

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

FAKULTA ŽIVOTNÍHO PROSTŘEDÍ

KATEDRA PROSTOROVYCH VĚD



**POROVNÁNÍ SEGMENTAČNÍCH ALGORITMŮ VYUŽITELNÝCH
PRO VYMEZENÍ KORUN STROMŮ Z DAT UAV**

BAKALÁŘSKÁ PRÁCE

VEDOUcí PRÁCE: ING. TOMÁŠ KLOUČEK, PH.D.

BAKALANT: DAVID HOUDEK

2023

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

David Houdek

Geografické informační systémy a dálkový průzkum Země v životním prostředí

Název práce

Porovnání segmentačních algoritmů využitelných pro vymezení korun stromů z dat UAV

Název anglicky

Comparison of segmentation algorithms usable for tree crowns delineation from UAV data

Cíle práce

Cílem bakalářské práce je porovnat segmentační algoritmy obrazu pro vymezení korun stromů z dat pořízených bezpilotními leteckými prostředky (UAV). Hlavním cílem práce je vybrat nejvhodnější algoritmus pro individuální vymezení korun stromů na podkladových datech, která budou vytvořena ze spektrálních snímků pořízených UAV.

Metodika

Rámcovou metodickou náplní bakalářské práce bude:

- (a) Zpracovat spektrální snímky pořízené pomocí bezpilotních leteckých prostředků (UAV) a vytvořit tak vstupní podkladová data;
- (b) Vytvořit validační data na podkladových datech;
- (c) Vybrat vhodné segmentační algoritmy obrazu pro vymezení korun stromů;
- (d) Provést segmentaci na podkladových datech;
- (e) Porovnat výsledky segmentace jednotlivých korun stromů s validačními daty;
- (f) Zhodnotit výsledky jednotlivých algoritmů a vybrat nejvhodnější pro segmentaci korun.

Doporučený rozsah práce

30-50 stran

Klíčová slova

dálkový průzkum Země; spektrální data; balíčky R; segmentace obrazu; vegetační pokryv

Doporučené zdroje informací

- Díaz-Varela, Ramón A. de la Rosa, Raúl León, Lorenzo Zarco-Tejada, Pablo J., 2015. High-resolution airborne UAV imagery to assess olive tree crown parameters using 3D photo reconstruction: Application in breeding trials. *Remote Sens.* 7, 4213-4232. <http://www.mdpi.com/2072-4292/7/4/4213>.
- Ganz, S., Käber, Y., Adler, P., 2019. Measuring tree height with remote sensing-a comparison of photogrammetric and LiDAR data with different field measurements. *Forests* 10. <https://doi.org/10.3390/f10080694>.
- Komárek, J.; Klápště, P.; Hrach, K.; Klouček, T. The Potential of Widespread UAV Cameras in the Identification of Conifers and the Delineation of Their Crowns. *Forests* 2022, 13, 710. <https://doi.org/10.3390/f13050710>
- Minařík, R.; Langhammer, J.; Lendziach, T. Automatic Tree Crown Extraction from UAS Multispectral Imagery for the Detection of Bark Beetle Disturbance in Mixed Forests. *Remote Sens.* 2020, 12, 4081. <https://doi.org/10.3390/rs12244081>
- Panagiotidis, D., Abdollahnejad, A., Surový, P., Chiteculo, V., 2017. Determining tree height and crown diameter from high-resolution UAV imagery. *Int. J. Remote Sens.* 38, 2392–2410. <https://doi.org/10.1080/01431161.2016.1264028>.
- Roussel, J. R., Auty, D., Coops, N. C., Tompalski, P., Goodbody, T. R. H., Meador, A. S., Bourdon, J. F., de Boissieu, F., & Achim, A., 2020. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, 251(February), 112061. <https://doi.org/10.1016/j.rse.2020.112061>.
- Surový, P., Almeida Ribeiro, N., Panagiotidis, D., 2018. Estimation of positions and heights from UAV-sensed imagery in tree plantations in agrosilvopastoral systems. *Int. J. Remote Sens.* 39, 4786–4800. <https://doi.org/10.1080/01431161.2018.1434329>.
-

Předběžný termín obhajoby

2022/23 LS – FŽP

Vedoucí práce

Ing. Tomáš Klouček, Ph.D.

Garantující pracoviště

Katedra prostorových věd

Elektronicky schváleno dne 28. 2. 2023

doc. Ing. Petra Šimová, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 1. 3. 2023

prof. RNDr. Vladimír Bejček, CSc.

Děkan

V Praze dne 18. 03. 2023

Prohlášení:

Prohlašuji, že jsem bakalářskou práci na téma: Porovnání segmentačních algoritmů využitelných pro vymezení korun stromů z dat UAV vypracoval samostatně a citoval jsem všechny informační zdroje, které jsem v práci použil a které jsem rovněž uvedl na konci práce v seznamu použitých informačních zdrojů.

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

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

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

V Praze dne 31. 3. 2023



Poděkování

Rád bych touto cestou svému vedoucímu Ing. Tomášovi Kloučkovi, Ph.D., za odborné vedení práce, cenné rady a vstřícný přístup.

Porovnání segmentačních algoritmů využitelných pro vymezení korun stromů z dat UAV

Abstrakt

Bezpilotní letecké prostředky (UAV) významným způsobem posouvají možnosti pořizování dat dálkového průzkumu Země. Cílem bakalářské práce bylo porovnání volně dostupných segmentačních algoritmů obrazu pro automatické vymezení korun stromů ze spektrálních dat pořízených UAV. Teoretická část práce je zaměřena na problematiku optického DPZ, jeho využití v lesnictví a metody (polo)automatické detekce jednotlivých stromů a vymezení jejich korun zejména z dat UAV. Praktická část práce představuje vlastní metodické řešení zaměřené na zpracování UAV dat metodou Structure from Motion a následné porovnání algoritmů Watershed, Region growing a Voronoi tessellation pro vymezení korun jednotlivých stromů. Náplní práce tedy bylo nejprve z jednotlivých UAV snímků vytvořit digitální výškový model vegetace zájmové oblasti, na který byly následně aplikovány vybrané algoritmy pro detekci a delineaci korun stromů. Takto automaticky vymezené koruny byly následně statisticky porovnány s vlastnoručně vytvořenými referenčními daty o skutečné velikosti korun stromů.

Z výsledků bakalářské práce vyplývá, že nejpřesnějším hodnoceným algoritmem, který se tedy svými velikostmi korun nejvíce blížil referenčním datům, byl obrácený Watershed algoritmus vypočtený pomocí R balíčku Forest tools, který dosáhl RMSPE (Root Mean Square Percentage Error) 23,7 %. Nejméně přesné byly naopak algoritmy Region growing a Voronoi tessellation vypočtené pomocí R balíčku LidR, které dosáhly shodně RMSPE okolo 30 %. Z výsledků a závěru práce proto vyplývá že spektrální UAV data s vysokým prostorovým rozlišením jsou slibným zdrojem informací o lesním porostu, nicméně je stále třeba vyvinout nové přesnější a rychlejší výpočetní algoritmy jejich zpracování, které by ještě zvýšily jejich možnou využitelnost pro praktickou aplikaci v lesním managementu.

Klíčová slova: dálkový průzkum Země; spektrální data; balíčky R; segmentace obrazu; vegetační pokryv

Comparison of segmentation algorithms usable for tree crowns delineation from UAV data

Abstract

Unmanned aerial vehicles (UAVs) are significantly advancing the capabilities of remote sensing data acquisition. The aim of the bachelor's thesis was to compare freely available image segmentation algorithms for the automatic delineation of tree crowns from spectral data taken by UAVs. The theoretical part of the work is focused on the issue of optical DPZ, its use in forestry and methods of (semi)automatic detection of individual trees and delineation of their crowns, especially from UAV data. The practical part of the work presents its own methodological solution focused on the processing of UAV data using the Structure from Motion method and the subsequent comparison of Watershed, Region growing and Voronoi tessellation algorithms for delineation the crowns of individual trees. The task of the work was to at first create a canopy height model of the area of interest from individual UAV images, to which selected algorithms for the detection and delineation of tree crowns were subsequently applied. The crowns automatically delineated in this way were then statistically compared with manually created reference data on the actual size of tree crowns.

The results of the bachelor's thesis show that the most accurate evaluated algorithm, which was therefore closest to the reference data in terms of its crown sizes, was the inverted Watershed algorithm calculated using the R package Forest tools, which achieved an RMSPE (Root Mean Square Percentage Error) of 23.7%. On the other hand, the Region growing and Voronoi tessellation algorithms calculated using the R package LidR were the least accurate, and they both achieved an RMSPE of around 30%. The results and the conclusion of the work therefore show that spectral UAV data with high spatial resolution are a promising source of information about forest cover, however, it is still necessary to develop new more accurate and faster computational algorithms for their processing, which would further increase their possible usability for practical application in forest management.

Keywords: remote sensing; spectral data; R packages; image segmentation; vegetation cover

Obsah

1 Úvod.....	10
2 Cíle práce	11
3 Literární rešerše	12
3.1 Optické DPZ.....	12
3.2 Spektrální chování objektů.....	14
3.3 Dálkový průzkum lesa.....	15
3.3.1 Fyzický sběr dat	16
3.3.2 Letecký sběr dat	16
3.3.3 Družice.....	16
3.3.4 Bezpilotní letecké prostředky (UAV)	17
3.4 Data DPZ.....	17
3.5 Metody detekce stromů	19
3.6 Aktuální stav delineačních algoritmů.....	19
3.7 Metody delineace korun	20
4 Charakteristika území.....	21
5 Metodika	22
5.1 Popis vybrané lokality	22
5.2 Použitá data	24
5.3 Použitý software.....	25
5.4 Zpracování dat.....	26
5.5 Detekce stromů.....	27
5.6 Vymezení korun	27
5.7 Tvorba referenčních dat	29
5.8 Statistické vyhodnocení dat.....	29
6 Výsledky	30
6.1 Výsledky lokálních maxim	30
6.2 Hodnoty delineace korun stromů	30
7 Diskuse	33
8 Závěr a přínosy práce	36
9 Seznam použitých zdrojů	37
10 Seznam obrázků, tabulek a zkratk	42
Seznam obrázků	42
Seznam tabulek	42

Seznam příloh.....	42
Seznam použitých zkratk.....	42
11 Přílohy.....	43

1 Úvod

Dálkový průzkum Země (DPZ) je obor zabývající se sběrem informací za pomoci elektromagnetického záření bez fyzického kontaktu s objekty. Využívá poznatky z fyziky, matematiky a geografie. DPZ je velmi rychle se rozvíjející vědní odvětví, který nám usnadňuje poznávání světa. Velmi nápomocný je například v lesnictví, kde nalézá své uplatnění při inventarizaci lesních porostů, při odhalování problémů v lesích a jejich předcházení spojených například s lesními škůdci, při určování druhové skladby apod. DPZ je tedy velmi efektivním nástrojem umožňujícím detailní management lesních porostů.

Bezpilotní letecké prostředky (UAV) jsou novým impulsem pro dálkový průzkum Země. V současnosti jde o jeden z jeho nejefektivnějších nástrojů. Bezpilotní letecké prostředky nebo chceme-li zkráceně drony, jsou schopné efektivně pracovat v malých letových výškách, a proto pořizovat data s lepší rozlišením, než které nám poskytne mnohem dražší letecký průzkum či družice. Síla těchto nových průzkumných prostředků navíc spočívá v jejich potenciální dostupnosti a relativně nízké ceně.

Lesnictví jako jeden z hlavních uživatelů DPZ dat proto může UAV využít například pro vymezení hospodářského a ochranného účelu lesů, při ochraně lesů před stále častějšími problémy spojenými s klimatickou změnou a špatným hospodařením, pro monitoring a předcházení lesních požárů, kalamit kůrovcových brouků, či sucha. Díky výše uvedeným výhodám tak UAV nabízí efektivní nástroj lesního managementu i pro malé vlastníky lesních pozemků. Jednou z dalších potenciálních aplikací UAV dat je precizní určení základních parametrů jednotlivých stromů (například výška, plocha koruny apod.), které jsou následně využitelné v problematice odhadu množství biomasy. K tomuto účelu lze použít celou řadu různorodých (polo)automatických detekčních algoritmů, které ale v praxi dosahují různé přesnosti.

