [vid. 2024-03-23]. ISSN 00128252. Dostupné z: doi:10.1016/j.earscirev.2023.104607
- 49) BUCAY, Mark Angelo, Tara Alessandra ABRINA, Jelaine GAN a Maria Finesa COSICO. *A Technical Analysis on the Manila Bay Dolomite Beach Reclamation Project*. *Philippine Journal of Public Policy: Interdisciplinary Development Perspectives* [online]. 2022, 2021 [vid. 2024-03-23]. ISSN 26723352, 27042847. Dostupné z: doi:10.54096/YOGV6309
- 50) ZHAO, Shaohua, Min LIU, Minghui TAO, Wei ZHOU, Xiaoyan LU, Yujiu XIONG, Feng LI a Qiao WANG. *The role of satellite remote sensing in*

- mitigating and adapting to global climate change.* Science of The Total Environment [online]. 2023, 904, 166820 [vid. 2024-03-23]. ISSN 00489697. Dostupné z: doi:10.1016/j.scitotenv.2023.166820
- 51) FAISAL, K., M. ALAHMAD a A. SHAKER. *REMOTE SENSING TECHNIQUES AS A TOOL FOR ENVIRONMENTAL MONITORING.* The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences [online]. 2012, XXXIX-B8, 513–518 [vid. 2024-03-23]. ISSN 1682-1750. Dostupné z: doi:10.5194/isprsarchives-XXXIX-B8-513-2012
- 52) JOSHI, Neha, Matthias BAUMANN, Andrea EHAMMER, Rasmus FENSHOLT, Kenneth GROGAN, Patrick HOSTERT, Martin JEPSEN, Tobias KUEMMERLE, Patrick MEYFROIDT, Edward MITCHARD, Johannes REICHE, Casey RYAN a Björn WASKE. *A Review of the Application of Optical and Radar Remote Sensing Data Fusion to Land Use Mapping and Monitoring.* Remote Sensing [online]. 2016, 8(1), 70 [vid. 2024-03-23]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs8010070
- 53) BOOYSEN, René, Richard GLOAGUEN, Sandra LORENZ, Robert ZIMMERMANN a Paul A.M. NEX. *Geological Remote Sensing.* In: Encyclopedia of Geology [online]. B.m.: Elsevier, 2021 [vid. 2024-03-26], s. 301–314. ISBN 9780081029091. Dostupné z: doi:10.1016/B978-0-12-409548-9.12127-X
- 54) MILLAN, Robyn M., Rudolf VON STEIGER, Meir ARIEL, Sergey BARTALEV, Maurice BORGEAUD, Stefano CAMPAGNOLA, Julie C. CASTILLO-ROGEZ, René FLÉRON, Volker GASS, Anna GREGORIO, David M. KLUMPAR, Bhavya LAL, Malcolm MACDONALD, Jong Uk PARK, V. SAMBASIVA RAO, Klaus SCHILLING, Graeme STEPHENS, Alan M. TITLE a Ji WU. *Small satellites for space science. Advances in Space Research* [online]. 2019, 64(8), 1466–1517 [vid. 2024-03-23]. ISSN 02731177. Dostupné z: doi:10.1016/j.asr.2019.07.035
- 55) NARAYANASAMY, A., Y. A. AHMAD a M. OTHMAN. *Nanosatellites constellation as an IoT communication platform for near equatorial countries.* IOP Conference Series: Materials Science and Engineering [online]. 2017, 260(1), 012028 [vid. 2024-03-23]. ISSN 1757-899X. Dostupné z: doi:10.1088/1757-899X/260/1/012028
- 56) SOZZI, Marco, Ahmed KAYAD, Stefano GOBBO, Alessia COGATO, Luigi SARTORI a Francesco MARINELLO. *Economic Comparison of Satellite, Plane and UAV-Acquired NDVI Images for Site-Specific Nitrogen Application:*

- Observations from Italy. *Agronomy* [online]. 2021, 11(11), 2098 [vid. 2024-03-23]. ISSN 2073-4395. Dostupné z: doi:10.3390/agronomy11112098
- 57) VANE, Gregg, Thomas G. CHRIEN, Edward A. MILLER a John H. REIMER. *Spectral And Radiometric Calibration Of The Airborne Visible/Infrared Imaging Spectrometer*. In: *Imaging Spectroscopy II* [online]. B.m.: SPIE, 1987, s. 91–107 [vid. 2024-03-24]. Dostupné z: doi:10.1117/12.942288
- 58) PEREIRA, Francisco R. Da S., Aliny A. DOS REIS, Rodrigo G. FREITAS, Stanley R. De M. OLIVEIRA, Lucas R. Do AMARAL, Gleyce K. D. A. FIGUEIREDO, João F. G. ANTUNES, Rubens A. C. LAMPARELLI, Edemar MORO a Paulo S. G. MAGALHÃES. *Imputation of Missing Parts in UAV Orthomosaics Using PlanetScope and Sentinel-2 Data: A Case Study in a Grass-Dominated Area*. *ISPRS International Journal of Geo-Information* [online]. 2023, 12(2), 41 [vid. 2024-03-24]. ISSN 2220-9964. Dostupné z: doi:10.3390/ijgi12020041
- 59) GAO, Chunrui, Hao LI, Jiachen WANG, Xin ZHANG, Kunming HUANG, Xiaoyan SONG, Wude YANG, Meichen FENG, Lujie XIAO, Yu ZHAO, Fahad SHAFIQ, Chao WANG, Xingxing QIAO a Fangzhou LI. *Combined use of spectral resampling and machine learning algorithms to estimate soybean leaf chlorophyll*. *Computers and Electronics in Agriculture* [online]. 2024, 218, 108675 [vid. 2024-03-24]. ISSN 01681699. Dostupné z: doi:10.1016/j.compag.2024.108675
- 60) LAHIRI, S. N. *Resampling Methods for Dependent Data* [online]. New York, NY: Springer New York, 2003 [vid. 2024-03-24]. Springer Series in Statistics. ISBN 9781441918482. Dostupné z: doi:10.1007/978-1-4757-3803-2
- 61) JIANG, Jiale, Qiaofeng ZHANG, Wenhui WANG, Yapeng WU, Hengbiao ZHENG, Xia YAO, Yan ZHU, Weixing CAO a Tao CHENG. MACA: A Relative Radiometric Correction Method for Multiflight Unmanned Aerial Vehicle Images Based on Concurrent Satellite Imagery. *IEEE Transactions on Geoscience and Remote Sensing* [online]. 2022, 60, 1–14 [vid. 2024-03-24]. ISSN 1558-0644. Dostupné z: doi:10.1109/TGRS.2022.3158644
- 62) BÖHLER, Jonas, Michael SCHAEPMAN a Mathias KNEUBÜHLER. *Crop Classification in a Heterogeneous Arable Landscape Using Uncalibrated UAV Data*. *Remote Sensing* [online]. 2018, 10(8), 1282 [vid. 2024-03-24]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs10081282
- 63) CHENG, Qing, Qiangqiang YUAN, Michael Kwok-Po NG, Huanfeng SHEN a Liangpei ZHANG. *Missing Data Reconstruction for Remote Sensing Images With Weighted Low-Rank Tensor Model*. *IEEE Access* [online]. 2019, 7,

