

Univerzita Karlova
Přírodovědecká fakulta
Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie
Studijní obor: Kartografie a geoinformatika



Bc. Lucie Jebavá

VYUŽITÍ OPTICKÝCH A LASEROVÝCH DAT K MODELOVÁNÍ LESNÍCH POROSTŮ

**UTILIZATION OF OPTICAL AND LASER DATA FOR MODELING OF
FOREST AREAS**

Diplomová práce

Vedoucí práce: Ing. Markéta Potůčková, Ph.D.

Praha 2017

Vysoká škola: Univerzita Karlova

Fakulta: Přírodovědecká

Katedra: Aplikované geoinformatiky a kartografie

Školní rok: 2017/2018

Zadání diplomové práce

pro Lucii Jebavou

obor Kartografie a geoinformatika

Název tématu: Využití optických a laserových dat k modelování lesních porostů

Zásady pro vypracování

Stereofotogrammetrie je klasickou metodou využívanou pro inventarizaci lesních porostů. V posledních letech je pro stejný účel využívána technologie LiDARového snímání, nicméně z ekonomických důvodů nejsou tato data pořizována ve stejném časovém rozlišení jako letecké snímky a navíc jejich hustota není většinou dostatečná pro určování parametrů na úrovni stromu. V diplomové práci budou ve zvolených modelových územích porovnány Digitální model povrchu ČR 1. generace (DMP 1G) odvozený z LiDARových dat, digitální model povrchu "KRNAP" odvozený z LiDARových dat vyššího prostorového rozlišení a digitální model povrchu odvozený ze stereoskopických snímků metodou *high density image matching*. Bude zhodnoceno jejich využití pro vymezení jednotlivých stromů (v kombinaci s ortofotem), vytvoření 3D modelu jednotlivých stromů a určení jejich výšky. Pro zpracování budou využity softwary SURE, eCognition a ArcGIS. Z důvodu využití výsledků práce pro další výzkumné aktivity na katedře aplikované geoinformatiky a kartografie PřF UK byly jako modelové plochy vybrány porosty smrku a borovice kleče v oblasti Krkonošského národního parku.

Rozsah grafických prací: podle potřeby

Rozsah průvodní zprávy: 50 - 60 stran

Seznam odborné literatury:

HAALA, N., ROTHERMEL, M. (2012): Dense Multi-Stereo Matching for High Quality Digital Elevation Models. PFG Photogrammetrie, Fernerkundungm Geoinformation, s. 331–343.

HÁJEK, F., ADOLT R., TOMANČÁK, O., STUDENÁ, K., KANTOROVÁ, M. (2015): Využití digitální stereofotogrammetrie jako podpůrných dat pro automatizovanou tvorbu lesnických tematických map. In: Symposium GIS Ostrava 2015: Současné výzvy Geoinformatiky. Ostrava: VŠB - Technická univerzita Ostrava. ISBN 978-80-248-3677-5. ISSN 1213-239X.

GINZLER, C., HOBI, M. L. (2015): Countrywide stereo-image matching for updating digital surface models in the framework of the Swiss national forest inventory. Remote Sensing, 7(4), s. 4343–4370.

PARIS, C., BRUZZONE, L. (2015): A Three-Dimensional Model-Based Approach to the Estimation of the Tree Top Height by Fusing Low-Density LiDAR Data and Very High Resolution Optical Images. IEEE Transactions on Geoscience and Remote Sensing, 53(1), s. 467–480.

POPESCU, S. C., WYNNE, R. (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), s. 589–604.

Vedoucí diplomové práce: Ing. Markéta Potůčková, Ph.D.

Datum zadání diplomové práce: 4. 1. 2017

Termín odevzdání diplomové práce: 27. 11. 2017

Platnost tohoto zadání je po dobu jednoho akademického roku.

.....
Vedoucí diplomové práce

.....
Vedoucí katedry

V Praze dne 4. 1. 2017

Prohlašuji, že jsem tuto závěrečnou práci zpracovala samostatně, pod vedením Ing. Markéty Potůčkové, Ph.D., a že jsem uvedla všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

V Praze dne 27. 11. 2017

.....

Lucie Jebavá

Ráda bych tímto poděkovala vedoucí diplomové práce Ing. Markétě Potůčkové, Ph.D. za věnovaný čas, cenné rady a připomínky během zpracování celé práce. Moc bych také chtěla poděkovat mé rodině a přátelům, kteří mě po celou dobu studia podporovali.

Abstrakt

Práce se zabývá možnostmi využití optických dat k modelování lesních porostů v porovnání s využitím dat leteckého laserového skenování. Nejprve jsou mezi sebou porovnány použité datové sady a vysvětleny příčiny rozdílů. Dále jsou vytvořeny výškové modely vegetace a poté je provedena objektová klasifikace za účelem oddělení zájmových porostů od okolí. V práci je navržen metodický postup vedoucí k identifikaci a vymezení jednotlivých stromů v porostu a následnému zjištění jejich výšky. Jsou zde také shrnuty další možnosti rozvíjející navržený postup. Výsledky práce ukazují, že optická data s rozlišením cca 25 cm jsou vhodná ke zjišťování charakteristik lesních porostů až na úroveň jednotlivých stromů. Výstupy práce mohou sloužit k inventarizaci porostů v hospodářských lesích.

Klíčová slova: letecké snímky, image matching, laserové skenování, bodové mračno, lesní inventarizace

Abstract

The thesis deals with the possible use of optical data for modeling forest area compared with utilization of airborne laser scanning data. At first these two datasets are compared and causes of differences are explained. Then canopy height models are made and object-oriented classification is applied for separation of vegetation stands. Methodical procedure is suggested for delineation and detection individual trees in forest. Then their height is detected. There are summarized and other possibilities for improvement in detection and delineation of trees. The results show that optical data with resolution about 25 cm are suitable for determining the characteristics of the forest stands up to individual tree level. The outputs of this research can be used for forest inventory.