Bakalářská práce navazuje na studii Komárek et al. (2022), která se zabývala hodnocením UAV dat pořízených řadou senzorů v různých letových výškách a rozšiřuje ji právě o problematiku přesnosti detekčních algoritmů. Hlavní přínos práce tak spočívá zejména v určení nejpřesnějšího z hodnocených algoritmů (Watershed, Region growing a Voronoi tessellation) využitelných pro vymezení korun stromů na základě spektrálních dat s velmi vysokým prostorovým rozlišením pořízených UAV a zpracovaných metodou Structure from Motion (SfM).

Základní struktura práce je rozdělena na řešeršní (teoretickou) část zaměřenou na problematiku optického DPZ, jeho využití v lesnictví a metody (polo)automatické detekce jednotlivých stromů a vymezení jejich korun zejména z dat UAV. Navazující praktická část práce představuje vlastní metodické řešení zaměřené na porovnání vybraných algoritmů využitelných pro vymezení korun stromů. Následně jsou představeny výsledky bakalářské práce, kterou jsou na závěr zasazeny do kontextu doposud publikované odborné literatury.

2 Cíle práce

Tématem bakalářské práce je porovnání segmentačních algoritmů obrazu pro automatické vymezení korun stromů z dat pořízených bezpilotními leteckými prostředky (UAV). Hlavním cílem práce je proto vybrat algoritmus nebo metodu, která dokáže nejlépe najít a následně vymežit koruny stromů na podkladových datech, která byla vytvořena ze spektrálních dat pořízených UAV a zpracovaná metodou Structure from Motion (SfM). Dílčí cíle bakalářské práce souvisí s těmito výzkumnými otázkami:

- A. Jaký ze zvolených algoritmů nejpřesněji vymezuje koruny stromů?
- B. Dochází v případě automaticky vymezených korun stromů k nadhodnocování nebo naopak podhodnocování jejich velikosti?
- C. Jsou současné nástroje dostatečně přesné pro praktickou aplikaci v lesním managementu?


3 Literární rešerše

3.1 Optické DPZ

Elektromagnetické záření

Dálkový průzkum Země (anglicky, remote sensing) se zabývá získáváním informací o objektech na dálku bez přímého kontaktu s nimi (Horák, 2014). K získání informací je využíváno obvykle elektromagnetické záření. Energie tohoto záření spočívá ve vlnění, které se šíří prostorem (Dobrovolný, 1998). Každý objekt, jehož teplota je vyšší než absolutní nula ($0 \text{ °K} = -273,15 \text{ °C}$), emituje nebo odráží elektromagnetické záření (Svatoňová, 2010). To lze pomocí různých přístrojů dálkového průzkumu Země zachytit. Záznamové zařízení pro registraci elektromagnetického záření jsou většinou umístěna na pohyblivých nosičích, zpravidla jsou jimi letadla nebo družice. V současné době se navíc začínají stále více prosazovat i bezpilotní letecké prostředky (UAV) (Horák, 2014).

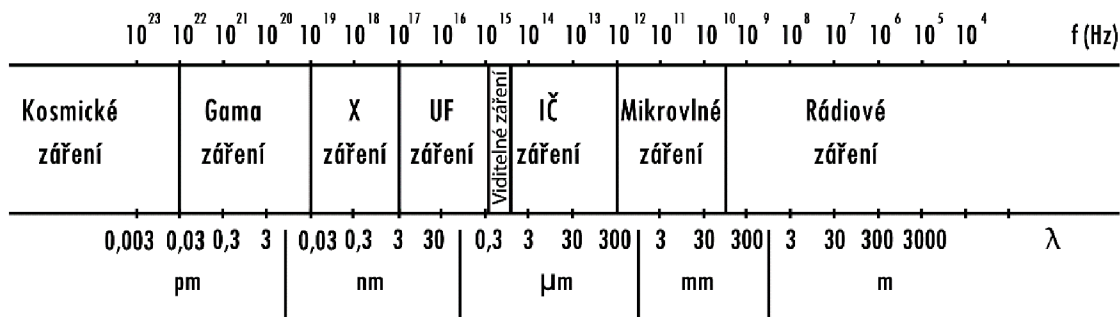
Elektromagnetické záření (Obr. 1) vzniká transformací energie z jiných zdrojů. Takovou formou může být kinetická, chemická, tepelná, elektrická, magnetická nebo jaderná (Kolář et al., 1997). Hlavním zdrojem elektromagnetického záření je Slunce.



Obrázek 1: Schéma elektromagnetické vlny Zdroj: Dobrovolný (1998)

Elektromagnetická vlna je zvláštní případem elektromagnetického pole, kde se periodicky mění velikost intenzity elektrického pole a magnetického pole (Horák, 2014). Základními charakteristikami elektromagnetického záření jsou vlnová délka a frekvence. Vlnová délka je vzdálenost dvou sousedních vrcholů vlny. Frekvence je potom počet vrcholů vlny procházejících fixním bodem za jednotku času. Rychlost šíření elektromagnetické vlny (c) je nepřímo úměrná její vlnové délce (λ) a frekvenci (ν) (Dobrovolný, 1998).

Celé spektrum elektromagnetického záření (Obr. 2) je rozděleno do několika druhů podle vlnové délky nebo frekvence. V dálkovém průzkumu jsou využívány zejména vlnové délky viditelného, infračerveného a mikrovlnného záření (Plánka, 2007).



Obrázek 2: Schéma elektromagnetického spektra Zdroj: Kolář et al. (1997)

Pro popis interakce elektromagnetického záření s objekty se v DPZ využívá částicová teorie. Doteď byla probírána vlnová teorie (Dobrovolný, 1998). Částicová teorie předpokládá, že se elektromagnetické záření skládá z mnoha samostatných jednotek, nazývaných fotony či kvanta. Energie fotonu (Obr. 3) je přímo úměrná frekvenci záření. Elektromagnetické vlnění se nemění, pokud je v homogenním prostředí. Tato ideální pozice, ale na Zemi nikdy nenastane (Horák, 2014).

$$Q = h * \nu = \frac{hc}{\lambda}$$

Obrázek 3: Vzorec pro výpočet energie fotonu Zdroj: Kolář et al. (1997)

Viditelné záření

Člověk má schopnost okem rozlišit a detekovat velmi úzkou část z elektromagnetického spektra. Ostatní části elektromagnetického spektra není schopen jakkoli zachytit nebo rozeznat, pokud k tomu nemá speciální pomůcky (Svatoňová, 2010). Viditelné spektrum (VIS) se nachází v intervalu mezi 0,4 a ž 0,7 μm (Schott, 2007). V hovorové řeči je označováno jen jako světlo. Jde o jedinou část spektra, která může být spojována s pojmem barvy. VIS lze proto rozdělit na dílčí intervaly (Tabulka 1), a to na modré (0,4 - 0,5 μm), zelené (0,5 - 0,6 μm) a červené světlo (0,6 - 0,7 μm). Viditelné světlo je v čisté a suché atmosféře minimálně rozptylováno. Problémem jsou různé aerosoly, které viditelné záření rozptyluje nebo přímo pohlcuje (Dobrovolný, 1998). Barva objektu je určena barvou světla, které odráží (Aggarwal, 2004).

Barva	Interval vlnové délky [μm]
Fialová	0,4 – 0,446
Modrá	0,446 – 0,5
Zelená	0,5 – 0,578
Žlutá	0,578 – 0,592
Oranžová	0,592 – 0,620
Červená	0,620 – 0,700

Tabulka 1: Spektrum viditelného spektra (VIS)

Infračervené záření

Infračervené záření má rozsah 0,750 až 1 000 μm . Pro dálkový průzkum Země má význam hranice do 4 μm , protože záření s větší vlnovou délkou už je silně absorbováno atmosférou a tím pádem je pro Dálkový průzkum Země nevyužitelné (Kolář et al., 1997). Člověk jej není schopen vnímat zrakem, ale denně ho detekuje ve formě tepla (NASA, 2022). Nejčastěji se v DPZ setkáme s blízkým infračerveným (NIR) a krátkovlnným infračerveným (SWIR) (Janssen et al., 2000).

Blízké infračervené záření navazuje na viditelnou část spektra. Je méně ovlivňováno atmosférou, proto jsou snímky ostřejší a kontrastnější. Je stěžejní pro studium vegetace, především v lesnictví a zemědělství. Voda se v těchto vlnových délkách chová jako téměř absolutně černé těleso (Janssen et al., 2000).

Krátkovlnné infračervené záření zahrnuje vlnové délky mezi 1,1 a 3 μm . Je pohlcováno vodou ve třech oblastech: 1,4, 1,9 a 2,4 μm . Využití této části spektra se tedy nabízí zejména v odhadu množství vody obsažené ve vegetaci či půdě. Také je užitečné pro rozlišení mezi typy mraků (mraky vodní a ledové a mezi mraky se sněhem a ledem), které se na snímcích mohou jevit ve stejné barvě (NASA, 2014; Lillesand et al., 2015).

3.2 Spektrální chování objektů

Viditelnost a rozpoznatelnost objektu na snímcích je dána množstvím odraženého záření. Při obvyklém způsobu, kdy se přiřazuje konkrétní odstín šedi určitému množství odraženého záření, bude světlý ten objekt, který odráží hodně záření z té části elektromagnetického spektra, které bylo na snímku zachyceno, a naopak. Intenzita odraženého či emitovaného záření je dána elektromagnetickými vlastnostmi látky ze které se skládá zkoumaný objekt. Vlastnosti závisí na druhu látky, jejím fyzikálním stavu a stavu okolí. Také se však mění v závislosti na vlnové délce použitého záření – mluvíme o spektrální závislosti. (Svatoňová et al., 2010)

Zářivé vlastnosti daného objektu popisuje jeho spektrální charakteristika. Tím myslíme jeho závislost odrazivosti na vlnové délce. Ze spektrálního chování lze pro každý

objekt odvodit spektrální příznaky. Jsou charakteristické pro každý typ povrchu. Dva objekty, které se chovají v 1 pásmu podobně a nelze je rozlišit, mohou mít v jiném pásmu zcela odlišné chování. Na tom předpokladu je postavena jejich možnost rozlišení metodami DPZ. Mimo aktuálních spektrálních vlastností objektů je možnost využít například i změnu jejich spektrálních vlastností v čase. Typickým příkladem je vegetace, která se mění podle ročních období. (Lillesand et al., 2015).

Spektrální vlastnosti vegetace

Spektrální projev vegetace není jednoduchý, ale je výslednicí odrazivých vlastností jednotlivých částí rostlin a pozadí, většinou půdy a vody. Dominantní vliv na prezentaci vegetace v obraze mají listy. Vedle vlastního složení listů se na výsledku interakce projevuje i geometrické uspořádání měření, zejména v případě šikmého snímání. Odrazivost listů ovlivňuje úhlová závislost odrazivosti. Ta je závislá opět na struktuře a stáří listu. Odrazové vlastnosti vegetačního krytu jsou formovány především následujícími faktory (Dobrovolný, 1998):

- Vnější uspořádání vegetačního krytu
- Vnitřní struktura jednotlivých částí rostlin
- Vodní obsah
- Zdravotní stav
- Vlastnosti půdního substrátu

Vnitřní struktura a biochemické vlastnosti listu předurčují optické chování vegetace hodnoceného nástroji dálkového průzkumu Země (Serbin et Townsend, 2020). List obsahuje typicky buněčnou tekutinu, celulózu, tuky, lignin, proteiny, cukry a oleje. Výsledná spektrální charakteristika je dána výsledkem interakce záření s jednotlivými látkami v listu a bude se pochopitelně lišit podle jejich charakteru a zastoupení. Kvantitativně se průběh spektrálních vlastností u jednotlivých druhů rostlin (listů) odlišuje, ale průběh křivek je podobný. Typicky má křivka 3 hlavní části: oblast pigmentační absorpce, oblast vysoké odrazivosti a oblast vodní absorpce (Horák, 2014; Dobrovolný, 1998)

3.3 Dálkový průzkum lesa

Zde se zaměříme čistě na možnosti dálkového průzkumu Země pro zjišťování informací o lesním (vegetačním) pokryvu. Kapitola představuje fyzicky sběr dat v terénu, letecký průzkum, družicové systémy a bezpilotní letecké prostředky (UAV).