- 142339–142352 [vid. 2024-03-24]. ISSN 2169-3536. Dostupné z: doi:10.1109/ACCESS.2019.2944577
- 64) ZHANG, C., W. LI a D. TRAVIS. *Gaps-fill of SLC-off Landsat ETM+ satellite image using a geostatistical approach*. International Journal of Remote Sensing [online]. 2007, 28(22), 5103–5122 [vid. 2024-03-24]. ISSN 0143-1161, 1366-5901. Dostupné z: doi:10.1080/01431160701250416
- 65) SARAFANOV, Mikhail, Eduard KAZAKOV, Nikolay O. NIKITIN a Anna V. KALYUZHNAЯ. *A Machine Learning Approach for Remote Sensing Data Gap-Filling with Open-Source Implementation: An Example Regarding Land Surface Temperature, Surface Albedo and NDVI*. Remote Sensing [online]. 2020, 12(23), 3865 [vid. 2024-03-24]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs12233865
- 66) SINGH, Raghvendra a P. Rama Chandra PRASAD. *Interpolation Of Data Gaps Of SLC-Off Landsat ETM+ Images Using Algorithm Based On The Differential Operators*. Journal of Applied Computer Science Methods [online]. 2014, 6(2), 93–100 [vid. 2024-03-24]. ISSN 2391-8241. Dostupné z: doi:10.1515/jacsm-2015-0001
- 67) WEISS, Daniel J., Peter M. ATKINSON, Samir BHATT, Bonnie MAPPIN, Simon I. HAY a Peter W. GETHING. *An effective approach for gap-filling continental scale remotely sensed time-series*. ISPRS Journal of Photogrammetry and Remote Sensing [online]. 2014, 98, 106–118 [vid. 2024-03-24]. ISSN 09242716. Dostupné z: doi:10.1016/j.isprsjprs.2014.10.001
- 68) SIABI, Negar, Seyed Hossein SANAEINEJAD a Bijan GHAHRAMAN. *Effective method for filling gaps in time series of environmental remote sensing data: An example on evapotranspiration and land surface temperature images*. Computers and Electronics in Agriculture [online]. 2022, 193, 106619 [vid. 2024-03-24]. ISSN 01681699. Dostupné z: doi:10.1016/j.compag.2021.106619
- 69) PRINGLE, M.J., M. SCHMIDT a J.S. MUIR. *Geostatistical interpolation of SLC-off Landsat ETM+ images*. ISPRS Journal of Photogrammetry and Remote Sensing [online]. 2009, 64(6), 654–664 [vid. 2024-03-24]. ISSN 09242716. Dostupné z: doi:10.1016/j.isprsjprs.2009.06.001
- 70) ZHANG, Chuanrong, Weidong LI a Daniel CIVCO. *Application of geographically weighted regression to fill gaps in SLC-off Landsat ETM+ satellite imagery*. International Journal of Remote Sensing [online]. 2014, 35(22), 7650–7672 [vid. 2024-03-24]. ISSN 0143-1161, 1366-5901. Dostupné z: doi:10.1080/01431161.2014.975377

- 71) MORENO-MARTÍNEZ, Álvaro, Emma IZQUIERDO-VERDIGUIER, Marco P. MANETA, Gustau CAMPS-VALLS, Nathaniel ROBINSON, Jordi MUÑOZ-MARÍ, Fernando SEDANO, Nicholas CLINTON a Steven W. RUNNING. *Multispectral high resolution sensor fusion for smoothing and gap-filling in the cloud*. Remote Sensing of Environment [online]. 2020, 247, 111901 [vid. 2024-03-24]. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2020.111901
- 72) BELGIU, Mariana a Lucian DRĂGUT. *Random forest in remote sensing: A review of applications and future directions*. ISPRS Journal of Photogrammetry and Remote Sensing [online]. 2016, 114, 24–31 [vid. 2024-03-24]. ISSN 09242716. Dostupné z: doi:10.1016/j.isprsjprs.2016.01.011
- 73) ROSSI, Richard E., Jennifer L. DUNGAN a Louisa R. BECK. *Kriging in the shadows: Geostatistical interpolation for remote sensing*. Remote Sensing of Environment [online]. 1994, 49(1), 32–40 [vid. 2024-03-24]. ISSN 00344257. Dostupné z: doi:10.1016/0034-4257(94)90057-4
- 74) TAFAZOLI, Mak. *A study of on-orbit spacecraft failures*. Acta Astronautica [online]. 2009, 64(2–3), 195–205 [vid. 2024-03-24]. ISSN 00945765. Dostupné z: doi:10.1016/j.actaastro.2008.07.019
- 75) HAO, Xiangyu, Jinxiu LIU, Janne HEISKANEN, Eduardo Eiji MAEDA, Si GAO a Xuecao LI. *A robust gap-filling method for predicting missing observations in daily Black Marble nighttime light data*. GIScience & Remote Sensing [online]. 2023, 60(1), 2282238 [vid. 2024-03-24]. ISSN 1548-1603, 1943-7226. Dostupné z: doi:10.1080/15481603.2023.2282238
- 76) LIU, Yan, Qirui REN, Jiahui GENG, Meng DING a Jiangyun LI. *Efficient Patch-Wise Semantic Segmentation for Large-Scale Remote Sensing Images*. Sensors [online]. 2018, 18(10), 3232 [vid. 2024-03-24]. ISSN 1424-8220. Dostupné z: doi:10.3390/s18103232
- 77) JENEROWICZ, Agnieszka, Damian WIERZBICKI a Michał KEDZIERSKI. *Radiometric Correction with Topography Influence of Multispectral Imagery Obtained from Unmanned Aerial Vehicles*. Remote Sensing [online]. 2023, 15(8), 2059 [vid. 2024-03-24]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs15082059
- 78) SIEBERTH, T., R. WACKROW a J. H. CHANDLER. *Motion blur disturbs – the influence of motion-blurred images in photogrammetry*. The Photogrammetric Record [online]. 2014, 29(148), 434–453 [vid. 2024-03-24]. ISSN 0031-868X, 1477-9730. Dostupné z: doi:10.1111/phor.12082