Key words: aerial imagery, image matching, laser scanning, point cloud, forest inventory

Obsah

Přehled použitých zkratk	8
Seznam obrázků, tabulek a grafů	9
1 ÚVOD A CÍLE PRÁCE	10
2 METODY ZÍSKÁVÁNÍ TROJROZMĚRNÝCH DAT	11
2.1 Letecké laserové skenování	11
2.2 Stereofotogrammetrie a metoda <i>high density image matching</i>	14
2.3 Výzkum lesních porostů	19
2.4 Fúze optických a laserových dat	23
3 DATA A ZÁJMOVÁ ÚZEMÍ	25
3.1 Digitální model povrchu 1. generace (DMP 1G)	25
3.2 Digitální model reliéfu 5. generace (DMR 5G)	25
3.3 Letecké měřické snímky	26
3.4 Ortofoto	26
3.5 Data leteckého laserového skenování KRNAP	26
3.6 Zájmová území	26
4 METODIKA	28
4.1 Příprava dat	28
4.2 Tvorba bodového mračna z leteckých měřických snímků	28
4.3 Porovnání bodových mračen	29
4.4 Tvorba DMP klasickou metodou	30
4.5 Tvorba výškových modelů porostu	30
4.6 Identifikace jednotlivých stromů	31
4.7 Geometrický model stromů a určení výšky	39
5 VÝSLEDKY	41
5.1 Porovnání bodových mračen	41
5.2 Porovnání rozdílů vytvořených rastrů	43
5.3 Objektová klasifikace	44
5.4 Modely stromů a jejich výška	44
6 DISKUZE	47
6.1 Data	47
6.2 Metodické řešení	48
7 ZÁVĚR	53
LITERATURA	54
Seznam příloh	61

Přehled použitých zkratk

ČÚZK – Český úřad zeměměřický a katastrální

DMP – Digitální model povrchu

DMR – Digitální model reliéfu

DSM – Digital Surface Model

ETRS89 - Evropský terestrický referenční systém 89

HDIM – High Density Image Matching

KRNAP – Krkonošský národní park

LiDAR – Light Detection and Ranging

LLS – Letecké laserové skenování

nDSM – normalized Digital Surface Model – normalizovaný digitální model povrchu

S-JTSK – Systém jednotné trigonometrické sítě katastrální

SW – software

ÚHÚL – Ústav hospodářské úpravy lesa

UTM33 – Univerzální transverzální Mercatorův systém souřadnic, zóna 33

ZABAGED – Základní báze geografických dat

ZÚ – Zeměměřický úřad

Seznam obrázků, tabulek a grafů

Obrázky

- Obr. 1: Letecké laserové skenování
- Obr. 3: Výška stromu
- Obr. 4: Rozmístění zájmových území v rámci KRNAP
- Obr. 5: Princip porovnání výšek bodů v SW DTM Analyst
- Obr. 6: Určení vrcholku koruny (a), vymezení jednotlivých korun z optických dat (b)
- Obr. 8: Vizualizace nDMSM HDIM borovice kleče
- Obr. 9: Segmentace obrazu – ortofoto (a), reálné koruny smrků (b), segmenty se stíny (c)
- Obr. 10: Vizualizace nDSM vytvořeného z DMR 5G a DMP 1G
- Obr. 11: Vizualizace nDSM vytvořeného z dat KRNAP
- Obr. 12: Vizualizace nDSM vytvořeného pomocí DMR 5G a dat HDIM
- Obr. 13: Lokální maxima určující polohu stromu v modelu vegetace
- Obr. 14: Bodové mračno náležící jednomu stromu a nalezená maxima
- Obr. 15: Body DMP 1G – v pravidelné mřížce doplněné ÚHÚL
- Obr. 16: Bodové mračno HDIM(zeleně) doplněné body z DMP 1G (červeně)

Tabulky

- Tab. 1: Parametry segmentace a klasifikace u porostu borovice kleče na základě optických dat
- Tab. 2: Parametry segmentace a klasifikace porostu borovice kleče při použití nDSM z dat KRNAP
- Tab. 3: Parametry segmentace a klasifikace u porostu smrku ztepilého při použití nDSM KRNAP a nDSM HDIM
- Tab. 4: Rozdíly mezi DMP 1G a DMP KRNAP
- Tab. 5: Rozdíly mezi DMP 1G a DMP HDIM
- Tab. 6: Rozdíly mezi DMP KRNAP a DMP HDIM
- Tab. 7: Průměrné rozdíly výšek při porovnání v porostu borovice kleče a mimo něj
- Tab. 8: Průměrné rozdíly výšek při porovnání v porostu smrku ztepilého a mimo něj
- Tab. 9: Průměrné rozdíly výšek při porovnání v porostu smrku ztepilého a mimo něj
- Tab. 10: Rozdíly zjištěných výšek stromů z dat HDIM a dat KRNAP

Graf

- Graf 1: Rozložení hodnot rozdílů v intervalech

1 ÚVOD A CÍLE PRÁCE

Stereofotogrammetrie je klasickou metodou využívanou pro inventarizaci lesních porostů. V posledních letech je pro stejný účel využívána technologie leteckého laserového skenování, ale z ekonomických důvodů nejsou tato data pořizována ve stejném časovém intervalu jako letecké snímky. Navíc jejich hustota není většinou dostatečná pro určování parametrů lesních porostů na úrovni stromu. Metodou *high density image matching* je možné získat z leteckých měřických snímků husté bodové mračno. Optická data by tedy mohla být vhodným zdrojem pro zjišťování parametrů jednotlivých stromů nebo celých porostů.

Práce se zabývá možnostmi využití optických dat k modelování lesních porostů v porovnání s daty leteckého laserového skenování. Zájmová území byla vybrána na území Krkonošského národního parku. Data využitá v práci byla poskytnuta Českým zeměměřickým úřadem katastrálním a Správou Krkonošského národního parku.

Hlavním cílem této diplomové práce je posouzení využití optických dat zpracovaných metodou *high density image matching* k modelování lesních porostů. Jako komparativní zdroj dat jsou použita data leteckého laserového skenování. Dalším cílem je identifikovat jednotlivé stromy v porostu, vymezit jejich koruny a následně je aproximovat jako rotační těleso. Dále je cílem zjištění výšek jednotlivých stromů a posouzení využitelnosti dat k výpočtům dalších charakteristik porostů či jednotlivých stromů jako jsou výčetní tloušťka kmene, střední výška porostu apod.

Výstupy práce mohou sloužit pro inventarizaci lesních porostů nebo porovnávání růstových změn porostů. Při pokročilejších analýzách pak také ke zjišťování dalších charakteristik jako je například výčetní tloušťka kmene či střední výška porostu.