3.3.1 Fyzický sběr dat

Fyzický sběr dat je nejprimitivnější způsob, jak získáme informace o rozloze, zdraví nebo třeba množství dřeva. Terénní průzkum má hned několik nevýhod souvisejících s časovou náročností a nutností mobility po zájmové oblasti. V zalesněných oblastech se většinou nemůžeme pohybovat jiným způsobem než lidskou chůzí. Dalším limitem jsou omezené lidské schopnosti získat potřebné informace. I přesto ale má terénní průzkum stále své místo při získávání informací o lesních porostech. Například, když potřebujeme mít kontrolní data pro porovnání s daty získanými DPZ (Panagiotidis, 2017), která jsou důležitá pro ověřování nových nebo zlepšení stávajících metod. Příkladem jsou právě segmentační algoritmy pro vymezení korun stromů (Silva et al., 2016). Pokud chceme spolehlivě ověřit úspěšnost vybraného algoritmu je nutné mít co nejpřesnější referenční data například pořízená přímo terénu (Surový et al., 2018).

3.3.2 Letecký sběr dat

Letecký sběr dat je prvním významným prostředkem DPZ spojený s vynálezem létajícího prostředku, tedy letadla. Zde můžeme zmínit, že lidé už dříve využívaly například horkovzdušné balony, které se ale velmi těžce ovládají. Horkovzdušný balon je totiž pouze unášen větrem a jeho praktičnost v rychlosti pořízení dat je nízká (Kaplan, 2017). Mimo balonů byly také v minulosti jako nosiče využívány různé draky nebo dokonce poštovní holuby (Dobrovolný, 1998).

Letecký průzkum se nejvíce rozmohl až s válečnými konflikty. Opravdu praktické využití přišlo s potřebou válčících stran v první světové válce. Strany konfliktu hledali možnosti, jak vyhrát válku. K tomu bylo potřeba znát nepřítele. Již krátce po vynálezu letadla na počátku 20. století začaly první pokusy s fotografováním z tohoto nosiče. Velký pokrok v leteckém snímkování byl dosažen během první a druhé světové války. Letecké snímkování se využívalo nejen pro vojenské účely, ale také pro topografická mapování, pro aplikace v zemědělství a lesnictví a pro fotogrammetrická měření. Dnes se pořízení dat DPZ pomocí letadel stále využívá, ale ve spoustě situací ho nahradily družice či UAV, které jsou často pro požadovaný úkol vhodnějším nebo levnějším nosičem. Příkladem dnešního využití letadla, jako nosiče senzoru, je pořizování podrobných lidarových dat či ortofota větších oblastí (například na úrovni celých států) (Kaplan, 2017; Dobrovolný, 1998).

3.3.3 Družice

Družice (vědecký správně umělé družice) nebo též satelity pořizují data DPZ při oběhu Země z výšek na hranici atmosféry nebo přímo z vesmíru. První družicí byl sovětský Sputnik 1 v roce 1947, který byl vlastně jen testovacím prototypem, jehož úkolem bylo dokázat, zda jde dopravit na oběžnou dráhu Země uměle vytvořený předmět a komunikovat s ním. Rokem 1947 také naplno začaly vesmírné závody v rámci studené války mezi Sovětským svazem a Spojenými státy americkými. Následovaly roky vývoje a zlepšování

vyslaných satelitů v té době převážně s účelem špionáže protivníkovy území. (Dobrovolný, 1998).

Výhodami družic oproti letadlům je velký záběr území, možnost pravidelného opakování pořizování dat na stabilní dráze a s minimálně se měnícími podmínkami. Problémy jsou samozřejmě spjaty s atmosférou, která blokuje některé vlnové délky elektromagnetického záření a s oblačností, která komplikuje sběr dat v pásmu viditelného a infračerveného spektra. Poslední nevýhodou je často malé prostorové rozlišení dat, které se ale s technologickým pokrokem neustále zlepšuje a dnes lze získat družicová data se submetrovou velikostí pixelu (Kropáček et al., 2020).

S možnostmi průzkumu lesa jsou zejména spjaty družicové systémy Landsat a Sentinel. Landsat je družicový program od agentury NASA. Družice Landsat položily základy k civilnímu využití dálkovému průzkumu Země při monitoringu životního prostředí. Každá z generací družice Landsat disponuje trochu jinými senzory, které ale i přesto lze díky jejich kompatibilitě využít při dlouhodobých časoprostorových analýzách. Nejdůležitějším přínosem mise Landsat je sledování změn krajinného pokryvu (Lauer et al., 1997; Irons et al., 2010). Družice Sentinel jsou hlavními družicemi programu Copernicus. Tento program obsahuje 6 družic, z nichž se každá odlišuje svými senzory, které využívají různých vlnových délek pro sledování zemského povrchu. Nás zde nejvíce zajímají družice Sentinel 1 a 2, které umožňují sledovat lesní porost a zemědělské plodiny. (Kropáček et al. 2020; Navarro et al., 2019; Segarra et al., 2020).

3.3.4 Bezpilotní letecké prostředky (UAV)

Bezpilotní letecké prostředky (UAV) nebo též drony jsou dnes novou hybnou silou v oblasti DPZ. UAV je technologie, která se v posledních letech velmi rychle rozvíjí, a to jak z pohledu samotných nosičů, tak miniaturizovaných senzorů. Používají se jak RGB, a multispektrální, tak termální senzory. Během jednoho náletu je možné nasnímat i několik desítek hektarů. V současné době se využívají různé typy UAV, a to jak multikoptéry, tak i letouny (nazývané též křídla) (Fahlstrom et al., 2022).

Výhodou UAV oproti jiným druhům DPZ nosičů, je jejich možnost nasnímat území z velmi malé letové výšky. Let je možno přednastavit předem a není bezpodmínečně nutné UAV manuálně řídit, pouze je třeba ho „hlídat“, jak stanovuje legislativa (Stöcker et al., 2017). Poslední výhodou je vzlet z místa nebo z ruky. To samozřejmě záleží na typu dronu. Běžné UAV mohou nést spektrální senzory pořizující data v pásmech VIS až NIR, silnější modely zvládnou unést i lidarová a termální měřící zařízení. (Dainelli et al., 2021)

3.4 Data DPZ

Spektrální UAV data

Spektrální RGB data patří mezi jedny z nejlevnějších a nejdostupnějších UAV dat. Jde jen o zachycené VIS záření, které normálně vidí zdravý člověk svými očima. U RGB senzorů se můžeme bavit o různých parametrech, které nám ovlivňují pořizovaná data. Většinou ale stejně platí pravidlo, že čím dražší je přístroj, tak tím kvalitnější jsou obvykle

výsledná data. Tento předpoklad platí obecně u většiny nejen UAV technologií (Jang et al., 2020).

RGB snímky lze nejčastěji využít pro tvorbu ortofotomozaiky analyzované oblasti. Případně pro tvorbu referenčních dat například v procesu klasifikace. RGB snímky se rovněž dají použít pro tvorbu výškových modelů vegetace (Canopy Height Model; CHM) pomocí metody Structure from mMotion (SfM) ve specializovaných softwarech (Iglhaut et al., 2019).

UAV multispektrální a hyperspektrální data nám poskytují oproti RGB snímků lepší možnosti v analýzách zaměřených na studium spektrálních vlastností objektů na zemském povrchu. Jednou z takových úloh je například analýza vegetačního pokryvu, pro kterou je v případě multispektrálních snímků zásadní pásmo NIR, které je velmi nápomocné při odlišení vegetace od svého okolí. Hyperspektrální data nabízí ještě více úzkých na sebe navazujících spektrálních pásem, které tak mohou napomoci ještě k přesnější analýze vegetace. Na druhou stranu, stejně jako v případě RGB snímků je, možné i z individuálních multispektrálních i hyperspektrálních dat vytvořit ortofotomozaiky i výškové modely vegetace. Nevýhodou obou senzorů je naopak mnohonásobně vyšší cena než v případě RGB (Lillesand et al., 2015).

Lidarová data

Přestože tato práce s lidarovými daty přímo nepracuje, je nutné se o nich zmínit a vysvětlit jejich princip, možnosti využití a výhody i nevýhody. Jde o data, která se již celkem běžně několik let vy užívají v lesnictví. Hlavním důvodem jejich časté aplikace je vysoká přesnost pořízených dat a z nich odvozených parametrů lesních porostů. Řada vědeckých prací i praktických aplikací v oblasti lesnictví používá lidarová data pro určení zejména přesné výšky a polohy porostu (Akay et al., 2009). Nevýhodou lidarových dat, a to ať pořízených senzorem neseným na letadle i UAV, je jejich vysoká pořizovací cena. Proto se napříč literaturou setkáváme s mnoha studií snažící se lidar nahradit jinými technologiemi, například právě spektrálními UAV data zpracovanými metodou SfM (Westoby et al., 2012).

LiDAR je zkratkou anglického názvu “Light Detection and Ranging”. Jedná se o druh aktivního dálkového průzkumu Země, který je svým principu podobný radarovému DPZ. Rozdíl je v opakovaném vysílání laserového pulsu do určitého bodu, z kterého se následně zaznamenává odraz. Metoda je založena na vyhodnocení časového intervalu mezi vysláním a návratem pulsu (Horák, 2014). Ideální je tato metoda pro tvorbu výškových modelů jako je digitální model reliéfu (DMR), digitální model povrchu (DSM), případně digitální výškový model vegetace (CHM). (Khosravipour et al., 2014)

LiDAR se široce aplikuje v lesnictví právě pro tvorbu výškových modelů vegetace, odhad biomasy, tvorbu vertikálních profilů vegetace, a navíc umožňuje výpočet široké škály metriky na úrovni individuálních stromů. Na lidarových datech jsme na rozdíl od metody SfM, schopni lépe oddělit body země (ground body), které se odrazí jako poslední a vegetaci, od které se odrazy vrací dříve (Dubayah a Drake, 2000). Z takto zpracovaných bodových mračen jsme následně schopni vytvořit velmi přesný CHM. Jeho přesnost, ale samozřejmě

přímo závisí na hustotě bodového mračna. Z hustého bodového mračna jsme schopni odhadnout velmi přesně lesnické metriky jednotlivých stromů a množství biomasy v lese (Dalponte a Coomes, 2016). V neposlední řadě jsou lidarová data schopna detekovat strukturální změny lesního porostu v čase (Dubayah a Drake, 2000).

3.5 Metody detekce stromů

Lokální maxima

Prvním krokem pro vymezení vrcholů stromů a jejich korun je algoritmus lokálního maxima (Local Maxima; LM). Někdy se tento přístup bere společně s algoritmem pro vymezení korun stromů jako jeho neoddělitelná součást, nicméně v této práci se zaměříme na každý z algoritmů individuálně (Panagiotidis et al, 2017). Jedná se o matematickou analýzu obrazu za účelem nalezení vrcholu stromů. Tato metoda tedy předpokládá vztah mezi největšími hodnotami v obraze a vrcholy hledaných stromů. Lokální maxima se vyskytují v odborné literatuře často pod zkratkou LM (Popescu a Wynne, 2004).

Nejdůležitějším bodem metody hledání lokálních maxim je nastavení oblasti, kde hledáme lokální maximum. Tato oblast je nazývána oknem, které musíme správně nastavit. Nastavují se dvě důležité věci. Prvním je tvar okna a druhým důležitějším parametrem je jeho velikost. Právě velikost okna má totiž největší dopad na výsledné množství a správnost detekce lokálních maxim (vrcholů stromů). Určující hodnotou (mimo průměrné velikosti koruny v zájmovém území) pro nastavení této proměnné je rozlišení rastru, na kterém analýzu provádíme. Větší rozlišení rastru se rovná menšímu oknu. Menší rozlišení rastru znamená nutnost nastavit větší okno (Wulder et al., 2000).