- 79) DENG, Gang, Zhiguang TANG, Chunyu DONG, Donghang SHAO a Xin WANG. *Development and Evaluation of a Cloud-Gap-Filled MODIS Normalized Difference Snow Index Product over High Mountain Asia*. Remote Sensing [online]. 2024, 16(1), 192 [vid. 2024-03-24]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs16010192
- 80) CHEN, Jin, Xiaolin ZHU, James E. VOGELMANN, Feng GAO a Suming JIN. *A simple and effective method for filling gaps in Landsat ETM+ SLC-off images*. Remote Sensing of Environment [online]. 2011, 115(4), 1053–1064 [vid. 2024-03-24]. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2010.12.010
- 81) XIE, Guanyao a Simona NICULESCU. *Mapping Crop Types Using Sentinel-2 Data Machine Learning and Monitoring Crop Phenology with Sentinel-1 Backscatter Time Series in Pays de Brest, Brittany, France*. Remote Sensing [online]. 2022, 14(18), 4437 [vid. 2024-03-24]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs14184437
- 82) STOURNARAS, Serafeim, Dimitrios LOUKATOS, Konstantinos G. ARVANITIS a Nikolaos KALATZIS. *Crop Identification by Machine Learning Algorithm and Sentinel-2 Data*. In: IOCAG 2022 [online]. B.m.: MDPI, 2022, s. 20 [vid. 2024-03-24]. Dostupné z: doi:10.3390/IOCAG2022-12261
- 83) AgEagle. *MicaSense series*. AgEagle Aerial Systems Inc. [online]. 2024, [vid. 2024-03-24]. Dostupné z: <https://ageagle.com/solutions/micasense-series-multispectral-cameras/>
- 84) AgEagle. *eBee X mapping drone - Drones*. AgEagle Aerial Systems Inc. [online]. 2024, [vid. 2024-03-24]. Dostupné z: <https://ageagle.com/drones/ebee-x/>
- 85) AgEagle. *MicaSense RedEdge MX*. runco [online]. 2024, [vid. 2024-03-24]. Dostupné z: <https://www.runco.com.ar/productos/micasense-rededge-mx/>
- 86) AgEagle. *eBee*. ROBOTS: Your Guide to the World of Robotics [online]. 2012, [vid. 2024-03-24]. Dostupné z: <https://robotsguide.com/robots/ebee>
- 87) AgEagle. *MicaSense. MicaSense* [online]. 2022, [vid. 2024-03-24]. Dostupné z: <https://support.micasense.com/hc/en-us/articles/360011389334-RedEdge-MX-Integration-Guide>
- 88) PlanetScope - Earth Online [online]. 2024, [vid. 2024-03-24]. Dostupné z: <https://earth.esa.int/eogateway/missions/planetscope>
- 89) SAFYAN, Mike. *Planet's First Launch of 2020: 26 SuperDoves on a Vega* [online]. 2020 [vid. 2024-03-24]. Dostupné

- z: <https://www.planet.com/pulse/planets-first-launch-of-2020-26-superdoves-on-a-vega/>
- 90) Planet. *Planet to Launch 36 SuperDove Satellites with SpaceX* [online]. 2022 [vid. 2024-03-24]. Dostupné z: <https://www.planet.com/pulse/planet-to-launch-36-superdove-satellites-with-spacex/>
- 91) PlanetScope. [online]. 2024, [vid. 2024-03-24]. Dostupné z: <https://developers.planet.com/docs/data/planetscope/>
- 92) Planet. *PSScene Imagery Product Spec.* [online]. 2023, [vid. 2024-03-24] Dostupné z: https://assets.planet.com/docs/Planet_PSScene_Imagery_Product_Spec_letter_screen.pdf.
- 93) HUANG, Sha, Lina TANG, Joseph P. HUPY, Yang WANG a Guofan SHAO. *A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing.* Journal of Forestry Research [online]. 2021, 32(1), 1–6 [vid. 2024-03-25]. ISSN 1007-662X, 1993-0607. Dostupné z: doi:10.1007/s11676-020-01155-1
- 94) XUE, Jinru a Baofeng SU. *Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications.* Journal of Sensors [online]. 2017, 2017, 1–17 [vid. 2024-03-25]. ISSN 1687-725X, 1687-7268. Dostupné z: doi:10.1155/2017/1353691
- 95) ZHENG, Alice a Amanda CASARI. *Feature engineering for machine learning: principles and techniques for data scientists.* First edition. Beijing : Boston: O'Reilly, 2018. ISBN 9781491953242
- 96) LEACH, Nicholas, Nicholas C. COOPS a Nikola OBRKNEZEV. *Normalization method for multi-sensor high spatial and temporal resolution satellite imagery with radiometric inconsistencies.* Computers and Electronics in Agriculture [online]. 2019, 164, 104893 [vid. 2024-03-25]. ISSN 01681699. Dostupné z: doi:10.1016/j.compag.2019.104893
- 97) JAVAHERI, Sadaf Hossein, Mohammad Mehdi SEPEHRI a Babak TEIMOURPOUR. *Response Modeling in Direct Marketing.* In: Data Mining Applications with R [online]. B.m.: Elsevier, 2014 [vid. 2024-03-25], s. 153–180. ISBN 9780124115118. Dostupné z: doi:10.1016/B978-0-12-411511-8.00006-2
- 98) ŠTUMPER, Marek a Jakub KRAUS. *Thermal Imaging in Aviation.* MAD - Magazine of Aviation Development [online]. 2015, 3(16), 13–16 [vid. 2024-03-25]. ISSN 1805-7578. Dostupné z: doi:10.14311/MAD.2015.16.03