2 METODY ZÍSKÁVÁNÍ TROJROZMĚRNÝCH DAT

Metody pro získávání 3D dat zaznamenaly během posledních dvou dekad dramatický vývoj. Více než jedno století byla stereoskopie jediná efektivní metoda pro získání relativně podrobných a přesných trojrozměrných dat pro rozlehlé oblasti. Od počátku tisíciletí však v mnoha oblastech začalo této metodě konkurovat laserové skenování. Hlavní hnací silou nárůstu popularity LiDARu je jeho schopnost získávat přímo rozsáhlá mračna bodů s vysokou prostorovou přesností (cca 0,1 m ve výšce a 0,5 m v rovině XY) (Vosselman a Maas, 2010), která poskytují podrobné popisy prostorových objektů zájmu (Liang et al., 2015). Dalšími způsoby pořizování 3D dat – nivelací, tachymetrií apod. se tato práce vzhledem ke svému zaměření nebude zabývat.

2.1 Letecké laserové skenování

V literatuře můžeme pro letecké laserové skenování najít několik výrazů. Hojně užívaným je termín LiDAR (= *Light Detection and Ranging*) (Bachman, 1979). Je ale důležité upozornit na to, že tento výraz se nevztahuje výhradně k leteckému laserovému skenování, ale také k pozemnímu (Vosselman, Maas, 2010). Poněkud výstižněji se tedy může jevit akronym ALS (*Airborne Laser Scanning*) (Wehr, Lohr, 1999). V češtině se potom využívá termín letecké laserové skenování (LLS).

Během devadesátých let minulého století bylo započato s vývojem zařízení k přímému měření 3D souřadnic podrobných bodů. Všechny tyto metody se dnes nazývají 3D skenování (Pavelka, 2006).

2.1.1 Laserový skener

Laserový skener je složen z několika důležitých částí - zdroje laserového záření, optické soustavy, mechanického prvku, detektoru elektromagnetického záření a velmi přesných hodin (Vosselman, Maas, 2010). Letecká skenovací zařízení mají s pozemními laserovými skenery téměř totožnou konstrukci, jde o skener se skenujícím hranolem nebo zrcátkem. Zásadním rozdílem je však jeho pohyb při letecké aplikaci, a proto je nezbytnou součástí také GNSS (*Global Navigation Satellite System*) a IMU (*inertial measurement unit*), aby byla

zjištěna přesná poloha nosiče za letu. Tato informace o poloze nosiče během letu je přihrávána k datům z laserového skeneru (Pavelka, 2006).

Zdrojem laserového záření může být v dnešní době široká škála různých emitörů. U výkonnějších zařízení se používají pevnolátkové rubínové lasery. V případech, že není kladen takový důraz na výkonnost laseru, využívá se laserů diodových. Výběr typu laseru závisí na konkrétních požadavcích pro dané měření – požadovaný výkon, ale i požadovaná vlnová délka záření (Dolanský, 2004). Paprsek, který je vysílán k zemskému povrchu, nejčastěji využívá oblasti blízkého infračerveného záření o vlnových délkách 1100–1200 nm. V současnosti jsou na trhu také zdroje záření s možností přeladění paprsku na jinou vlnovou délku, podle toho jakou odrazivost má zaměřovaný cíl (Vosselman, Maas, 2010). Pokud dojde k tomu, že je zdroj záření přeladěn na jinou vlnovou délku, musí být přeladěn také detektor, aby byl schopen záření rozeznat.

Jako detektory se využívají světlo-citlivé diody, které jsou synchronizovány spolu se zdrojem záření na stejnou vlnovou délku. Detektory musí být velmi citlivé, protože při difúzním odrazu klesá energie světla s druhou mocninou vzdálenosti (Dolanský, 2004).

Optická soustava zajišťuje koncentraci do velmi úzkého svazku a zároveň souosost detektoru s emitorem. Je složena z polopropustného zrcadla, které transformuje záření do úzkého paprsku a z nepropustného zrcadla, které slouží k tomu, že paprsek je vyslán vždy pod stejným úhlem (Shan, Toth, 2008).

Poslední součástí LiDARu jsou velmi přesné hodiny, jejichž hlavním úkolem je měřit čas od vyslání svazku paprsků až do doby jejich detekce (Beraldin et al., 2010). Na principu výpočtu rychlosti šíření světla pak lze snadno určit vzdálenost objektu od skeneru. Ze znalosti směru vyslaného svazku paprsků a vzdálenosti objektu je potom možné určit polohu každého měřeného bodu (Dolanský, 2004).

2.1.2 Princip laserového skenování

Laserový skener vysokou rychlostí emituje krátké laserové impulsy o frekvenci 100–300 kHz (Vosselman, Maas, 2010), které jsou směřovány pod různými úhly k zemskému povrchu (Dolanský, 2004). Po odrazu jsou tyto impulsy zpětně zachycovány citlivým detektorem. Sledováním časových rozdílů mezi vysláním a přijetím impulzu lze přesně určit vzdálenost skener - bod (John, 2011). Snadno pak lze dopočítat vzdálenost jednotlivých bodů na základě vztahu (1).


$$d = \frac{v \cdot t}{2} \quad (1)$$

d – délka průvodiče

v – rychlost šíření laserového paprsku

t – tranzitní čas

Oproti klasickému leteckému průzkumu je tato metoda méně závislá na stavu atmosféry a umožňuje vytváření modelů reliéfu, z nichž jsou odfiltrovány objekty jako například vegetace (John, 2011). Jelikož je letecký laserový skener aktivním senzorem, nezávislým na slunečním záření, je možné měření provádět 24 hodin denně (Šíma, 2009).



Obr. 1: Letecké laserové skenování (zdroj: Höfle et al., 2010)

2.1.3 Zpracování naměřených dat

Výsledkem měření leteckého laserového skenování je mračno bodů, tj. množina podrobných bodů objektu. Prvním krokem zpracování naměřených dat je pak georeferencování na základě vztahu (2) (Pavelka, 2006).

$$\begin{bmatrix} X_p \\ Y_p \\ Z_p \end{bmatrix}^m = \begin{bmatrix} X \\ Y \\ Z \end{bmatrix}^m + R_b^m \left[R_s^b \rho \begin{pmatrix} \sin \alpha \\ 0 \\ \cos \alpha \end{pmatrix} + \begin{bmatrix} a_x \\ a_y \\ a_z \end{bmatrix}^b \right] \quad (2)$$

$[X, Y, Z]^{mT}$ – souřadnice inerciální měřické jednotky (IMU) v referenčním souřadnicovém systému

R_b^m – matice rotace IMU souřadnicového systému do referenčního souřadnicového systému

R_s^b – matice rotace mezi systémem IMU a skenerem

$[a_x, a_y, a_z]^{bT}$ – posun mezi IMU a skenerem

α – úhel skenování

ρ – měřená vzdálenost

Vlastní zpracování dat a následné analýzy mohou mít několik podob. První možnou metodou je převedení mračna bodů na rastr, analýzy se pak provádí přímo nad rastrem. Práce se

samotným 3D mračnem bodů představuje další možnost. Poslední možností je pak kombinace obou výše zmíněných přístupů. Můžeme tedy říci, že volba příslušné metody je závislá na typu analýzy a požadavcích na výstupy. Důležitým faktorem při rozhodování je také velikost zájmového území (Sedláčková, 2014).