3.6 Aktuální stav delineačních algoritmů

S delineačními algoritmy je to v době zpracování této práce problematičtější. Hlavním problémem je jejich dostupnost a možnosti širší veřejnosti se k těmto algoritmům dostat, pochopit a pracovat s nimi. Rovněž nejsou tolik otestované jako hledání lokálních maxim. Většina prací má za cíl vyhodnotit výšku stromů nebo jen zjistit jejich polohu a delineaci koruny se už nezabývají.

V této práci pracujeme s balíčky vytvořenými do programu R studio, které jsou volně dostupné. Jedná se o balíčky jako LidR (Roussel et al., 2022), rLiDAR (Silva et al., 2021) nebo Forest tools (Plowright a Roussel, 2021), které primárně jsou určeny pro úpravu lidarových dat. Z těchto balíčků se podařilo použít níže zmíněné tři algoritmy pro segmentaci korun stromů.

3.7 Metody delineace korun

Seeded region growing

Seeded region growing, někdy též pouze region growing, je velmi obecně řečeno pixelovou metodou segmentace obrazu. Metoda rozděluje obraz na jednotlivé regiony se stejnými parametry, které byly stanoveny na počátku analýzy (Adams et al., 1994). V případě segmentace korun stromů vychází region growing algoritmus z lokálních maxim, které představují detekované vrcholy stromů. Proto tento algoritmus najdeme pod názvem seeded region growing (Dalponte et al., 2015).

Algoritmus vezme lokální maxima, každé s unikátním číslem a hledá v případě studie Dalponte et al. (2015) v mračnu nebo v rastru v okolí vrcholu sousední body, které by mohl přidat. Při splnění podmínek připojuje okolní pixely podle námi nastavených parametrů. Vlastně, jak z názvu algoritmu vypovídá, nám kolem vrcholů stromů “vyrostou” koruny stromů (Hyypä et al., 2001).

Obracený watershed algoritmus

Watershed je původně hydrologický nástroj pro vymezení území povodí, který běžně najdeme v balíčcích programů pro práci s prostorovými daty. Jde o jeden z nejběžněji používaných a velmi oblíbených algoritmů v oblasti segmentace (Panagiotidis et al., 2017). V případě detekce korun nástroj funguje velmi podobně jako v případě vymezení povodí. Jako vstupní data, funkce potřebuje pro vymezení povodí odtokový bod. Jde o bod, kterým oteče veškerá voda z povodí. V případě stromů jde o jejich vrchol, který se pro tuto metodu musí stát lokálním minimem. Jednoduše tedy jak detekované vrcholky stromů, tak vstupní CHM rastr vynásobíme minus jedničkou. Proto se někdy setkáváme v odborné literatuře s pojmem lokální minima místo maxima, nicméně pro potřeby analýzy jde víceméně o totožná vstupní data (Edson et al., 2011). Algoritmus si seřadí všechny vrcholy stromů do seznamu. Z toho následně vybere vždy ten s nejvyšší hodnotou a virtuálně zaplavuje okolní pixely, dokud nenarazí na hranici odkud by se přelila voda do dalšího území a vyřadí ho ze seznamu. Tímto projde celý seznam, dokud nezůstanou žádné vrcholy. Výsledkem analýzy je CHM rastr území rozdělený do subpovodí, která reprezentují vymezené koruny stromů (Carleer et al., 2005; Panagiotidis et al., 2017)

Voronoi tessellation algoritmus

Tento algoritmus je primárně určen pro zpracování Lidarových dat, ale lze jej použít i na CHM doručené jiným způsobem (Roussel et al., 2022). Algoritmus opět používá vrcholy (seeds) jako body z kterých přibližně navrhne přibližný buffer (oblast o daném poloměru) v bodě vrcholu. Následně použije centrální voronoi tessellation, který použije vrchol stromu jako těžiště pro rozdělení okolních pixelů mezi vrcholy stromů (Aurenhammer et Klein, 1999). Vahou těžiště je hodnota výšky vrcholu stromu. Tím izoluje jednotlivé koruny stromů do polygonů a vznikne nám mapa korun stromů (Silva et al. 2016).

4 Charakteristika území

Lokalita jejíž data byla zpracována v této práci je součástí chráněné krajinné oblasti Křivoklátsko, dále jen CHKO Křivoklátsko. CHKO Křivoklátsko se nachází v západní části Středočeského kraje (Obrázek 4). Má přibližnou rozlohu 628 km² a jde o velmi silně zalesněnou a členitou oblast. Napříč jejím územím protéká řeka Berounka. Hlavní charakteristiky této oblasti zabránily člověku, aby ji více ovlivnil a kolonizoval (AOPK ČR, 2022).



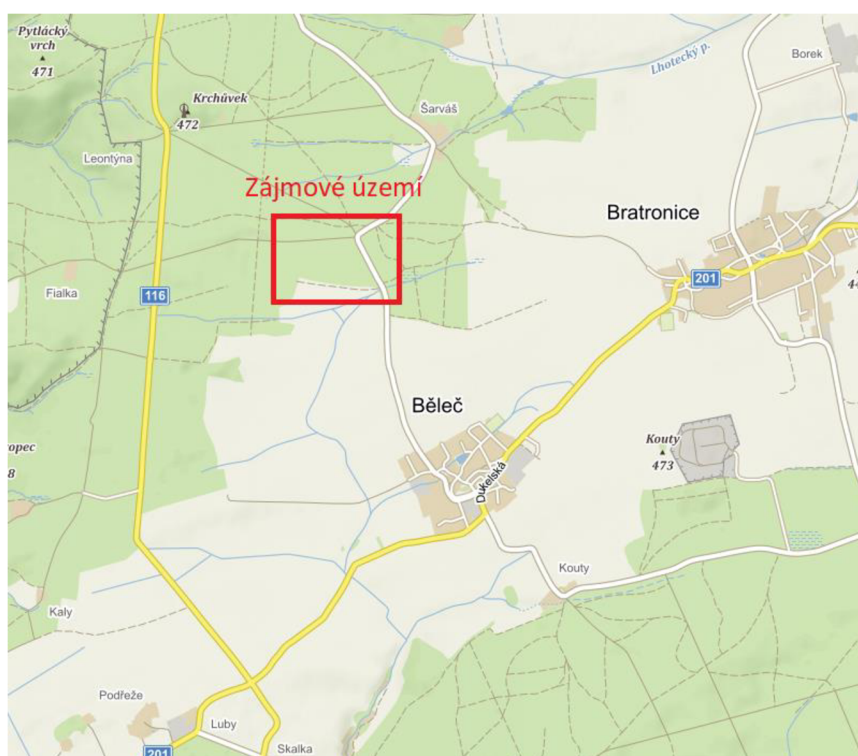
Obrázek 4: Poloha zájmového území; Zdroj: vlastní zpracování, ArcGIS Online (ESRI)

Od raného středověku hrálo Křivoklátsko úlohu loveckého hvozdu. V 19. století Křivoklátsko získalo na významu jako zdroj dřeva a začalo se zde rozvíjet lesnictví. To mělo vliv na druhovou skladbu vegetace. Začaly zde převládat jehličnaté stromy, a to hlavně smrky a borovice. Jde sice rovněž o původní vegetaci, ale jejich zastoupení vysoce převyšuje listnaté stromy a náročnější jehličnaté stromy jako jsou například jedle. (Ložek et al, 2005). Od 1. března 1977 bylo území v programu Mab (Man and the biosphereOblast) od organizace UNESCO prohlášeno za biosférickou rezervaci. O rok později 1978 byla vyhlášeno jako CHKO výnosem Ministerstva kultury (AOPK ČR, 2022). V plánu je na části území povýšit status Křivoklátska z chráněné krajinné oblasti na národní park (Stloukal, 2022). Zda bude národní park opravdu vyhlášen je otázkou. Vyhlášení se stále odkládá a není jisté kdy k němu dojde (České noviny, 2023).

5 Metodika

5.1 Popis vybrané lokality

V bakalářské práci využívaná vstupní data zachycují území nacházející se severně od obce Běleč na souřadnicích 50° 04' s. š., 13° 59' v. d. (Obrázek 5). Lokalita má rozlohu přibližně 15 hektarů. Nadmořská výška místa se pohybuje od 420 do 435 metrů nad mořem (Komárek et al, 2022). Na lokalitě se nachází smrko-borovicový hospodářský les, jehož primárním účelem je produkce dřeva. Dominantní zastoupení proto mají jehličnaté druhy stromů, přibližně 40 % zastoupení má borovice a smrky, 20 % modřínů (Komárek et al, 2022).



Obrázek 5: Poloha zájmového území, Mapy.cz (Seznam.cz)

Les lze navíc rozdělit do dvou částí podle jeho stáří, s kterým souvisí výška jednotlivých porostů. Jedna část zájmového území je tvořena starý až 40 metrů vysoký les s větším zastoupením borovic a modřínů. Druhou část území naopak tvoří mladší les dosahující výšky mezi 10 až 20 metry s dominantnějším zastoupením smrku (Obrázek 6).

Přírodní podmínky

CHKO Křivoklátsko spadá do mírně teplé klimatické oblasti. Průměrná roční teplota dosahuje 7–8 °C. Křivoklátsko se nachází ve srážkovém stínu, a proto průměrný roční úhrn srážek činí 500 až 550 mm. Ve vegetačním období pouze 350 mm a většina tohoto úhrnu spadne v červenci. I přesto si tato oblast udržuje velký rozsah lesů a poměrně hustou síť menších vodních toků. Křivoklátsko ovlivňují dva geologické fenomény. Prvním je říční

fenomén, který se projevuje kaňonovitým údolím řeky Berounky s rozvětvenou sítí postranních přítoků v celé oblasti Křivoklátska. Druhým je vrcholový fenomén projevující se bezlesím na jižních a jihozápadních temenech některých vrcholů (Ložek et al, 2005). Cílem ochrany jsou velmi mikroklimaticky rozdílná stanoviště a ochrana říčního reliéfu řeky Berounky. I přes zásahy člověka do biodiverzity rozsáhlých lesních porostů a změnám v oblasti říčního koryta kvůli rekreačním účelům si Křivoklátsko udržuje velkou biodiverzitu (ANONYMUS, 2017).

Charakteristika vegetace

Borovice lesní je jehličnan dorůstající do výšky až 40 m, s rozvolněnou, nepravidelnou korunou (Fenofáze, 2023). Koruna v severní a severovýchodní části evropského areálu štíhlá s jemným větvením, ve střední a jižní části převažují jedinci s klenutou až deštníkovitou korunou a silnými větvemi. Kmen přímý, na extrémních stanovištích často křivolaký (Botany, 2023). Borovice lesní patří mezi nejvýznamnější hospodářské dřeviny. Poskytuje vynikající pružné, lehké a měkké pryskyřičnaté dřevo. Je často vysazována v rekultivacích pro zpevnění sutí a písčitých půd i sadovnický jako okrasný strom (Skalický V. 1988). V lesnické praxi se vysazuje po celém území, často právě na horších, jinak těžko využitelných půdách (Fenofáze, 2023).

Smrk ztepilý je strom vysoký až 50 m s kuželovitou korunou, v horských oblastech a rozvolněných porostech zavětvenou často až k zemi. Větve jsou mírně vztyčené nebo mírně ohnuté k zemi (u starších stromů), jen ve vrcholových partiích vždy mírně vztyčené, větvičky převislé. Lesnickým hospodařením byl rozšířen i do nižších poloh a na nepůvodní lokality, kde mnohdy vytváří rozsáhlé monokultury, přičemž právě porosty vykazují velkou ekologickou nestabilitu. (Botany, 2023).

Modřín opadavý je opadavý jehličnatý strom s průměrnou výškou až 35 m. V mládí má jeho koruna štíhlý a pravidelně kuželovitý tvar. U starších jedinců koruna často řídne a stává se nepravidelnou (Zoo Praha, 2023). Původní rozšíření modřínu opadavého zahrnuje Alpy, Karpaty (slovenské, ukrajinské a rumunské) a Polsko. Mnohde se vyskytovaly jen určité subspecie. U nás je původní pouze na východ od Hrubého Jeseníku, všechny ostatní výsadby modřínů jsou vesměs nepůvodní (Botany, 2023).