- 99) KLEIJNEN, Jack P. C. *Validation of models: statistical techniques and data availability*. In: Proceedings of the 31st conference on Winter simulation: Simulation---a bridge to the future - Volume 1 [online]. New York, NY, USA: Association for Computing Machinery, 1999, s. 647–654 [vid. 2024-03-26]. WSC '99. ISBN 9780780357808. Dostupné z: doi:10.1145/324138.324450
- 100) WILLMOTT, Cort J., Scott M. ROBESON a Kenji MATSUURA. A *refined index of model performance*. International Journal of Climatology [online]. 2012, 32(13), 2088–2094 [vid. 2024-03-26]. ISSN 0899-8418, 1097-0088. Dostupné z: doi:10.1002/joc.2419
- 101) NETTLETON, David. *Selection of Variables and Factor Derivation*. In: Commercial Data Mining [online]. B.m.: Elsevier, 2014 [vid. 2024-03-26], s. 79–104. ISBN 9780124166028. Dostupné z: doi:10.1016/B978-0-12-416602-8.00006-6
- 102) CHAI, T. a R. R. DRAXLER. *Root mean square error (RMSE) or mean absolute error (MAE)?* [online]. preprint. B.m.: Numerical Methods. 2014 [vid. 2024-03-26]. Dostupné z: doi:10.5194/gmdd-7-1525-2014
- 103) ROMEO, Giovanni. *Data analysis for business and economics*. In: Elements of Numerical Mathematical Economics with Excel [online]. B.m.: Elsevier, 2020 [vid. 2024-03-26], s. 695–761. ISBN 9780128176481. Dostupné z: doi:10.1016/B978-0-12-817648-1.00013-X
- 104) Mapy Google. [online]. 2024, [vid. 2024-03-24]. Dostupné z: <https://www.google.com/maps/>
- 105) KANDASAMY, S., F. BARET, A. VERGER, P. NEVEUX a M. WEISS. *A comparison of methods for smoothing and gap filling time series of remote sensing observations – application to MODIS LAI products*. Biogeosciences [online]. 2013, 10(6), 4055–4071 [vid. 2024-03-27]. ISSN 1726-4189. Dostupné z: doi:10.5194/bg-10-4055-2013

9. Přílohy

Příloha 1: Srovnání shody dat podle NDVI - UAV a Planet data - různé typy LULC

NDVI pro výřezy	RMSE	RMSE %	R ²	Pearsonova korelace	Willmottův index	MAE
Výřez zástavby UAV VS výřez zástavby Planet	0,1797	29,01	0,15	0,74	0,91	0,15086
Výřez zástavby doplněných UAV dat VS původní UAV data	0,0070	1,02	0,99	0,99	0,99	0,00023
Výřez členité vegetace UAV VS výřez členité vegetace Planet	0,0894	10,04	0,27	0,52	0,98	0,08168
Výřez členité vegetace doplněných UAV dat VS původní UAV data	0,0035	0,50	0,99	0,99	0,99	0,00012
Výřez les UAV VS výřez les Planet	0,0418	4,61	0,11	0,34	0,99	0,03656
Výřez les doplněných UAV dat VS původní UAV data	0,0016	0,23	0,99	0,99	0,99	0,00005
Výřez pole UAV VS výřez pole Planet	0,0706	10,96	0,10	0,32	0,98	0,06243
Výřez pole doplněných UAV dat VS původní UAV data	0,0027	0,40	0,99	0,99	0,99	0,00009
Výřez travnaté louky UAV VS výřez travnaté louky Planet	0,0303	3,22	0,04	0,21	0,99	0,02946
Výřez travnaté louky doplněných UAV dat VS původní UAV data	0,0011	0,17	0,99	0,99	0,99	0,00004

Příloha 2: Srovnání shody dat podle NDVI - UAV a Planet data různé varianty simulace chybějících částí v podobě pruhů

NDVI pro jeden pruh	RMSE	RMSE %	R ²	Pearsonova korelace	Willmottův index	MAE
Výřez 5 % pruhu UAV VS 5 % Planet pruh	0,1012	13,62	0,78	0,93	0,98	0,07615
Výřez 5 % doplněných UAV dat VS původní UAV data	0,0221	2,98	0,99	0,99	0,99	0,00375
Výřez 25 % pruhu UAV VS 25 % Planet pruh	0,1000	13,50	0,79	0,93	0,98	0,07610
Výřez 25 % doplněných UAV dat VS původní UAV data	0,0500	6,82	0,94	0,97	0,99	0,01902
Výřez 50 % pruhu UAV VS 50 % Planet pruh	0,1037	14,41	0,77	0,93	0,98	0,07959
Výřez 50 % doplněných UAV dat VS původní UAV data	0,0726	10,18	0,89	0,95	0,99	0,03925