Ruční editace mračna bodů, které bylo měřením získáno, je velmi časově náročná až téměř nemožná. Je tedy třeba využít automatizovaných postupů, které tyto úkony provedou dostatečně přesně (Dolanský, 2004). Pro zpracování měřených dat existují speciální programy (Pavelka, 2006) jako např. nadstavba ArcGIS (LASTools), Grass GIS, BCAL LiDAR Tools nebo MCC – LIDAR.

Zpracování bodového mračna se skládá z klasifikace a filtrace. Během procesu filtrace jsou odstraněna chybná měření, šum a body, které popisují jiné objekty, než je požadováno. Při tvorbě digitálního modelu reliéfu je to například odfiltrování vegetace a dalších objektů. Při automatické filtraci je možné využít několik typů algoritmů (Badea, Jacobsen, 2008). Využívají se filtry morfologické, filtry založené na porovnávání sklonu nebo filtry založené na lineární predikci s různou vahou pro každý měřený bod (Dolanský, 2004).

Při klasifikaci jsou naměřené body rozděleny na základě výškových poměrů v jejich okolí nebo na základě spektrálních vlastností. Tento proces je prováděn v několika cyklech, kdy je při každém cyklu klasifikována vždy pouze jedna třída. Následující cyklus už poté probíhá nad ještě nezařazenými body. Klasifikaci je možné z bodového mračna vyselektovat vrstvy se specifickými vlastnostmi. Po použití dalších funkcí lze z bodů obsažených ve vrstvě generovat další výstupy lidarového měření. Příkladem může být vrstevnicový plán z bodů terénu či mapa porostů z vrstvy vegetace (Dolanský, 2004).

Jednou z metod klasifikace bodového mračna je také segmentace. Její výsledky jsou závislé na hustotě bodového mračna. V případě nízké hustoty je průběh procesu jednodušší, ale nedostatek texturových informací způsobuje, že nalezení hranic segmentů je obtížné. S vysokou hustotou bodového mračna souvisí komplexnost, zároveň je možné, že se vytvoří příliš mnoho malých segmentů způsobujících rozdrobenost výsledné klasifikace (Hu et al., 2011).

2.2 Stereofotogrammetrie a metoda *high density image matching*

Stereofotogrammetrie je technika zpracování digitálního obrazu, která umožňuje získání prostorových měření a určení geometricky spolehlivých tvarů na zemském povrchu (Pavelka, 2003). Metodou *image matching* („párování“ obrazů) je možné označit korelační

proces, při kterém jsou v několika snímcích získaných fotogrammetricky automaticky nalezeny odpovídající si objekty (Schenk, 1999).

2.2.1 Vývoj metody

V oblasti fotogrammetrie se stereoskopická metoda uplatňuje již od počátku 20. století. Jedná se o poměrně rozšířenou metodu pro sběr dat využitelných pro modelování terénu nebo objektů na něm (Pavelka, 2003). Prvopočátky metody *image matching* spadají do 50. let 20. století. Dále byla rozvíjena během 70. let. Dnes jsou techniky *image matching* začleněny do komerčních fotogrammetrických softwarů jako standardní měřicí a výpočtový nástroj (Remondino et al., 2014).

První experimenty byly prováděny analogovými procedurami pro kartografické účely. Nedávné integrace algoritmů počítačového vidění a fotogrammetrických metod vedly k zajímavým výsledkům. Je zřejmé, že pokud porovnáme manuální a automatické metody, automatické jsou mnohem rychlejší a zároveň dosahují vyšších přesností. V poslední době byly vyvinuty procedury, které jsou stále více automatizované pro celý proces 3D modelování (Remondino et al., 2014). Rekonstrukce trojrozměrných reprezentací povrchu z velkého množství překrývajících se snímků tedy byla a stále je živým tématem výzkumu ve fotogrammetrii a počítačovém vidění (Haala, Cavegn, 2016).

2.2.2 Princip stereofotogrammetrie

Stereofotogrammetrie využívá dvou vhodně pořízených snímků (tzv. stereoskopické dvojice), díky kterým je možné zpětně rekonstruovat tvar a rozměr 3D objektů. Snímky jsou pořizovány z paluby letadla pomocí fotogrammetrické komory a k následnému zpracování jsou třeba, jak již bylo zmíněno výše, nejméně dva snímky. Tyto snímky jsou pořízeny ze dvou či více různých míst, ale zaujímají stejné území (Oršulák, Pacina, 2012). Důležitým faktorem pro výslednou kvalitu digitálního modelu povrchu je textura povrchu a také překryv snímků (Haala, Cavegn, 2016).

Stereofotogrammetrie principiálně vychází z fyzikálního jevu zvaného stereoskopický vjem, který je vlastní každému zdravému páru očí. V návaznosti na přirozený prostorový vjem může být popsán také umělý stereoskopický vjem. Jeho základem jsou dva různé obrazy stejného objektu, které byly pořízeny z rozdílné polohy fotogrammetrické základny. Jejich odděleným současným pozorováním vzniká umělý stereoskopický vjem. Pro pozorování dvou snímků se využívá speciálních pomůcek, mezi něž patří stereoskopy, optické soustavy přístrojů, anaglyfy nebo nejnázne dostupné speciální brýle. Umělý stereoskopický vjem je však zkreslen vlivem délky fotogrammetrické základny, tvarem paprskových svazků

(optické zvětšení pozorovaného systému – souřadnice z a orientací paprskových svazků – tzv. pseudojevem).

Technologický postup stereofotogrammetrického vyhodnocení měřických snímků má následující posloupnost. Nejprve je třeba připravit projekt, do této fáze patří například i příprava snímkového letu. Dále následuje práce v terénu, kdy jsou pořízeny snímky a zaměřeny vlíčovací body. Následujícím krokem jsou přípravné práce, mezi něž patří geodetické výpočty, digitalizace, úpravy obrazových dat apod. Samotné fotogrammetrické zpracování obsahuje výpočet snímkových orientací, podrobné vyhodnocení a v posledním kroku pak kontrolu, exporty výstupů apod. Výhodou takového postupu je v prvé řadě vysoká přesnost výstupů a univerzálnost použití – výstupy mohou být ve 2D i ve 3D. Negativem pak je poměrně vysoká časová náročnost a pracnost zpracování, potřeba speciálního softwaru. Dále také vysoké nároky na znalosti operátora.