Obrázek 6: Vybraná testovací data

5.2 Použitá data

Vstupní UAV data byla poskytnuta od vedoucího práce a v nedávné minulosti už byla použita pro vědeckou práci publikovanou pod hlavičkou ČZU v odborném časopise (Komárek et al, 2022). Studie Komárek et al. (2022) se zabývá vlivem různých spektrálních senzorů umístěných na UAV (pořizující data v různých letových výškách) na přesnost detekce jednotlivých stromů a jejich korun (Komárek et al, 2022). Konkrétně se jednalo o senzory Zenmuse X5S FC6520 (Matrice 210), Phantom 4 FC 6310 (Phantom 4), RedEdge-M (Phantom 4 Pro) a Sequoia (Disco Pro Ag).

Snímky byly pořízeny ve 100 m AGL, 150 m AGL a 200 m AGL (AGL – Above Ground Level; nad zemským povrchem). Sběr dat proběhl 26. února 2019 mezi 10 hodinou dopoledne a 3 hodinou odpoledne, a to za příznivých meteorologických podmínek. Bylo většinou zataženo, teplota okolo 12 °C a vítr severozápadní o rychlosti mezi 2–5 m.s⁻¹. Nejlepších výsledků ve studii dosáhla data pořízená z Phantom 4 Pro (Obrázek 7) z výšky 150 m AGL (Komárek et al, 2022). Právě tyto RGB snímky byly použity jako vstupní data pro řešení bakalářské práce.



Obrázek 7: Dron Phantom 4 Pro A.Savin, Zdroj: WikiCommons

Phantom 4 Pro (Tabulka 2) je poloprofesionální bezpilotní letecký prostředek (UAV) od čínské technologické společnosti DJI. Dle uživatelské příručky je určený primárně k pořizování video záznamu pro reklamní účely, filmový průmysl nebo k mapování v krajinného pokryvu. Potencionálních možností využití má ale mnohem více (dronpro.cz, online 2023). Například monitoring vegetace jako tomu bylo v případě studie (Komárek et al. (2022) nebo pořízení fotogrammetrických dat různých objektů ve vnitřních nebo vnějších interiérech (Peppa, 2019). Nevýhodou tohoto UAV je jeho vydrž ve vzduchu, která je pouze 30 min. Phantom 4 Pro nese integrovaný senzor FC6310, který nejde oddělit od trupu dronu. Celý jeho název je jednopalcový CMOS senzor FC6310. Jde o RGB kameru pořizující snímky v rozlišení 5472×3628 pixelů (dronpro.cz, online 2023).

Technické specifikace stroje	
Typ UAV	Kvadroptéra
Váha	1388 g
Maximální délka letu	30 min.
Provozní teplota	0 °C–40 °C
Maximální dosah	7 km
Parametry senzoru	
Rozlišení	19,8 MP
Spektrální pásma	VIS (RGB)
Zorné pole	84°

Tabulka 2: Technické specifikace dronu Phantom 4 Pro, Zdroj: dji.com (2023) a Komárek et al (2022)

5.3 Použitý software

Pro zpracování dat bylo použito několik softwarů. Prvním a pro nás nejdůležitějším z nich je program R studio Desktop (verze 4.2.2, R Core Team). Ten nabízí rozhraní pro práci s programovacím jazykem R. Pro tuto práci byly všechny algoritmy pro vymezení korun prováděny skrze tento program. Rovněž výpočet chyb měření a úspěšnost postupů byl opět proveden v tomto programu pomocí vhodných, volně dostupných balíčků. Dalším

programem byl Agisoft Metashape (verze 1.6.2, Agisoft LLC) umožňující provedení procesu Structure from Motion (SfM). Byl použit pro zpracování surových dat (RGB snímků zájmového území) a vyhotovení modelů vegetace (CHM). Posledním programem byl ArcGIS Pro Desktop (verze 3.1.0, Esri). Tento program určený pro práci s prostorovými daty b. Byl využit pro průběžnou kontrolu výstupů z programu R, tvorbu validačních dat a vyhotovení grafických výsledků.

5.4 Zpracování dat

Jak už bylo řečeno, našimi vstupními daty jsou RGB snímky z UAV Phantom 4 Pro. Jde o 136 snímků v rozlišení 5472x3628 pixelů. Snímky byly pořízeny nad územím v 7 letových řadách. Informaci ohledně své přesné polohy má každá fotografie uloženou v takzvaném EXIF formátu, který můžeme považovat za metadata. V EXIF je tedy uvedena přesná GPS poloha každého pořízeného snímku v souřadnicový systém WGS84 (EPSG: 4326).

Vstupní data byla zpracována v programu Agisoft Metashape Professional (verze 1.6.2, Agisoft LLC). Tento program zpracovává snímky metodou Structure from Motion. Do softwaru byly nejprve nahrány a následně vyrovnány snímky zájmového území. Bylo vygenerováno řídké bodové mračno s parametry *Accuracy: High*, *Key point limit: 40 000*, *Tie point limit: 4 000*. Většina nastavení zůstala ve výchozím stavu, jak je nabídne sám Agisoft. Jak uvádí ve své studii Tinkham a Swayze (2021) je pro zpracování kvalitně pořízených UAV dat zobrazujících lesní vegetaci dostačující ponechat základní nastavení, které nám Agisoft přímo nabídne. Nastavení parametru *Accuracy* na *Very high* a *zahuštění bodového mračna* opět na *Very high* ukazovaly mírné zlepšení, ale za cenu mnohem větších hardwarových nároků. Zahuštění bodového mračna bylo tedy nastaveno na *Quality: High* a jako *Filtrační model* byla zvolena metoda *Mild*. Některé studie provádí filtraci metodou *Aggressive* (Minařík at al, 2020), ale v rámci bakalářské práce jsem se rozhodl držet studie od W.T. Tinkhama a N.C. Swayze (2021).

Pro tvorbu DTM bylo nutné nejdříve klasifikovat ground body přes Agisoft funkci *Classify ground points* v tool záložce. Klasifikace byla provedena metodou pokus omyl. Výsledky klasifikace byly ještě vizuálně zkontrolovány před vygenerováním DTM. Klasifikace byla většinou přesná až na oblast nejvzrostlejšího lesa v centrální části mračna. Zde zbyly tři oblasti ground bodů, ve kterých algoritmus klasifikoval některé části nízké lesní vegetace jako ground body. Tyto chyby byly ručně opraveny. Z výsledného klasifikovaného bodového mračna jsem vygeneroval digitální model povrchu (DSM) a digitální model terénu (DTM). Prázdna místa mezi body byla dopočítána pomocí interpolace.


Na závěr jsem v Agisoftu vygeneroval rovněž ortofotomozaiku, která sloužila v další části práce jako podklad pro tvorbu referenčních dat představujících reálnou velikost korun stromů. Barevná ortofotomozaika byla vygenerována na základě DSM v rozlišení 3,5 x 3,5 cm a formátu .tiff. Výsledky práce v programu Agisoft Metashape byly ortofotomozaika v

rozlišení 3,5 cm, DTM a DSM s rozlišením 6,8 cm. Všechny modely byly vyexportovány v souřadnicovém systému S-JTSK / Krovak East North (EPSG: 5514). Všechny tři se shodným formátem .tiff.

Tvorba výškového modelu vegetace (CHM) proběhla v programu ArcGIS Pro (verze 3.1.0, Esri). CHM byl jednoduše vytvořen funkcí minus odečtením výšky terénu (DTM) od výšek povrchu (DSM). Následně byla rovněž v ArcGIS Pro všechna výše vypočtená data oříznuta na finální zájmové území, na kterém budou dále hodnoceny provedené segmentace korun stromů provedena. Pro tuto analýzu byl vybrán výřeza oblast okolo 100 x 100 metrů v oblasti vzrostlého lesau v centrální části snímaného porostu.

5.5 Detekce stromů

K zprostředkování algoritmů pro identifikaci vrcholů stromů a na jejich základě vymezených korun stromů byl použit software R studio, ve kterém jsou volně dostupné balíčky určené jak pro ITC (individual tree detection), tak ITS (individual tree segmentation). Pro oba metodické kroky byly použity balíčky lidR (Roussel et al., 2022) a Forest tools (Plowright a Roussel, 2021). Prvním krokem k delineaci, tedy vymezení, korun stromů je nalezení jejich vršků (Obrázek 8). Oba použité balíčky shodně nabízí filtrování lokálních maxim pro nalezení vrcholů stromů. Doporučeným nastavením je variabilní okno, které se mění podle konkrétní situace v analyzovaném rastru a nástroj automaticky nastaví jeho optimální velikost.



Obrázek 8: Výsledek filtrace lokálních maxim (ilustrativní)

5.6 Vymezení korun


Druhým metodickým krokem je potom samotné vymezení korun stromů, které bylo provede pomocí algoritmů Watershed, Region growing a Seed voronoi tessellation. Ty to tři algoritmy používají jako vstupní data výškový model vegetace (CHM) a vyfiltrovaná lokální

maxima z předchozího kroku. Watershed algoritmus z balíčku Forest tools je primárně určen pro zpracování rastrových dat. Funkce má několik vstupů. Kromě volby, která data z předchozích kroků vložíme do procesu, volíme ještě další parametry. Například Parametr výškového stropu, pod který už funkce nemá brát pixely pro koruny stromů. Tento parametr jsem nastavil na 5 metrů tak, aby nám algoritmus nepřidával do výsledných korun stromů nízké lesní vegetace. Poslední krokem byla volba výstupního formát segmentace, ve kterém jsem ponechal raster formát (Obrázek 9).

Algoritmy Region growing a Seed voronoi tessellation byly provedeny pomocí balíčku lidR. Oba algoritmy jsou dle dostupné dokumentace primárně určeny pro zpracování výškového modelu vytvořené z lidarového mračka. To ale nebrání jeho nahrazení výškovým modelem vegetace vytvořeným metodou SfM z RGB snímků. Obě funkce mají obsahují řadu parametrů, které ovlivňují výsledek segmentace korun stromů. Volba těchto parametrů byla založena na metodě pokus-omyl, při které byla vyzkoušena různá nastavení a jejich vliv na výslednou segmentaci korun stromů.

Region growing algoritmus, je v rámci lidR převzatý z balíčku itcSegment (Roussel et al., 2022). V nastavení funkce se nachází opět vložení výškového modelu vegetace a vrstva detekovaných lokálních maxim. Stejná je i možnost nastavení prahové hodnoty pod kterou už funkce nemá pixely přidávat do oblasti korun. Odlišným nastavením od předchozí funkce Watershed jsou dvě nastavení tresholdů představující, jak má algoritmus přidávat okolní pixely k maximu a nastavení maximální hodnoty koruny v pixelech. Avšak opět metodou pokus-omyl bylo zjištěno, že pouze změna nastavení maximální hodnoty korun má výrazný vliv na dosažený výsledek. Nicméně nejvěrohodnějšího výsledku bylo dosaženo se základním nastavením. Funkce vrací opět pouze segmentovaný raster.

Seed voronoi tessellation je ekvivalentem k funkci Nearest neighbour. Nastavení se zase víceméně neliší od ostatních výše uvedených funkcí. Důležité je vložit vstupní výškový model vegetace a vyfiltrovaná lokální maxima. Podobně jako u Region growing algoritmu je i zde parametr maximální velikost koruny. Posledním možným nastavením je parametr Exclusion ovlivňující, které pixely funkce ještě přidá do plochy koruny. Nicméně nejvěrohodnějšího výsledku bylo opět dosaženo se základním nastavením. Možným výsledným formátem je znovu pouze rastr.



Obrázek 9: Výsledná delinace korun stromů s jejich vrcholy (Watershed algoritmus)

5.7 Tvorba referenčních dat

Pro statistické vyhodnocení a určení přesnosti jednotlivých algoritmů byla potřeba validační dat, která byla po vytvoření následně porovnána s výslednými segmentacemi korun stromů. Jak bylo uvedeno v metodice výše tato referenční data byla vlastnoručně vytvořena v ArcGIS Pro vizuální interpretací ortofomozaiky zájmové oblasti. Stejně jako v případě studie Komárek et al. (2022). Konkrétní rozměry korun stromů byly manuálně vektorizovány nad ortofotomozaikou do nové polygonové vrstvy. Jako hlavní metrika následného statistického vyhodnocení byla zvolena rozloha korun.