NDVI pro dva pruhy	RMSE	RMSE %	R ²	Pearsonova korelace	Willmottův index	MAE
Výřez 5 % pruhu UAV VS 5 % Planet pruh	0,1017	13,71	0,77	0,93	0,98	0,07636
Výřez 5 % doplněných UAV dat VS původní UAV data	0,0227	3,05	0,98	0,99	0,99	0,00382
Výřez 25 % pruhu UAV VS 25 % Planet pruh	0,1029	14,30	0,77	0,92	0,98	0,07992
Výřez 25 % doplněných UAV dat VS původní UAV data	0,0515	6,92	0,94	0,97	0,99	0,01998
Výřez 50 % pruhu UAV VS 50 % Planet pruh	0,1047	15,19	0,76	0,92	0,98	0,08186
Výřez 50 % doplněných UAV dat VS původní UAV data	0,0729	9,80	0,89	0,95	0,99	0,03949

NDVI pro tři pruhy	RMSE	RMSE %	R²	Pearsonova korelace	Willmottův index	MAE
Výřez 5 % pruhu UAV VS 5 % Planet pruh	0,0970	13,34	0,73	0,91	0,98	0,07398
Výřez 5 % doplněných UAV dat VS původní UAV data	0,0218	2,93	0,99	0,99	0,99	0,00369
Výřez 25 % pruhu UAV VS 25 % Planet pruh	0,0968	13,38	0,74	0,91	0,98	0,07370
Výřez 25 % doplněných UAV dat VS původní UAV data	0,0488	6,56	0,95	0,97	0,99	0,01842
Výřez 50 % pruhu UAV VS 50 % Planet pruh	0,0972	13,47	0,75	0,92	0,98	0,07387
Výřez 50 % doplněných UAV dat VS původní UAV data	0,0694	9,33	0,90	0,96	0,99	0,03698

NDVI pro čtyři pruhy	RMSE	RMSE %	R²	Pearsonova korelace	Willmottův index	MAE
Výřez 5 % pruhu UAV VS 5 % Planet pruh	0,1016	14,28	0,72	0,91	0,98	0,07861
Výřez 5 % doplněných UAV dat VS původní UAV data	0,0226	3,03	0,98	0,99	0,99	0,00390
Výřez 25 % pruhu UAV VS 25 % Planet pruh	0,1009	15,41	0,74	0,92	0,93	0,07801
Výřez 25 % doplněných UAV dat VS původní UAV data	0,0499	6,71	0,94	0,97	0,99	0,01913
Výřez 50 % pruhu UAV VS 50 % Planet pruh	0,1138	20,15	0,66	0,91	0,92	0,09004
Výřez 50 % doplněných UAV dat VS původní UAV data	0,0692	9,30	0,90	0,96	0,99	0,03733

NDVI pro pět pruhů	RMSE	RMSE %	R²	Pearsonova korelace	Willmottův index	MAE
Výřez 5 % pruhu UAV VS 5 % Planet pruh	0,0986	13,73	0,74	0,91	0,98	0,07614
Výřez 5 % doplněných UAV dat VS původní UAV data	0,0219	2,95	0,99	0,99	0,99	0,00373
Výřez 25 % pruhu UAV VS 25 % Planet pruh	0,1017	15,65	0,68	0,91	0,92	0,07767
Výřez 25 % doplněných UAV dat VS původní UAV data	0,0487	6,54	0,95	0,97	0,99	0,01847
Výřez 50 % pruhu UAV VS 50 % Planet pruh	0,1129	19,94	0,67	0,92	0,92	0,08934
Výřez 50 % doplněných UAV dat VS původní UAV data	0,0700	9,41	0,90	0,95	0,99	0,03739

Příloha 3: Srovnání shody dat podle spektrálních kanálů - UAV a Planet data různé typy LULC

Spektra povrchy		Modrá	Zelená	Červená	Red-Edge	NIR
Výřez zástavby UAV VS výřez zástavby Planet	RMSE	0,0627	0,0556	0,1252	0,1720	0,6151
	RMSE %	12,53	14,93	18,60	35,93	68,29
	R²	0,3126	0,3654	0,1557	0,4102	0,1052
	Pearsonova korelace	0,55	0,60	0,39	0,64	0,32
	Willmottův index	0,69	0,76	0,61	0,66	0,72
	MAE	0,03861	0,03849	0,11010	0,14412	0,57385
Výřez zástavby doplňených UAV dat VS původní UAV data	RMSE	0,0043	0,0052	0,0065	0,0125	0,0238
	RMSE %	0,42	0,45	0,64	1,24	2,27
	R²	0,99	0,99	0,99	0,99	0,99
	Pearsonova korelace	0,99	0,99	0,99	0,99	0,99
	Willmottův index	0,99	0,99	0,99	0,99	0,99
	MAE	0,00012	0,00016	0,00017	0,00040	0,00078
Výřez členité vegetace UAV VS výřez zástavby Planet	RMSE	0,0334	0,0631	0,0537	0,1740	0,7566
	RMSE %	4,99	7,42	4,93	22,21	71,82
	R²	0,20	0,24	0,24	0,24	0,14
	Pearsonova korelace	0,44	0,49	0,49	0,49	0,37
	Willmottův index	0,65	0,68	0,70	0,67	0,72
	MAE	0,02606	0,05402	0,04702	0,14427	0,70254
Výřez členité vegetace doplňených UAV dat VS původní UAV data	RMSE	0,0017	0,0025	0,0017	0,0077	0,0251
	RMSE %	0,16	0,22	0,17	0,77	2,39
	R²	0,99	0,99	0,99	0,99	0,99
	Pearsonova korelace	0,99	0,99	0,99	0,99	0,99
	Willmottův index	0,99	0,99	0,99	0,99	0,99
	MAE	0,00005	0,00007	0,00004	0,00023	0,00080
Výřez les UAV VS výřez zástavby Planet	RMSE	0,0136	0,0421	0,0409	0,0852	0,4444
	RMSE %	2,61	3,88	1,62	10,70	39,47
	R²	0,04	0,06	0,04	0,09	0,11
	Pearsonova korelace	0,21	0,25	0,21	0,30	0,33
	Willmottův index	0,56	0,70	0,72	0,63	0,71