Aby mohla být dvojice snímků stereofotogrammetricky vyhodnocena, musí také proběhnout příprava. Nejprve je to obnovení prvků vnitřní orientace komory, dále pak určení prvků vnější orientace – zde je možno volit z několika možností. Prvním z nich je komplexní řešení, kdy dochází v jednom kroku ke svazkovému vyrovnání. Druhým pak může být etapové řešení, kdy dochází k blokovému vyrovnání ve více krocích (prvním krokem je relativní orientace, druhým absolutní orientace). Poslední možností vnější orientace je přímé určení – to je provedeno za letu pomocí IMU a GNSS (Pavelka, 2003; Cukrov, 2013). Umělé stereoskopické vnímání, které bylo vytvořeno pozorováním stereosnímků, dovoluje operátorovi vidět vyfotografovanou krajinu plasticky a provádět na ní s pomocí virtuální měřicí značky různá měření (určení výšky objektů apod.). Vyhodnocení snímku však nemusí probíhat pouze manuálně identifikací bodů operátorem, ale je možné využít digitální fotogrammetrické stanice, které mají implementovanou korelační analýzu obrazu. Při této operaci se pomocí korelace identifikují stejné významné body na pravém i levém snímku a dochází k automatické tvorbě digitálního modelu terénu.

Zatímco v analogové a analytické fotogrammetrii se manuálním měřením všech bodů zabývá operátor, v digitálních aplikacích je tento úkol řešen automaticky. V literatuře se tento proces označuje jako *image matching* (Schenk, 1999 in Potůčková, 2004). Jeho nedostatkem je to, že body neleží pouze na terénu, ale i na povrchu objektů, a vyhodnocuje se tedy digitální model povrchu. Pro tvorbu digitálního modelu reliéfu je třeba provést filtraci. K největším potížím dochází v lesních porostech, kde je ve vegetačním období téměř nemožné, aby byl bod na zemském povrchu viditelný na dvou snímcích. Proto se za účelem tvorby digitálního modelu reliéfu území s vegetací snímkuje spíše mimo vegetační období, aby koruny stromů nezakrývaly zemský povrch (Oršulák, Pacina, 2012).


2.2.3 Princip *high density image matching*

Proces *image matching* lze rozdělit na několik částí. První z nich je detekce, druhá pak ztotožnění, po které následuje fáze transformace. Na počátku je nutností nalézt ve snímcích či datových sadách totožné prvky, přičemž snahou je najít jich co největší množství. Poté je třeba vypočítat matematicky definované vztahy, díky nimž je možné oba snímky resp. datové sady ztotožnit. Můžeme rozlišit tři metody *image matching*, první z nich je metoda shodnosti oblastí (*area based*), další pak shodnost prvků (*feature based*), případně shodnost vztahů (*relational methods*) (Remondino et al., 2008; Pokorný, 2013). Klíčový problém metody *image matching* je spojen právě s volbou entity, která je porovnatelná s entitou v ostatních snímcích, a také míra podobnosti (kvantitativní vyhodnocení totožnosti). Vyhledání shodných oblastí nebo konkrétních prvků lze dosáhnout automatizovanými postupy. Zpravidla jsou vyhledávány významné plochy, homogenní objekty, hrany, linie, body a rohy. Při využití metody *area based* se krok detekce integruje do samotné fáze ztotožnění. Základem metody je použití plovoucího okna nad hlavním obrazem. Při tom je využíváno různých dalších metod pro vyhledávání podobných objektů v obraze. Problematické je využití této metody při ztotožnění hladkých povrchů, protože zde není možnost záznamu nějakého záchytného prvku. Mezi výhody můžeme zařadit snadnou implementaci do softwaru a možnosti modifikace. Metody *feature based* jsou založeny na vyhledání shodných prvků na základě jejich jedinečnosti. U prvků je předpokládána časová neměnnost, která následně ovlivňuje výslednou kvalitu ztotožnění (Pokorný, 2013). Posledním typem jsou metody *relational*, které jsou založeny na vzájemných vztazích mezi prvky a jejich geometrickými a topologickými vztahy (Yen et al., 2006).

2.2.4 Rozdíly mezi metodami

Klasická stereofotogrammetrie je založená na vyhledávání – korelaci významných prvků/pixelů ve dvou obrazech najednou. V okolí každého významného prvku je pak vytvořeno okolí a dále se vyhledává podobná textura v obou obrazech. Každý významný prvek je při tom považován za jakousi izolovanou oblast, což způsobuje jev viditelný v obrázku 2 – nejsou zde dobře patrné hrany objektů. Oblasti mezi těmito významnými body jsou pak interpolovány. Přístup *high density image matching* vyhledává v obrazech shodné oblasti (*area based*), shodné prvky (*feature based*), nebo shodnost vztahů (*relational methods*), ale postupuje přitom pixel po pixelu. Výběr metody je závislý například na charakteristikách území, které je zpracováváno (Remondino et al., 2008). Při procesu je zkoumán průběh paralaxy v okolí shodných prvků či oblastí, je tedy možné, aby byly lépe vykresleny hrany, protože zájmové prvky nejsou brány jako izolované a je uvažováno také jejich okolí. Navíc postup *high density image matching* přináší více možností v tom, že je

možné zde využít i více než dva stereo snímky, tzv. *multi-view stereo*, čímž může přispět ke zpřesnění výsledného bodového mračna.



Obr. 2: Rozdíly mezi klasickou obrazovou korelací (b) a *density image matching* (c) (zdroj: Hirschmüller, 2005)

V obrázku 2 můžeme vidět rozdíly mezi modelem vytvořeným klasickou stereofotogrammetrickou metodou (b) a modelem vytvořeným pomocí *high density image matching* (c). V modelu vytvořeném druhým způsobem (c) jsou patrnější hrany objektů a některé objekty jsou mnohem snáze rozpoznatelné než v modelu (b).

3.2.5 Softwarová řešení

V současnosti je možné k tvorbě bodového mračna na základě metody *high density image matching* využít několik algoritmů nebo přímo softwarů. Dostupné jsou buď volně v podobě *opensource*, případně existují i komerční řešení. Za největší výhodu takto vytvořeného bodového mračna můžeme jistě označit možnost jeho vytvoření z více jak dvou překrývajících se snímků, což dodává výsledné datové sadě větší věrohodnost. To je rozdíl oproti laserovému skenování, kdy bodové mračno vychází pouze z jediného měření (Remondino et al., 2012).