5.8 Statistické vyhodnocení dat

Před samotným finální vyhodnocení přesnosti provedených segmentací korun musela být všechna data sjednocena na stejný souřadnicový systém a datový formát, k čemuž byl opět použit program u ArcGIS Pro (verze 3.1.0, Esri). Některé výsledky provedených analýz totiž byly v rastru a některá ve vektorové vrstvě. Jako jednotný formát byl zvolen Esri shapefile (vektorový formát). Souřadnicové systémy segmentací korun byla následně slazeny se souřadnicovým systémem validačních dat. Na závěr byly do nového atributového sloupce každé vrstvy spočteny plochy korun stromů pomocí funkce Calculate geometry (m^2).

Všechny výsledky byly poté sjednoceny do jedné tabulky a vyexportovány v podobě csv souboru. Pro statistické vyhodnocení byl opět použit program R studio. S pomocí balíčku MLmetrics (Yan, 2016) byly pro každý segmentační algoritmus korun stromů vypočteny následující statistické hodnoty: maximální hodnota, minimální hodnota, průměr, medián, průměrná absolutní chyba (mean absolute error, MAE), její procentuální verze (MAPE), střední kvadratická chyba (root-mean-square error, RMSE) a její procentuální verze (RMSPE).

6 Výsledky

6.1 Výsledky lokálních maxim

Odhadnutí lokálních maxim neboli vyhodnocených vrcholů stromů bylo provedeno dvěma verzemi filtru lokálních maxim s variabilním oknem. Jde o stejnou metodou jen každá je jiným způsobem upravena autory jednotlivých R balíčků. Nejúspěšnější byl filtr z balíčku Forest tools. Dosáhl úspěšnosti 80,6 %, kdy označil správně 142 stromů ze 176. Stejná funkce z balíčku LidR označila 129 vrcholů a úspěšnost měla 70,3 %. LidR balíček ve srovnání s Forest tools více opomíjel vrcholy. Forest tools nám zase v několika případech určil více vrcholů na stejné koruně stromu (Tabulka 3).

Tree tops	maxima	správné	špatné	opomenuté	úspěšnost
LidR	130	129	1	46	73,3 %
Forest tools	149	142	7	27	80,6 %

Tabulka 3: Výsledky filtrů lokálních maxim

6.2 Hodnoty delinee korun stromů


Hlavními výsledky této práce jsou vypočtené statistické metriky popisující úspěšnost provedené delinee korun stromů. Jak můžeme vidět v Tabulce 4, která shrnuje základní deskriptivní statistiky pro všechny zvolené algoritmy, tak hodnotám validačních dat nejlépe odpovídal algoritmus Watershed, a to jak v případě minimální a maximální velikosti detekované koruny, tak rovněž v hodnotách mediánu (střední hodnoty). Naopak tomu ale je v případě vypočtené průměrné velikosti koruny, kdy validačním datům odpovídají spíše algoritmy Voronoi tessellation a Region growing. Je však nutné podotknout, že rozdíl mezi všemi algoritmy je pouze 1 m². Celkově je z výsledků patrné, že všechny algoritmy v průměru nadhodnocovaly velikost detekovaných korun oproti jejich skutečné velikosti reprezentované validačními daty (Tabulka 4).

Metody delinee	min (m ²)	median (m ²)	max (m ²)	průměr (m ²)
Watershed	8,15	26,49	74,75	29,21
Voronoi tessellation	11,80	27,26	55,59	28,76
Region growing	12,01	27,53	57,60	28,77
skutečné	8,18	22,07	73,48	24,28

Tabulka 4: Výsledky hodnot delinee korun stromů

Lepší přehled o těchto deskriptivních statistikách nám dávají výsledky představené krabicovými grafy (anglicky „boxplots“) jednotlivých algoritmů v obrázku 10. Na obrázku prezentované krabicové grafy představují velikost vymezených korun pro každý algoritmus a validační data („skutečná data“).

Všechny tři algoritmy mají velmi podobný medián, který je nadhodnocený oproti validačním datům. Algoritmus watershed má největší rozptyl v hodnotách detekovaných korun, na druhou stranu je jeho střední hodnota nejbližší hodnotě validačních dat. Algoritmy Voronoi tessellation a Region growing jsou vizuálně téměř podobné. Dobře viditelné je obecné nadhodnocení všemi algoritmy, kdy všechny krabicové grafy algoritmů jsou na ose y výše než validační data (Obrázek 10).



Obrázek 10: Krabicové grafy rozlohy korun stromů. Medián je v grafech zobrazen tlustou čarou. Zabarvené obdélníky reprezentují rozložení dat mezi 1. a 3. kvartilem. Kolečka potom představují odlehlé hodnoty.

Na základě metrik MAE a MAPE lze za jednoznačně nejpřesnější algoritmus určit Watershed algoritmus spočtený pomocí balíčku Forest tools, který při porovnání s validačními daty dosáhl o 1,28 m² lepší přesnosti než Region growing a 1,63 m² než Voronoi tessellation. Hodnota MAPE Watershed algoritmu tak byla spočtena na 19,6 %, naopak v případě Region growing a Voronoi tessellation na cca 25 % (Tabulka 5).

Metody delineace	MAE (m ²)	MAPE
Watershed	5.70	19,6 %
Voronoi tessellation	7.33	25,7 %
Region growing	6.98	24,4 %

Tabulka 5: Hodnoty střední absolutní chyby (MAE) a její hodnoty v % (MAPE)

Podobných výsledků jako statistické metriky MAE a MAPE (jen s nepatrně větší chybou) dosáhly metriky RMSE a RMSPE. Watershed algoritmus byl v případě RMSPE o

cca 6 % přesnější, než Region growing a Voronoi tessellation. Region growing dosahuje nepatrně lepší přesnosti než Voronoi tessellation, ale rozdíl mezi těmito dvěma metodami byl velmi zanedbatelný. Právě výsledky RMSPE jsou v rámci bakalářské práce, díky jejímu častému využití napříč odbornou literaturou, brány jako nejdůležitější ukazatel přesnosti jednotlivých algoritmů, na jehož základě je patrné, že nejlepšího výsledku dosáhl právě algoritmus Watershed (Tabulka 6).

Metody delineaace	RMSE (m ²)	RMSPE
Watershed	7.33	23,7 %
Voronoi tessellation	9.23	30,9 %
Region growing	8.84	29,3 %

Tabulka 6: Hodnoty kvadratické odchylky (RMSE) a její hodnoty v % (RMSPE)

7 Diskuse

Dálkový průzkum Země je v dnešní době čím dál důležitější součástí lesnictví a zemědělství. Sběr dat pomocí UAV nám poskytuje rychle a poměrně levně data pro inventarizaci lesních porostů a nabízí nám tak nepřímým měření vlastností stromů (Panagiotidis et al, 2017). Správné použití UAV dat v zemědělství s jejich správným zpracováním, nám pomůže získat rychleji informace například o problémech adaptace dřevin na klimatickou změnu nebo vyhodnocení zásahu do pěstebnímu systému (Díaz-Varela et al, 2015).

Pro detekci a segmentaci korun stromů jsou velmi zásadní vstupní data. Ty často určují, jak úspěšná výsledná segmentace může být (Komárek et al, 2022). Proto se často práce v tématu detekce a delineaace stromů soustředí na posouzení vlivu odlišných dat jako tomu je v práci od Ganz et al. (2019), která porovnává přesnost lidarových dat a fotogrammetricky odvozených výškových dat. Cílem mé práce bylo použít spektrální RGB snímky, které byly studií Komárek et al. (2022) určeny jako nepřesnější zdroj dat pro zvolenou zájmovou oblast. Výsledky práce byly rozděleny na dvě části. V první části jsou výsledky detekce vrcholů stromů pomocí lokálních maxim (LM). Přesnosti LM detekcí vrcholů stromů dosáhly až 80 % úspěšnosti. V druhé části byly následně posouzeny vybrané algoritmy pro delineaace korun stromů. V tomto případě byl nejúspěšnější algoritmus Watershed z R balíčku Forest tool, který dosáhl hodnoty RMPSE 23,7 %. Až za ním se téměř shodně umístily algoritmy Region growing (Dalponte et al., 2015) s hodnotou 29,3 % a Voronoi tessellation (Silva et al. 2016) s hodnotou 30,9 % vypočtené pomocí R balíčku lidR.

Porovnání výsledků s ostatními pracemi na toto téma je problematické, ale i tak se o něj pokusíme. Zatím totiž není nijak zavedena jednotná metodika, jak porovnávat zvolené algoritmy. V naší práci byl zvolen prostý výpočet obsahu plochy korun. Některé lesnické studie naopak používají pro definování rozměrů korun stromů jejich poloměr nebo průměr měřený po různých osách definovaných například orientací ke světové straně. Tento postup využili ve své studii například Komárek et al. (2022) nebo Díaz-Varela et al. (2014). Další studie jako například Dalponte a Coomes (2016) definují dokonce vlastní způsoby hodnocení přesnosti (Dalponte a Coomes, 2016). Nejvíce podobnou prací je asi studie od Panagiotidis et al. (2017), která posuzovala hodnoty výšky a metriky korun ze spektrálních RGB dat. Výsledky delineaace zde porovnávaly s terénním měřením. Hodnoty RMSPE v této práci vyšly 14,29 %, respektive 18,56 % v závislosti na studijní lokalitě. Což je přesnější výsledek, než kterého dosáhl Watershed algoritmus v této práci. Nicméně je zde nutné uvést, že v práci od Panagiotidis et al. (2017) nepočítali obsah korun stromů, ale hodnotili právě průměry detekovaných korun. Pokud jde o chování hodnoceného algoritmu, tak stejně jako v případě této práce nadhodnocoval rozměry korun stromů.

Problematika vyhledání vršků stromů zejména pomocí lokálních maxim je, co se počtu publikovaných studií týče, mnohem čtenější, a lze ji díky velmi podobné metodice hodnocení přesnosti dobře kvantifikovat a napříč studiemi vzájemně porovnávat. Zde můžeme porovnat výsledky například s prací Surového et al. (2018). Ti za použití filtru lokálních maxim na území plantáže dosáhli přesnosti detekce stromů napříč různými

lokalitami mezi 50 až 90 %. Rovněž v práci, ze které vycházím od Komárka et al. (2022) byly detekovány vrcholky stromů s přesností 80 až 90 %. Výsledky této práce se přiblížily k hodnotě 80 %, což lze v kontextu publikovaných studií považovat za dobrý výsledek.

Prekážkou praktické aplikace algoritmů pro vymezení korun byla ještě v nedávné minulosti zejména jejich nízká dostupnost pro širokou veřejnost. Doposud byla většina algoritmu pouze za zavřenými dveřmi výzkumných pracovišť. V posledních letech se situace začala měnit s tvorbou balíčků do programu R studio. Příkladem je práce Roussel et al. (2020), kteří si uvědomují důležitost tvorby open-source softwaru pro veřejnost. Balíček lidR v tomto případě nabízí několik funkcí a algoritmů pro tvorbu modelů vegetace a jejich vyhodnocení (Roussel et al. 2020). Samotné GIS softwary nenabízí přímou možnost provedení metod segmentace korun stromů z digitálních výškových modelů vegetace. Například program ArcGIS Pro funkci pro delineaace korun stromů přímo nemá, ale uživatel s dostatečnou znalostí tohoto softwaru můžeme vytvořit pomocí jeho základních funkcí svůj vlastní delineační nástroj (například obrácený Watershed algoritmus), jak je uvedeno v práci Panagiotidis et al. (2017). Jednou z proměnných, která může ovlivňovat přesnost provedené delineační analýzy je kvalita vstupního digitálního modelu vegetace, kterou významně ovlivňuje samotný proces zpracování surových dat metodou SfM. Jak uvádí Tinkham a Swayze (2021), už nastavení hustoty fotogrammetrického mračna má velký vliv na kvalitu výsledného modelu vegetace. Nutné je při výpočtu myslet i na možné omezení v podobě výpočetních možností používaného hardwaru, který máme k dispozici pro zpracování UAV dat. Například s nastavením kvality použité v této práci měl dostupný počítač se středně dobrými parametry (popis stroje v Příloze 5) při výpočtu hustého bodového mračna značný problém. Rovněž musíme mít na paměti, že snaha o kvalitnější model v Agisoft Metashape může mít za následek pouze hustší bodové mračno, ne kvalitnější model, což můžeme mít paradoxně negativní vliv na výslednou delineaaci, a to zejména nadhodnocením rozlohy detekovaných korun. Další proměnou, která může ovlivnit dosažený výsledek je samotné implementování metod delineaace. Jak jsem již uvedl, tyto metody jsou často velmi uzavřené pro běžné uživatele. Problém nastává i v nastavení jednotlivých parametrů těchto funkcí. Algoritmy Region growing i Voronoi tessellation sice v dokumentaci uvádí, jak je možné upravit jejich parametry delineaace, ale ve skutečnosti jejich nastavení nemá prakticky žádný vliv na dosažené výsledky. Naopak metoda Watershed implementovaná v R balíčku Forest tools nedovoluje uživateli nastavit víceméně žádné konkrétní parametry a optimalizovat tak výpočet pro potřeby Vaší zájmové lokality.