	MAE	0,01023	0,03731	0,03826	0,06603	0,4066
Výřez les doplněných UAV dat VS původní UAV data	RMSE	0,0009	0,0013	0,0005	0,0037	0,0137
	RMSE %	0,08	0,11	0,05	0,37	1,31
	R²	0,99	0,99	0,99	0,99	0,99
	Pearsonova korelace	0,99	0,99	0,99	0,99	0,99
	Willmottův index	0,99	0,99	0,99	0,99	0,99
	MAE	0,00002	0,00004	0,00001	0,00011	0,00042
Výřez pole UAV VS výřez zástavby Planet	RMSE	0,0193	0,0354	0,1342	0,0148	0,3082
	RMSE %	6,49	8,67	6,53	17,93	33,87
	R²	0,01	0,08	0,05	0,15	0,10
	Pearsonova korelace	0,13	0,29	0,24	0,39	0,31
	Willmottův index	0,51	0,73	0,74	0,53	0,74
	MAE	0,01531	0,03282	0,13366	0,01182	0,30716
Výřez pole doplněných UAV dat VS původní UAV data	RMSE	0,0022	0,0030	0,0022	0,0062	0,0118
	RMSE %	0,22	0,26	0,22	0,62	1,12
	R²	0,99	0,99	0,99	0,99	0,99
	Pearsonova korelace	0,99	0,99	0,99	0,99	0,99
	Willmottův index	0,99	0,99	0,99	0,99	0,99
	MAE	0,00007	0,00010	0,00007	0,00021	0,00041
Výřez travnaté louky UAV VS výřez zástavby Planet	RMSE	0,0175	0,0584	0,1115	0,1185	0,8060
	RMSE %	3,69	7,37	1,66	22,53	76,77
	R²	0,00003	0,00104	0,00005	0,00044	0,00651
	Pearsonova korelace	0,0060	0,0322	0,0070	0,0211	0,0807
	Willmottův index	0,73	0,74	0,74	0,74	0,74
	MAE	0,01687	0,05798	0,11133	0,11744	0,80386
Výřez travnaté louky doplněných UAV dat VS původní UAV data	RMSE	0,0012	0,0025	0,0005	0,0078	0,0268
	RMSE %	0,12	0,22	0,05	0,78	2,55
	R²	0,99	0,99	0,99	0,99	0,99
	Pearsonova korelace	0,99	0,99	0,99	0,99	0,99
	Willmottův index	0,99	0,99	0,99	0,99	0,99
	MAE	0,00004	0,00009	0,00002	0,00027	0,00093

Příloha 4: Srovnání shody dat podle spektrálních kanálů - UAV a Planet data simulace chybějících částí v podobě jednoho pruhu

Pro jeden pruh		Modrá	Zelená	Červená	Red-Edge	NIR
Výřez 5 % pruhu UAV VS 5 % Planet pruh	RMSE	0,0334	0,0612	0,1080	0,1244	0,7076
	RMSE %	9,07	12,19	13,59	29,53	72,55
	R²	0,6971	0,7415	0,7518	0,5718	0,0074
	Pearsonova korelace	0,83	0,86	0,86	0,75	0,08
	Willmottův index	0,87	0,84	0,78	0,76	0,72
	MAE	0,02510	0,05537	0,09778	0,10516	0,65942
Výřez 5 % doplněných UAV dat VS původní UAV data	RMSE	0,0200	0,0272	0,0299	0,0657	0,1617
	RMSE %	1,96	2,37	2,98	6,55	15,99
	R²	0,88	0,82	0,89	0,75	0,74
	Pearsonova korelace	0,93	0,90	0,94	0,86	0,86
	Willmottův index	0,96	0,95	0,97	0,92	0,92
	MAE	0,00374	0,00544	0,00471	0,01370	0,03419
Výřez 25 % pruhu UAV VS 25 % Planet pruh	RMSE	0,0328	0,0612	0,1085	0,1236	0,7124
	RMSE %	9,11	12,25	13,65	29,56	73,06
	R²	0,709	0,747	0,770	0,570	0,006
	Pearsonova korelace	0,84	0,86	0,87	0,75	0,08
	Willmottův index	0,88	0,84	0,78	0,76	0,72
	MAE	0,02450	0,05562	0,09879	0,10414	0,66165
Výřez 25 % doplněných UAV dat VS původní UAV data	RMSE	0,0455	0,0612	0,0682	0,1478	0,3653
	RMSE %	4,45	5,34	6,79	14,74	36,11
	R²	0,54	0,40	0,55	0,29	0,29
	Pearsonova korelace	0,73	0,63	0,74	0,54	0,54
	Willmottův index	0,84	0,78	0,85	0,73	0,73
	MAE	0,01900	0,02740	0,02402	0,06887	0,17195
Výřez 50 % pruhu UAV VS 50 % Planet pruh	RMSE	0,0388	0,0659	0,1112	0,1247	0,6719
	RMSE %	9,52	12,47	13,69	29,36	69,56
	R²	0,6435	0,6809	0,7350	0,5026	0,0005
	Pearsonova korelace	0,80	0,82	0,85	0,70	0,02
	Willmottův index	0,87	0,83	0,78	0,76	0,71

	MAE	0,02653	0,05697	0,10026	0,10437	0,61839
Výřez 50 % doplněných UAV dat VS původní UAV data	RMSE	0,0673	0,0881	0,0968	0,2077	0,5036
	RMSE %	6,58	7,68	9,64	20,72	49,79
	R²	0,21	0,13	0,24	0,09	0,14
	Pearsonova korelace	0,46	0,36	0,49	0,30	0,37
	Willmottův index	0,69	0,67	0,69	0,66	0,67
	MAE	0,03868	0,05507	0,04850	0,13585	0,33234