SURE (*photogrammetric SURface REconstructio from imagery*) je softwarové řešení pro *multi-view stereo* (MVS), které umožňuje odvození hustých mračen bodů z dodaných sad snímků a informací o jejich orientaci (Haala, Rothermel, 2012; Rothermel et al., 2012). Referenční snímek je přiřazen k sousedním snímkům za využití *semi-global search stereo* algoritmu (Hirschmüller, 2005).

2.3 Výzkum lesních porostů

2.3.1 Využití laserových a optických dat v lesnictví

V nedávné době byl odhad vlastností lesních porostů účinně vylepšen použitím technologií dálkového průzkumu Země, které mají zajisté více výhod než tradiční způsob inventarizace lesních porostů. Ten je založen na pozemních měřeních nivelací či tachymetrií. K získání spolehlivých odhadů různých vlastností porostu by měl být objem shromážděných údajů reprezentativní pro celý lesní ekosystém, což se vzhledem k časové náročnosti a často také nedostatečnému přístupu do některých oblastí může zdát jako nepředstavitelná úloha pro pozemní terénní šetření. Na místě tedy může být právě využití dálkového průzkumu, který představuje důležitý nástroj pro objektivní a přesné monitorování velkých lesních ploch (Paris, Bruzzone, 2015).

V lesnictví mohou být data laserového skenování vhodným zdrojem informací pro určení některých porostních charakteristik, především údajů o výšce a počtu stromů v porostech (Mikita et al., 2013). Dále mohou být zjišťovány například objemy dřevní hmoty či detekce změn a jsou vytvářeny modely lesních porostů (Næsset, 1997; Maltamö et al., 2007). Mezi základní procesy patří také rozlišování listnatých a jehličnatých lesů. Dále je možné identifikovat dřeviny, což může být užitečné při výzkumu druhové rozmanitosti (Sooyoung, 2009). LiDARová data mohou být také použita k rekonstrukci 3D modelu lesa. Zejména data s vysokou hustotou bodového mračka (5 bodů/m²) umožňují přesně určit výšku koruny stromu. Výsledkem tedy může být přesnější odhad lesních parametrů na úrovni jednoho stromu (např. objem kmene) (Dalponte et al., 2011). Problémem však může být to, že LiDARová data s vysokou přesností mají vysoké pořizovací náklady, zejména v případě velkých zájmových území. Je to způsobeno tím, že při zvyšování hustoty dat je třeba zvýšit také dobu letu. Jako příklad je možné uvést snížení intervalu odstupe jednotlivých laserových impulsů z 1,5 m na 0,3 m, pořizovací náklady na kilometr čtvereční tak mohou narůst přibližně třikrát (Wulder et al., 2008).

Aplikace související s lesnictvím byly jednou z hlavních oblastí ve výzkumu využití dat laserového skenování jako jednoho ze způsobů získávání biofyzikálních vlastností stromů dohledatelných z 3D bodových mračen. Taková úroveň podrobnosti, jaká je potřebná pro tyto atributy, je v současnosti dosažitelná pouze pomocí laserových technik. Ty mají schopnost proniknout korunou stromů a zmapovat tak také jeho vertikální strukturu (Liang et al., 2015). K získání informací o výšce, o struktuře lesních porostů, objemu biomasy a také o zakřivení kmenů můžeme využít rozdílné laserové systémy: letecké, pozemní, mobilní a nejnovější *personal* (Magnussen, Boudewyn, 1998; Yu et al., 2013; Liang et al., 2014).

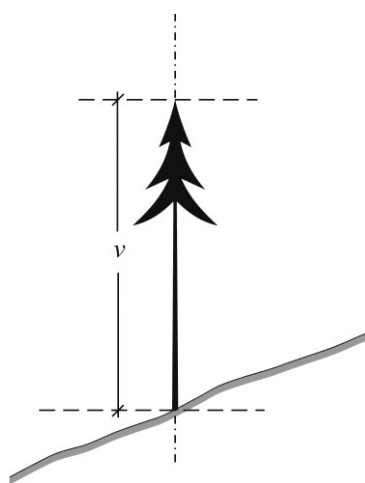
Nejnovější lesnické výzkumy ukázaly LiDAR jako nejvhodnější zdroj pro 3D informace, zatímco spektrální informace ze snímků obsahují doplňující informace o porostech vhodné například pro mapování habitatů nebo lesních požárů (Chust et al., 2008; Erdody, Moskal, 2010).

Tvorba bodového mračka ze stereoskopické dvojice snímků popřípadě většího počtu snímků byla do nedávné doby omezena vysokými výpočetními nároky (Liang et al., 2015). Spolu s velmi rychlým nárůstem výpočetního výkonu se však postupně v poslední době do praxe dostávají postupy modelování povrchu objektů z leteckých snímků metodou *image matching* (Hájek et al., 2015). V České republice jsou letecké měřické snímky využívány Ústavem pro hospodářskou úpravu lesa (ÚHÚL), více v kapitole 2.3.3. Atributů, které je možné na základě zpracovaných optických dat zjišťovat, je celá řada, podobně jako u dat LLS.

Z ekonomického hlediska je patrné, že nákladnější pořizování dat leteckým laserovým skenováním není možné provádět v tak krátkých časových intervalech jako sběr optických dat. Pokud hustota bodového mračka získaného z LiDARových dat není dostatečná pro určování parametrů lesních porostů na úrovni stromu, je nasnadě pokusit se o vylepšení přesnosti pomocí integrace dvou typů dat.

2.3.2 Charakteristiky lesních porostů a jednotlivých stromů

Měřitelných veličin charakterizujících jak celé lesní porosty tak také jednotlivé stromy je celá řada. Na úrovni stromu se jedná o polohu stromu, jeho výšku (Obr. 3), dále pak o objem dřevní hmoty a také tvar či průměr koruny. Na úrovni lesních porostů je pak možné měřit střední výšku porostu, korunový zápoj, zakmenění a také objem dřevní hmoty (ÚHÚL, 2003).