V této bakalářské práci byly referenční data vytvořena ručně autorem pomocí vizuální interpretace nad UAV ortofotomozaikou (Příloha 1). Vytvořená ortofotomozaika metodou SfM může mít v některých místech lehce horší kvalitu (být nepatrně rozmazaná), stromy v zapojeném lesním porostu se mohou částečně zakrývat nebo mohou jejich koruny srůstat dohromady. Navíc menší stromy nebo stromy vyloženě schované pod většími korunami jsou v takovém případě při tvorbě referenčních dat ignorovány. V takových momentech je proto často obtížné přesně identifikovat konkrétní koruny jednotlivých stromů, a tím vyloučit možné nepřesnosti ve vektorizovaných validačních korunách. Na druhou stranu zcela 100 % není ani hodnocení založené na terénním měření. Proto nelze objektivně říci, jaký

z uvedených způsobů tvorby validačních dat je v praxi přesnější a více se blíží reálné velikosti korun stromů.

8 Závěr a přínosy práce

Cílem bakalářské práce bylo porovnat vybrané segmentační algoritmy obrazu pro vymezení korun stromů z dat pořízených bezpilotními leteckými prostředky (UAV). Tato práce navazuje výběru algoritmů a testování jejich přesnosti na studii Komárek et al. (2022), která byla naopak zaměřena na výběr nejvhodnějších vstupních UAV dat. Dílčími cíli bakalářské práce bylo dále vybrat pro veřejnost dostupné algoritmy, vytvoření digitálního modelu vegetace z dat UAV metodou Structure from Motion (SfM), tvorba vlastních referenčních dat o velikosti korun a následné statistické vyhodnocení přesnosti zvolených algoritmů. Konkrétně byly pro vymezení korun stromů použity 3 algoritmy z 2 balíčků určených do programu R studio. Balíček Forest tools nabídl algoritmus Watershed, zatímco balíček LidR poskytl algoritmy Region growing (Dalponte) a Voronoi tessellation (Silva). Všechny 3 algoritmy používají jako vstup pro vymezení korun vršky stromů vypočtené pomocí algoritmu lokálního maxima (LM) s variabilním oknem.

V případě detekce vršků stromů pomocí lokálních maxim byl nejúspěšnější algoritmus z R balíčku Forest tools s úspěšností 80,6 % oproti 73,3 % dosaženým pomocí algoritmu implementovaném v R balíčku LidR. Úspěšnost delineačních algoritmů pro vymezení korun stromů byla hodnocena pomocí různých statistických metrik, tou nejdůležitější z pohledu autora práce byla metrika RMSPE. Nepřesnějších výsledků dosáhl algoritmus Watershed s hodnotou 19,6 % RMSPE (výzkumná otázka A). Algoritmy Region growing a Voronoi tessellation dosáhly velmi podobných výsledků, a to Region growing 29,3 % a Voronoi tessellation 30,9 % RMSPE. Všechny hodnocené algoritmy navíc nadhodnocovaly velikost vymezených korun oproti validačním datům (výzkumná otázka B). Závěry této práce lze nicméně brát pouze jako výsledky jedné z mnoho případových studií, takže je nelze považovat za univerzálně platné napříč různými zájmovými lokalitami či vstupními daty.

Precizní vymezení korun stromů je v době zpracování této práce stále složitým, zdlouhavým a nevyřešeným problémem. V případě současných algoritmů totiž menší změna parametrů ve filtraci lokálních maxim, změna v parametrech vymezení korun stromů nebo jen jiné vyhlazení výškového modelu vegetace může přinést velmi odlišné výsledky. Z výsledků a závěru práce vyplývá že spektrální UAV data s vysokým prostorovým rozlišením jsou slibným zdrojem informací o lesním porostu, nicméně je stále třeba vyvinout nové přesnější a rychlejší výpočetní algoritmy jejich zpracování, které by ještě zvýšily jejich možnou využitelnost pro praktickou aplikaci v lesním managementu (výzkumná otázka C).

9 Seznam použitých zdrojů

- 1) ADAMS, R., & BISCHOF, L. (1994). Seeded region growing. *IEEE Transactions on pattern analysis and machine intelligence*, 16(6), 641-647.
- 2) AGGARWAL, S. (2004). Principles of remote sensing. *Satellite remote sensing and GIS applications in agricultural meteorology*, 23(2), 23-28.
- 3) AKAY, A. E., OĞUZ, H., KARAS, I. R., & ARUGA, K. (2009). Using LiDAR technology in forestry activities. *Environmental monitoring and assessment*, 151, 117-125.
- 4) ANONYMUS (2017), Plán péče o CHKO Křivoklátsko na období 2017–2026, AOPK ČR
- 5) AURENHAMMER, F., & KLEIN, R. 1999. Voronoi diagrams. In *Handbook on Computational*
- 6) CARLEER, A. P., DEBEIR, O., & WOLFF, E. (2005). Assessment of very high spatial resolution satellite image segmentations. *Photogrammetric Engineering & Remote Sensing*, 71(11), 1285-1294.
- 7) DAINELLI, R., TOSCANO, P., DI GENNARO, S. F., & MATESE, A. (2021). Recent advances in Unmanned Aerial Vehicles forest remote sensing—A systematic review. Part II: Research applications. *Forests*, 12(4), 397.
- 8) DALPONTE, M., REYES, F., KANDARE, K., & GIANELLE, D. (2015). Delineation of individual tree crowns from ALS and hyperspectral data: a comparison among four methods. *European Journal of Remote Sensing*, 48(1), 365-382.
- 9) DALPONTE, MICHELE; COOMES, DAVID A. (2016). Tree-centric mapping of forest carbon density from airborne laser scanning and hyperspectral data. *Methods in ecology and evolution*, 7.10: 1236-1245.
- 10) DÍAZ-VARELA, R. A. ROSA R DE LA, LEÓN L, ZARCO-TEJADA PJ (2015) High-Resolution Airborne UAV Imagery to assess olive tree crown parameters using 3D photo reconstruction: Application in breeding trials. *Remote Sensing*, 7(4), 4213-4232.
- 11) DOBROVOLNÝ P., (1998): Dálkový průzkum Země. Digitální zpracování obrazu. Masarykova univerzita. Brno. 210 s. ISBN 80-210-1812-7.
- 12) DUBAYAH, RALPH O.; DRAKE, JASON B. (2000). Lidar remote sensing for forestry. *Journal of forestry*, 98.6: 44-46.
- 13) EDSON, C., & WING, M. G. (2011). Airborne light detection and ranging (LiDAR) for individual tree stem location, height, and biomass measurements. *Remote Sensing*, 3(11), 2494-2528.
- 14) FAHLSTROM, P. G., GLEASON, T. J., & SADRAEY, M. H. (2022). Introduction to UAV systems. John Wiley & Sons.

- 15) GANZ, S., KÄBER, Y., & ADLER, P. (2019). Measuring tree height with remote sensing—A comparison of photogrammetric and LiDAR data with different field measurements. *Forests*, 10(8), 694.
- 16) HORÁK, J. (2014): Skripta Dálkový Průzkum Země, Ostrava, 132 s.
- 17) HYYPPA, J., KELLE, O., LEHIKONEN, M., & INKINEN, M. (2001). A segmentation-based method to retrieve stem volume estimates from 3-D tree height models produced by laser scanners. *IEEE Transactions on geoscience and remote sensing*, 39(5), 969-975.
- 18) IGLHAUT, J., CABO, C., PULITI, S., PIERMATTEI, L., O'CONNOR, J., & ROSETTE, J. (2019). Structure from motion photogrammetry in forestry: A review. *Current Forestry Reports*, 5, 155-168.
- 19) IRONS, J. R., & DWYER, J. L. (2010). An overview of the Landsat data continuity mission. *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XVI*, 7695, 58-64.
- 20) J.R. SACK, AND G. URRUTIA (1999). *Geometry*. Edited. Elsevier, Amsterdam. pp. 201–290.
- 21) JANG, G., KIM, J., YU, J. K., KIM, H. J., KIM, Y., KIM, D. W., ... & CHUNG, Y. S. (2020). Cost-effective unmanned aerial vehicle (UAV) platform for field plant breeding application. *Remote Sensing*, 12(6), 998.
- 22) JANSSEN, L. L., BAKKER, W. H., WEIR, M. J. C., GORTE, B. G. H., POHL, C., WOLDAI, T., ... & REEVES, C. V. (2000). *Principles of remote sensing: an introductory textbook*. ITC Educational Textbook Series, 2.
- 23) KAPLAN, C. (2017). *Aerial aftermaths: Wartime from above*. Duke University Press.
- 24) KHOSRAVIPOUR, A., SKIDMORE, A. K., ISENBURG, M., WANG, T., & HUSSIN, Y. A. (2014). Generating pit-free canopy height models from airborne lidar. *Photogrammetric Engineering & Remote Sensing*, 80(9), 863-872.
- 25) KOLÁŘ J., HALOUNOVÁ L., PAVELKA K., (1997): Dálkový průzkum Země 10. 1. vydání. Vydavatelství ČVUT. Praha. 164 s. ISBN 80-01-01567-X.
- 26) KOMÁREK, J. & KLÁPŠTĚ, P. & HRACH, K. & KLOUČEK, T. (2021). The Potential of Widespread Ready-Made UAVs in Quantifying Conifers and Delineating Their Crowns. DOI: 10.21203/rs.3.rs-723971/v1
- 27) KROPÁČEK J, MORAVEC D, KOMÁREK J (2020) Dálkový průzkum – I, Praha
- 28) LAUER, D. T., MORAIN, S. A., & SALOMONSON, V. V. (1997). The Landsat program: Its origins, evolution, and impacts. *Photogrammetric Engineering and Remote Sensing*, 63(7), 831-838.
- 29) LILLESAND, T., KIEFER, R. W., & CHIPMAN, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.
- 30) LOŽEK, V., KUBÍKOVÁ J. ŠPRYŇAR P. (2005) *Střední Čechy*. Praha: Agentura ochrany přírody a krajiny ČR, Chráněná území ČR. ISBN isbn80-86064-87-5.