Příloha 5: Srovnání shody dat podle spektrálních kanálů - UAV a Planet data simulace chybějících částí v podobě dvou pruhů

Pro dva pruhy		Modrá	Zelená	Červená	Red-Edge	NIR
Výřez 5 % pruhu UAV VS 5 % Planet pruh	RMSE	0,0335	0,0609	0,1078	0,1242	0,7068
	RMSE %	9,07	12,19	13,54	29,49	72,46
	R²	0,702	0,738	0,752	0,572	0,006
	Pearsonova korelace	0,83	0,85	0,86	0,75	0,07
	Willmottův index	0,87	0,84	0,78	0,76	0,72
Výřez 5 % doplněných UAV dat VS původní UAV data	RMSE	0,02512	0,05513	0,09734	0,10498	0,65740
	RMSE %	0,0203	0,0272	0,0303	0,0660	0,1621
	R²	1,98	2,37	3,01	6,58	16,03
	Pearsonova korelace	0,87	0,81	0,89	0,75	0,74
	Willmottův index	0,93	0,90	0,94	0,86	0,86
Výřez 25 % pruhu UAV VS 25 % Planet pruh	RMSE	0,00379	0,00546	0,00479	0,01377	0,03420
	RMSE %	0,0345	0,0617	0,1112	0,1210	0,6891
	R²	9,25	12,37	13,71	29,47	71,21
	Pearsonova korelace	0,654	0,70	0,746	0,521	0,007
	Willmottův index	0,80	0,83	0,86	0,72	0,08
Výřez 25 % doplněných UAV dat VS původní UAV data	RMSE	0,02554	0,05524	0,1016	0,10066	0,63633
	RMSE %	0,0463	0,0619	0,0686	0,1473	0,3563
	R²	4,52	5,39	6,83	14,69	35,22
	Pearsonova korelace	0,53	0,39	0,55	0,29	0,32
	Willmottův index	0,72	0,62	0,74	0,54	0,57
Výřez 50 % pruhu UAV VS 50 % Planet pruh	RMSE	0,01956	0,02785	0,02481	0,06860	0,16692
	RMSE %	0,0437	0,0723	0,1151	0,1261	0,6444
	R²	9,67	12,41	13,60	28,55	66,95
	Pearsonova korelace	0,6387	0,6523	0,6703	0,4477	0,0009
	Willmottův index	0,79	0,80	0,81	0,65	0,02

	MAE	0,03019	0,05940	0,10262	0,10419	0,58718
Výřez 50 % doplněných UAV dat VS původní UAV data	RMSE	0,0675	0,0882	0,0970	0,2072	0,4996
	RMSE %	6,60	7,68	9,66	20,66	49,39
	R²	0,21	0,12	0,24	0,09	0,15
	Pearsonova korelace	0,46	0,35	0,49	0,30	0,39
	Willmottův index	0,69	0,67	0,69	0,66	0,67
	MAE	0,03880	0,05503	0,04869	0,13509	0,32842

Příloha 6: Srovnání shody dat podle spektrálních kanálů - UAV a Planet data simulace chybějících částí v podobě tří pruhů

Pro tři pruhy		Modrá	Zelená	Červená	Red-Edge	NIR
Výřez 5 % pruhu UAV VS 5 % Planet pruh	RMSE	0,0417	0,0708	0,1094	0,1342	0,6667
	RMSE %	8,00	11,12	11,06	26,17	67,88
	R²	0,62	0,65	0,65	0,45	0,02
	Pearsonova korelace	0,78	0,80	0,80	0,65	0,14
	Willmottův index	0,82	0,78	0,76	0,71	0,71
Výřez 5 % doplněných UAV dat VS původní UAV data	RMSE	0,0189	0,0249	0,0252	0,0600	0,1523
	RMSE %	1,85	2,17	2,51	5,99	15,05
	R²	0,89	0,84	0,92	0,79	0,77
	Pearsonova korelace	0,94	0,92	0,96	0,88	0,87
	Willmottův index	0,97	0,95	0,98	0,93	0,93
Výřez 25 % pruhu UAV VS 25 % Planet pruh	RMSE	0,0427	0,0714	0,1109	0,1360	0,6729
	RMSE %	8,20	11,28	11,11	27,25	68,27
	R²	0,61	0,64	0,63	0,45	0,01
	Pearsonova korelace	0,78	0,79	0,79	0,65	0,12
	Willmottův index	0,83	0,79	0,76	0,72	0,71
Výřez 25 % doplněných UAV dat VS původní UAV data	RMSE	0,0435	0,0567	0,0587	0,1365	0,3446
	RMSE %	4,25	4,94	5,85	13,61	34,06
	R²	0,57	0,48	0,66	0,38	0,35
	Pearsonova korelace	0,75	0,69	0,81	0,61	0,59
	Willmottův index	0,85	0,81	0,89	0,76	0,75
Výřez 50 % pruhu UAV VS 50 % Planet pruh	RMSE	0,0413	0,0727	0,1111	0,1378	0,6793
	RMSE %	8,33	11,15	11,22	27,03	69,78
	R²	0,64	0,67	0,66	0,47	0,01
	Pearsonova korelace	0,80	0,81	0,81	0,67	0,10
	Willmottův index	0,84	0,80	0,77	0,73	0,71

	MAE	0,02907	0,05992	0,09779	0,11519	0,61927
Výřez 50 % doplněných UAV dat VS původní UAV data	RMSE	0,0624	0,0817	0,0858	0,1962	0,4938
	RMSE %	6,09	7,12	8,54	19,57	48,81
	R²	0,33	0,24	0,39	0,16	0,15
	Pearsonova korelace	0,57	0,49	0,62	0,41	0,39
	Willmottův index	0,74	0,71	0,77	0,68	0,67
	MAE	0,03594	0,05069	0,04160	0,12612	0,31925

Příloha 7: Srovnání shody dat podle spektrálních kanálů - UAV a Planet data simulace chybějících částí v podobě čtyř pruhů