Obr. 3: Výška stromu (zdroj: ÚHÚL, 2003)

2.3.3 Inventarizace lesních porostů v České republice

V České republice existuje spolupráce mezi Zeměměřickým úřadem (ZÚ) a ÚHÚL. Je založena na vzájemné výměně a poskytování prostorových dat. ZÚ poskytuje ÚHÚL nově pořízené letecké měřické snímky, výškopisná data apod. Tyto podklady jsou ÚHÚL využity hlavně pro druhý cyklus Národní inventarizace lesů a produkci celorepublikových lesnických tematických map. Na druhé straně ZÚ začleňuje informace z lesnických map do ZABAGED a zvyšuje tím její informační potenciál (Hron, 2012). Národní inventarizace lesů fotogrammetricky zjišťuje vybrané parametry na inventarizačních bodech v síti 500 x 500 m (ÚHÚL, 2014) = 360 tis. ploch na území ČR. Je při tom využívána stereofotogrammetrická interpretace v barevné kombinaci infračerveného, červeného a zeleného kanálu. ÚHÚL zpracovává také infračervené ortofoto a normalizovaný digitální model povrchu (dále nDSM), který je vytvořen odečtením DMR od DMP (Hájek et al., 2015).

2.3.4 Podobné způsoby inventarizace lesních porostů v zahraničí

Způsoby a metody, jakým jsou lesní porosty inventarizovány, se mezi jednotlivými státy významně liší. Dálkový průzkum Země však hraje ve vyspělých státech stále větší roli při řešení úloh týkajících se lesnictví. Poměrně častým a běžným nástrojem sloužícím k inventarizaci lesních porostů jsou letecké snímky. Porovnáním klasických metod měření v terénu a metod, při kterých se využívá odhadů z leteckých snímků, se zabývala práce McIntosh et al. (2012). Přístup, kdy se pro tvorbu nDSM využijí letecké snímky společně s daty LLS pro získání přesného DMR, je již několik let praktikován například ve švýcarské Národní inventarizaci lesů (Waser et al., 2011, Ginzler et al., 2015). Tento postup se velmi podobá české Národní inventarizaci lesů II. Azizi et al. (2014) ve své práci uvádí příklad možnosti využití satelitních snímků k mapování hustoty a objemu dřevní hmoty v lesních porostech.

2.3.5 Identifikace jednotlivých stromů v literatuře

Pokud je zapotřebí vymezení jednotlivých korun stromů, je nutné rozhodnout, jaká data k tomu budou využita, zda data optická, jejichž využití při segmentaci popisuje odstavec níže, nebo data LiDARová (Lindberg, Holmgren, 2017).

Segmentace obrazu je prvním krokem objektově orientované klasifikace a také metodou, jak vymezit jednotlivé koruny stromů z dat optických. Využít lze různé přístupy, z nichž dva nejzákladnější jsou *top-down* a *bottom-up*. Přístupy jsou založeny na různém definování homogenity. Jak již název napovídá, segmentace *top-down* začíná dělit obraz od větších segmentů k menším, kdy na počátku segmentace je obraz považován za jeden celý segment,

který je postupně dělen na menší a menší segmenty. Opakem je segmentace *bottom-up*, kdy jsou na začátku segmentace za jednotlivé segmenty považovány jednotlivé pixely. Ty se postupně propojují ve větší celky (Levin, Weiss, 2009).

Zájem o identifikaci a následné vymezení tvaru koruny stromu v digitálních obrazech má kořeny již v roce 1920, kdy byly letecké snímky poprvé využity k inventarizaci lesních porostů (Howard, 1991). Techniky využívající dálkový průzkum v lesnictví pak byly stále více využívány, a proto i zdokonalovány. Dodnes jsou ve společnostech v oblasti lesnictví využívány především metody založené na manuální interpretaci dat dálkového průzkumu v kombinaci a terénním šetřením (Erikson, 2004). V práci Eriksona (2004) jsou představeny různé algoritmy pro segmentaci jednotlivých korun stromů, zároveň jsou porovnávány s ostatními a jsou uvedeny jejich výhody či nevýhody oproti algoritmům jiným. Všechny uváděné algoritmy jsou zaměřeny na zachování tvaru koruny. Výběr vhodného algoritmu je závislý na požadovaných následných analýzách. Regiony reprezentující jednotlivé koruny rostou podle určitých pravidel z počátečních bodů (*seed points*). Jedna z metod začíná z mnoha regionů a hledá nejlépe koruně odpovídající region. Další metody začínají nastavením počátečního bodu, který reprezentuje lokaci koruny k vytvoření regionu. Ve výzkumech zabývajících se korunami stromů je za vysoké rozlišení považována velikost maximálně 1 m. Tvar koruny začíná být viditelný, pokud má průměr alespoň 2 m. V obraze s vyšším rozlišením jsou zahrnuty nejen koruny, ale také podrost, což může způsobovat problémy při oddělování zájmových částí obrazu. Toto oddělování se nazývá právě segmentací.

Určením polohy stromu se zabývají ve svých pracích Eysn et al. (2011), Höfle a Hollaus (2010) nebo Reitberger et al. (2009). Tento atribut je třeba znát k dalším výpočtům týkajících se lesního porostu. Pozice stromu je v datech LLS určena jako souřadnice x , y bodu lokálního maxima v koruně stromu. Tento bod je vybrán na základě filtru lokálních maxim.

Pro automatickou detekci jednotlivých stromů bylo vyvinuto mnoho metod, z nichž značná část je založena na výškovém modelu vegetace (*canopy height model* = CHM) odvozeném z LiDARových dat – jedná se vlastně o nDSM. Používány jsou také rastry povrchu vzniklé interpolací bodového mračna představujícího povrch, které bylo taktéž získáno pomocí skenování (Hyypä et al., 1999; Huang et al., 2013; Persson et al., 2002). Při použití těchto metod je nutné počítat s některými problémy. Prvním je již samotné odvození CHM, při kterém vzniká množství chyb a „nejistot“ způsobených výběrem interpolace a také volbou prostorového rozlišení rastru (Smith et al., 2004). Všechny tyto faktory samozřejmě dále ovlivní následné odhady metrik stromů (Suárez et al., 2005). Dalším problémem je krok, při

kterém je provedeno ke Gaussovskému vyhlazení povrchu, protože poté dochází k podhodnocování nebo naopak nadhodnocování výšky stromů (Tiede et al., 2005). Morsdorf et al. (2004) aplikovali *k-means* shlukovací (*k-means cluster*) algoritmus k detekci jednotlivých stromů. Jejich klastrovací metoda závisí na počátečním bodu vybraném z CHM odvozeného z LiDARu, takže není možné ji použít na bodové mračno. Li et al. (2010) navrhuje *spacing based tree* segmentační algoritmus pro smíšené jehličnaté lesy. Sima a Nüchter (2012) ve své metodice používají segmentaci založenou na grafech. Metoda byla testována na jehličnatých lesních porostech.