- 31) MINAŘÍK, R., LANGHAMMER, J., & LENDZIOCH, T. (2020). Automatic tree crown extraction from UAS multispectral imagery for the detection of bark beetle disturbance in mixed forests. *Remote Sensing*, 12(24), 4081.
- 32) NAVARRO, J. A., ALGEET, N., FERNÁNDEZ-LANDA, A., ESTEBAN, J., RODRÍGUEZ-NORIEGA, P., & GUILLÉN-CLIMENT, M. L. (2019). Integration of UAV, Sentinel-1, and Sentinel-2 data for mangrove plantation aboveground biomass monitoring in Senegal. *Remote Sensing*, 11(1), 77.
- 33) PANAGIOTIDIS, D., ABDOLLAHNEJAD, A., SUROVÝ, P., & CHITECULO, V. (2017). Determining tree height and crown diameter from high-resolution UAV imagery. *International journal of remote sensing*, 38(8-10), 2392-2410.
- 34) PEPPA, M. V., HALL, J., GOODYEAR, J., & MILLS, J. P. (2019). Photogrammetric assessment and comparison of DJI Phantom 4 pro and phantom 4 RTK small unmanned aircraft systems. *ISPRS Geospatial Week 2019*.
- 35) PLÁNKA L., (2007): Dálkový průzkum Země: Modul 01, Teoretické základy. Vysoké učení technické v Brně, Fakulta stavební.
- 36) POPESCU, S. C., & WYNNE, R. H. (2004). Seeing the trees in the forest: Using lidar and multispectral data fusion with local filtering and variable window size for estimating tree height. *Photogrammetric engineering and remote sensing*, 70(5), 589-604.
- 37) ROUSSEL, J.R., AUTY, D., COOPS, N. C., TOMPALSKI, P., GOODBODY, T. R. H., SÁNCHEZ MEADOR, A., BOURDON, J.F., DE BOISSIEU, F., ACHIM, A. (2020). lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, 251 (August), 112061. <doi: 10.1016/j.rse.2020.112061>.
- 38) SEGARRA, J., BUCHAILLOT, M. L., ARAUS, J. L., & KEFAUVER, S. C. (2020). Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy*, 10(5), 641.
- 39) SERBIN S. P., TOWNSEND P. A., (2020): *Scaling Functional Traits from Leaves to Canopies in Remote Sensing of Plant Biodiversity*. Springer Nature Switzerland AG. Cham. 594 s. ISBN 978-3-030-33156-6.
- 40) SCHOTT J. R., (2007): *Remote Sensing: The Image Chain Approach*. Oxford University Press. Oxford. New York. 701 s.
- 41) SILVA, C. A., HUDAK, A. T., VIERLING, L. A., LOUDERMILK, E. L., O'BRIEN, J. J., HIERS, J. K., ... & KHOSRAVIPOUR, A. (2016). Imputation of individual longleaf pine (*Pinus palustris* Mill.) tree attributes from field and LiDAR data. *Canadian journal of remote sensing*, 42(5), 554-573.
- 42) SILVA, M. R. S., EGER, R. A., ROSENFELDT, Y. A. Z., AND LOCH, C. (2018). (2018). Testing DJI Phantom 4 Pro for urban georeferencing. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences- ISPRS Archives*, 42(1), 407-411.
- 43) SKALICKÝ, V. (1988). Regionálně fytogeografické členění, s. 103-121. In: HEJNÝ, S.; SLAVÍK, B. (eds.) et al. *Květena České socialistické republiky 1*. Vydání 1. Praha: Academia. 557 s., 1 skl. mapa.

- 44) STÖCKER, C., BENNETT, R., NEX, F., GERKE, M., & ZEVENBERGEN, J. (2017). Review of the current state of UAV regulations. *Remote sensing*, 9(5), 459.
- 45) SUROVÝ, P., ALMEIDA RIBEIRO, N., & PANAGIOTIDIS, D. (2018). Estimation of positions and heights from UAV-sensed imagery in tree plantations in agrosilvopastoral systems. *International Journal of Remote Sensing*, 39(14), 4786–4800.
- 46) SVATOŇOVÁ H., LAUERMANN L., (2010): Dálkový průzkum Země – aktuální zdroj geografických informací (1. vydání). Masarykova univerzita. Brno. 96 s. ISBN 978-80-210-5162-1.
- 47) TINKHAM, W. T., & SWAYZE, N. C. (2021). Influence of Agisoft Metashape parameters on UAS structure from motion individual tree detection from canopy height models. *Forests*, 12(2), 250.
- 48) WESTOBY, M. J., BRASINGTON, J., GLASSER, N. F., HAMBREY, M. J., & REYNOLDS, J. M. (2012). ‘Structure-from-Motion’ photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, 179, 300-314.
- 49) WULDER, M., NIEMANN, K. O., & GOODENOUGH, D. G. (2000). Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. *Remote Sensing of environment*, 73(1), 103-114.

Internetové zdroje:

- 1) AOPK ČR, ©2023: Správa CHKO Křivoklátsko [online]. Copyright © 2022 [cit. 18.03.2023]. Dostupné z: <https://krivoklatsko.ochranaprirody.cz/>
- 2) BOTANY.CZ: Botanická databáze [online]. [cit. 15.03.2023]. Dostupné z: <https://botany.cz/cs/>
- 3) ČESKÉNOVINY.CZ Článek o přípravách NP Křivoklátsko, [online]. Copyright © 2023 [cit. 17.03.2023]. Dostupné z: <https://www.ceskenoviny.cz/zpravy/2331757>
- 4) DJI.COM, Oficiální webové stránky firmy DJI [online]. [cit. 10.03.2023]. Dostupné z: <https://www.dji.com/>
- 5) DRON.CZ, E-shop a půjčovna dronů [online]. [cit. 20.03.2023]. Dostupné z: <https://dronpro.cz/e-shop>
- 6) FENOFÁZE: Fenologické fáze. Ústav výzkumu globální změny AV ČR, v.v.i. a Český hydrometeorologický ústav: Fenologické fáze. [online]. [cit. 18.03.2023]. Dostupné z: <https://www.fenofaze.cz/cz/>

- 7) JEAN-ROMAIN ROUSSEL AND DAVID Auty (2021). Airborne LiDAR Data Manipulation and Visualization for Forestry Applications. R package version [cit. 30.03.2023]. 3.2.3. <https://cran.r-project.org/package=lidR>
- 8) NASA, 2014: Observing in Infrared. [online]. [cit. 20.03.2023]. Dostupné z: <https://earthobservatory.nasa.gov/features/FalseColor/page5.php>
- 9) PLOWRIGHT A, ROUSSEL J (2021). _ForestTools: Analyzing Remotely Sensed Forest Data_. R package version 0.2.5, [cit. 30.03.2023]., <<https://CRAN.R-project.org/package=ForestTools>>.
- 10) ZOO PRAHA.CZ: [online]. Pražská zoologická zahrada, [cit. 21.03.2023]. Dostupné z: <https://www.zoopraha.cz/>
- 11) Yan Y (2016). _MLmetrics: Machine Learning Evaluation Metrics_. R package version 1.1.1, [cit. 30.03.2023]., <<https://CRAN.R-project.org/package=MLmetrics>>.

10 Seznam obrázků, tabulek a zkratk

Seznam obrázků

Obrázek 1: Schéma elektromagnetické vlny Zdroj: Dobrovolný (1998)	12
Obrázek 2: Schéma elektromagnetického spektra Zdroj: Kolář et al. (1997)	13
Obrázek 3: Vzorec pro výpočet energie fotonu Zdroj: Kolář et al. (1997)	13
Obrázek 4: Poloha zájmového území; Zdroj: vlastní zpracování, ArcGIS Online (ESRI)...	21
Obrázek 5: Poloha zájmového území, Mapy.cz (Seznam.cz).....	22
Obrázek 6: Vybraná testovací data	24
Obrázek 7: Dron Phantom 4 Pro A.Savin, Zdroj: WikiCommons	25
Obrázek 8: Výsledek filtrace lokálních maxim (ilustrativní)	27
Obrázek 9: Výsledná delineeace korun stromů s jejich vrcholy (Watershed algoritmus).....	28
Obrázek 10: Krabicové grafy rozlohy korun stromů. Medián je v grafech zobrazen tlustou čarou. Zabarvené obdélníky reprezentují rozložení dat mezi 1. a 3. kvartilem. Kolečka potom představují odlehle hodnoty	31

Seznam tabulek

Tabulka 1: Spektrum viditelného spektra (VIS)	14
Tabulka 2: Technické specifikace dronu Phantom 4 Pro, Zdroj: dji.com (2023) a Komárek et al (2022)	25
Tabulka 3: Výsledky filtrů lokálních maxim	30
Tabulka 4: Výsledek hodnot delineeace korun stromů.....	30
Tabulka 5: Hodnoty střední absolutní chyby (MAE) a její hodnoty v % (MAPE).....	31
Tabulka 6: Hodnoty kvadratické odchylky (RMSE) a její hodnoty v % (RMSPE)	32


Seznam příloh

Příloha 1: Ortofomozaika pro celé nasnímané území.....	43
Příloha 2: Kód pro delineeace korun stromů v programu R studio.....	44
Příloha 3: Krabicové grafy jednotlivých algoritmů a validačních dat.....	45
Příloha 4: Přehled statistik delineeace korun stromů.	45
Příloha 5: Specifikace hardwaru.....	46

Seznam použitých zkratk

Soupis a definování zkratk (vyskytuje-li se jich v textu velké množství)
CHKO – chráněná krajinná oblast
AGL – Above Ground Level
CHM – Canopy Height Model
DTM – Digital Terrain Model
DSM – Digital Surface Model

11 Přílohy




Příloha 1: Ortofomozaika pro celé nasnímané území

```

#=====
#Forest tools
#=====
library(ForestTools)
library(raster)
chm <- raster("C:\\Users\\Houde\\Desktop\\segmentace_14_12\\CHM_test3.tif")
crs(chm) <- CRS('+init=EPSG:5514')
#-----
# Detecting treetops (ITD)
#-----
lin <- function(x){x * 0.05 + 0.6}
ttops_forest <- vwf(CHM = chm, winFun = lin, minHeight = 8)
shapefile(ttops_forest, filename='C:\\Users\\Houde\\Desktop\\segmentace_14_12\\ttops.shp')
#-----
# Create crown map (ITS)
#-----
crowns_forest <- mcws(treetops = ttops_forest, CHM = chm, minHeight = 5, verbose =
FALSE)
shapefile(ttops_forest,
filename='C:\\Users\\Houde\\Desktop\\segmentace_14_12\\Forest_ttops.shp')
#=====
#lidR
#=====
library(raster)
library(lidR)
chm <- raster("C:\\Users\\Houde\\Desktop\\segmentace_14_12\\CHM_test3.tif")
crs(chm) <- CRS('+init=EPSG:5514')
#-----
# Detecting treetops (ITD)
#-----
f <- function(x) { x * 0.07 + 3 }
ttops <- find_trees(chm, lmf(f))
ttops_3_circ = find_trees(chm, lmf(3, shape = c("circular")))
#-----
# Create crown map (ITS)
#-----
silva2016(chm, treetops, max_cr_factor = 0.6, exclusion = 0.3, ID = "treeID")
crowns_silva <- silva2016(chm, treetops, max_cr_factor = 0.6, exclusion = 0.3, ID =
"treeID")()
dalponte2016(chm, ttops, th_tree = 2, th_seed = 0.45, th_cr = 0.55, max_cr = 100, ID =
"treeID")
crowns_dalponte = dalponte2016(chm, ttops, th_tree = 2, th_seed = 0.45, th_cr = 0.55, max_cr
= 60, ID = "treeID")()
#-----
# Export raster
#-----
writeRaster(crowns_silva, "C:\\Users\\Houde\\Desktop\\segmentace_5_2\\Silva_crowns.tif",
dataType = "INT2U")
writeRaster(crowns_dalponte,
"C:\\Users\\Houde\\Desktop\\segmentace_5_2\\Dalponte_crowns.tif", dataType = "INT2U")

```

Příloha 2: Kód pro delinace korun stromů v programu R studio



Příloha 3: Krabicové grafy jednotlivých algoritmů a validačních dat

Metody delineaace	Watershed	Voronoi tessellation	Region growing	Validační data
minimální hodnota (m ²)	8,15	11,8	12,01	8,18
median (m ²)	26,49	27,26	27,53	22,07
maximální hodnota (m ²)	74,75	55,59	57,6	73,48
průměr (m ²)	29,21	28,76	28,77	24,28
MAE (m ²)	5,70	7,33	6,98	
MAPE	19,6 %	25,7 %	24,4 %	
RMSE (m ²)	7,33	9,23	8,84	
RMSPE	23,7 %	30,9 %	29,3 %	

Příloha 4: Přehled statistik delineaace korun stromů.

Specifikace hardwaru	
Operační systém (OS)	Microsoft Windows 11 Home
Typ systému	x64 - based PC
Procesor	AMD Ryzen 5 3600 6-Core Processor
Grafická karta	NVIDIA GeForce GTX 1660 Ti
Celková fyzická paměť (RAM)	15.91 GB

Příloha 5: Specifikace hardwaru