Pro čtyři pruhy		Modrá	Zelená	Červená	Red-Edge	NIR
Výřez 5 % pruhu UAV VS 5 % Planet pruh	RMSE	0,0396	0,0660	0,1105	0,1315	0,6756
	RMSE %	8,45	11,04	12,46	28,39	69,22
	R²	0,63	0,66	0,65	0,48	0,01
	Pearsonova korelace	0,79	0,81	0,80	0,68	0,07
	Willmottův index	0,84	0,81	0,77	0,73	0,71
	MAE	0,02874	0,05615	0,09880	0,10938	0,61732
Výřez 5 % doplněných UAV dat VS původní UAV data	RMSE	0,0207	0,0266	0,0288	0,0634	0,1566
	RMSE %	2,02	2,32	2,87	6,32	15,48
	R²	0,87	0,82	90	0,76	0,75
	Pearsonova korelace	0,93	0,90	0,95	0,87	0,87
	Willmottův index	0,96	0,95	0,97	0,93	0,92
	MAE	0,00374	0,00525	0,00448	0,01293	0,03222
Výřez 25 % pruhu UAV VS 25 % Planet pruh	RMSE	0,0418	0,0698	0,1135	0,1303	0,6669
	RMSE %	8,71	11,08	12,28	28,05	68,65
	R²	0,63	0,66	0,69	0,47	0,01
	Pearsonova korelace	0,79	0,81	0,82	0,67	0,12
	Willmottův index	0,84	0,80	0,77	0,73	0,71
	MAE	0,02967	0,05883	0,10059	0,10930	0,60829
Výřez 25 % doplněných UAV dat VS původní UAV data	RMSE	0,0446	0,0583	0,0619	0,1395	0,3487
	RMSE %	4,35	5,08	6,17	13,92	34,48
	R²	0,55	0,45	0,63	0,35	0,34
	Pearsonova korelace	0,74	0,67	0,79	0,59	0,58
	Willmottův index	0,85	0,80	0,88	0,75	0,74
	MAE	0,01823	0,02572	0,02151	0,06359	0,15982
Výřez 50 % pruhu UAV VS 50 % Planet pruh	RMSE	0,0657	0,1009	0,1341	0,1338	0,5279
	RMSE %	10,75	12,67	13,54	26,52	56,58
	R²	0,517	0,538	0,552	0,248	0,006
	Pearsonova korelace	0,71	0,73	0,74	0,49	0,07
	Willmottův index	0,80	0,72	0,73	0,68	0,69

	MAE	0,04270	0,07169	0,11255	0,10469	0,45944
Výřez 50 % doplněných UAV dat VS původní UAV data	RMSE	0,0626	0,0824	0,0871	0,1978	0,4960
	RMSE %	6,11	7,18	8,68	19,73	49,03
	R²	0,33	0,23	0,38	0,15	0,14
	Pearsonova korelace	0,57	0,48	0,61	0,39	0,38
	Willmottův index	0,74	0,71	0,76	0,68	0,67
	MAE	0,03632	0,05145	0,04264	0,12755	0,32140

Příloha 8: Srovnání shody dat podle spektrálních kanálů - UAV a Planet data simulace chybějících částí v podobě pěti pruhů

Pro pět pruhů		Modrá	Zelená	Červená	Red-Edge	NIR
Výřez 5 % pruhu UAV VS 5 % Planet pruh	RMSE	0,0383	0,0676	0,1150	0,1299	0,6714
	RMSE %	8,20	11,39	11,75	27,78	68,18
	R²	0,65	0,66	0,64	0,47	0,01
	Pearsonova korelace	0,80	0,81	0,80	0,69	0,10
	Willmottův index	0,83	0,79	0,76	0,73	0,71
Výřez 5 % doplněných UAV dat VS původní UAV data	RMSE	0,0194	0,0259	0,0271	0,0620	0,1536
	RMSE %	1,90	2,26	2,70	6,18	15,18
	R²	0,88	0,83	0,91	0,77	0,76
	Pearsonova korelace	0,94	0,91	0,95	0,88	0,87
	Willmottův index	0,97	0,95	0,97	0,93	0,93
Výřez 25 % pruhu UAV VS 25 % Planet pruh	RMSE	0,0452	0,0759	0,1152	0,1329	0,6687
	RMSE %	9,04	11,73	12,15	27,93	68,22
	R²	0,64	0,57	0,66	0,47	0,01
	Pearsonova korelace	0,80	0,80	0,81	0,67	0,08
	Willmottův index	0,84	0,80	0,77	0,73	0,71
Výřez 25 % doplněných UAV dat VS původní UAV data	RMSE	0,0445	0,0586	0,0612	0,1396	0,3471
	RMSE %	4,35	5,11	6,10	13,92	34,32
	R²	0,55	0,44	0,64	0,35	0,34
	Pearsonova korelace	0,74	0,66	0,80	0,59	0,58
	Willmottův index	0,85	0,80	0,88	0,75	0,75
Výřez 50 % pruhu UAV VS 50 % Planet pruh	RMSE	0,0666	0,1011	0,1351	0,1344	0,5260
	RMSE %	11,26	13,14	13,88	24,95	56,33
	R²	0,519	0,545	0,559	0,247	0,007
	Pearsonova korelace	0,71	0,73	0,74	0,49	0,08
	Willmottův index	0,80	0,72	0,73	0,67	0,69

	MAE	0,04243	0,07293	0,11292	0,10439	0,45756
Výřez 50 % doplněných UAV dat VS původní UAV data	RMSE	0,0645	0,0836	0,0877	0,1984	0,4943
	RMSE %	6,30	7,29	8,74	19,79	48,86
	R²	0,27	0,20	0,37	0,15	0,15
	Pearsonova korelace	0,52	0,45	0,60	0,39	0,39
	Willmottův index	0,71	0,70	0,76	0,68	0,67
	MAE	0,03664	0,05173	0,04289	0,12789	0,32038