Jak je patrné z výše uvedeného výčtu, většina algoritmů pracuje s rastrem získaným interpolací CHM, který je odvozen z bodového mračna LiDARových dat. V práci Zhanga et al. (2015) je představen nový algoritmus využitelný hlavně pro automatickou inventarizaci městských lesů na úrovni jednotlivých korun stromů. Jsou při tom využívána data LiDARového snímání v podobě bodového mračna, která obsahují trojrozměrnou informaci o struktuře, která může být dále využitelná pro určení výšky stromu, průměru koruny a dalších parametrů. Testování v typických urbánních lesích ukázalo, že algoritmus dává uspokojivé výsledky. Algoritmus obsahuje tři zásadní kroky: filtraci LiDARových dat, detekci vrcholů stromů a extrakci jednotlivých stromů. Pro tuto práci není krok filtrace zásadní, zpracovávaná bodová mračna jsou jasně předem rozdělena na body terénu a povrchu, proto nejsou zapotřebí hyperspektrální data, která Zhang et al. (2005) využívají k oddělení právě těchto dvou kategorií. Dále je aplikován jeden z následujících algoritmů: algoritmus lokálního maxima, *treetop detection* algoritmus nebo *tree climbing* algoritmus. Při použití uvedených algoritmů se detekuje vrchol koruny stromu. Detekované vrcholy stromů jsou pak počátečními body pro segmentaci jednotlivých korun. Pro tento krok se dá využít algoritmus inverzní *tree climbing* metody.

2.4 Fúze optických a laserových dat

LiDAR i stereofotogrammetrie mají své jedinečné výhody i nevýhody pro rekonstrukci povrchu. Některé nedostatky jedné metody tak mohou být kompenzovány výhodami, které nabízí metoda druhá. Možnostmi kombinace dat získaných leteckým laserovým skenováním a z leteckých snímků pro tvorbu digitálního výškového modelu se zabývá např. Schenk a Csathó (2002) nebo Rönholm et al. (2010).

Fúze dat laserového skenování a dat optických byla analyzována v několika studiích. Detailní analýzy poukázaly na fakt, že kombinace zmíněných dat vede k přesnějším odhadům charakteristik lesních porostů (Paris, Bruzzone, 2015). Laserové skenování a letecké snímání jsou systémy, pomocí nichž lze získat data s vysokým prostorovým rozlišením (Erdody, Moskal, 2010). Letecké snímky zajišťují doplňující informace k datům

leteckého laserového skenování, stejně to funguje i obráceně. Integrace bodového mračna získaného LLS s mračnem získaným z leteckých snímků má velký potenciál pro vylepšení 3D modelování a také klasifikací objektů v prostředí lidské činnosti i přírodní sféře. Nejvíce slibnými oblastmi vyžadujícími další výzkum jsou automatické rozpoznávání objektů, přesnost klasifikace individuálních stromů, zhušťování bodového mračna, automatická klasifikace land use nebo generování fotorealistických 3D modelů (Rönnholm et al., 2007). Z podstaty způsobu pořizování dat je zřejmé, že oba typy dat nelze pořizovat simultánně. Zatímco data laserového skenování je možné získávat i během nočních hodin, letecké snímkování toto neumožňuje. Dalším důvodem pro separátní pořizování dat mohou být například jiné požadavky na optimální výšku letu (Rönnholm, 2010).

Data získaná laserovým skenováním spolu s daty získanými z leteckých snímků mohou být velmi efektivní při pokročilejších odhadech *canopy fuel metrics* pro modelování lesních požárů a mohou odrážet skutečnou prostorovou heterogenitu lesních porostů (Erdody, Moskal, 2010). Další studie prokázaly, že kromě *canopy fuels metrics* je možné využít fúzi dat LLS a optických dat s vysokým rozlišením také ke zvýšení přesnosti metrik týkajících se korun stromů (McCombs et al., 2003; Popescu, Wynne, 2004). Studie ukázala, že metody dálkového průzkumu včetně LLS mohou být použity k odhadům *canopy fuels* (Holmgren, Persson, 2004; Andersen et al., 2005; Erdody, Moskal, 2010).

Nový přístup k tvorbě 3D modelu sloužícího k odhadu výšek stromů za použití laserových dat s nízkou hustotou bodového mračna v kombinaci s optickými daty s velmi vysokým rozlišením představili ve své práci Paris a Bruzzone (2015). Metoda, kterou navrhují, využívá synergie obou typů dat k dosažení přesné výšky na úrovni jednotlivých stromů. K tomu, aby bylo možné identifikovat všechny koruny stromů ve scéně, je algoritmus multisenzorové segmentace aplikován na obraz tak, že integruje informaci o výšce získanou z dat laserového skenování. Autoři se budou dále zabývat dalšími možnými strategiemi pro výběr parametrického modelu pro ty stromy, které byly během skenování zasaženy pouze jednou. Hlavním cílem by při tom mělo být lepší přizpůsobení modelu skutečnému tvaru jednotlivých stromů, do metody tedy v budoucnu budou zahrnuty i terénní vlastnosti jako sklon či orientace.

3 DATA A ZÁJMOVÁ ÚZEMÍ

3.1 Digitální model povrchu 1. generace (DMP 1G)

DMP 1 G z Českého úřadu zeměměřického a katastrálního představuje území České republiky včetně staveb a rostlinného pokryvu. Je tvořen nepravidelnou sítí výškových bodů (TIN) s úplnou střední chybou výšky 0,4 m pro přesně vymezené objekty (např. budovy) a 0,7 m pro objekty, které nejsou přesně ohraničeny (např. lesy). Data byla získána metodou leteckého laserového skenování v letech 2009–2013. Při zpracování dat bylo území rozděleno na čtverce 5 x 5 m a v každém tomto čtverci byl vybrán jeden pravděpodobný reprezentativní bod reliéfu jako bod s nejnižší výškou. Při tom bylo kontrolováno, zda se tento bod extrémně svojí výškou neliší od bodů okolních. Tento postup byl aplikován v zemědělsky obhospodařovaných územích. V ostatních areálech kromě stavebních objektů a oblastí se vzrostlými stromy byla z důvodu nekonzistentní hustoty dat řešena generalizace modelu výběrem reprezentativních výškových bodů v síti 1 x 1 m. V každém čtverci byl vybrán pravděpodobný bod reliéfu jako bod s nejnižší výškou. Data jsou distribuována v textovém formátu (ČÚZK, 2016a).

3.2 Digitální model reliéfu 5. generace (DMR 5G)

DMR 5G z Českého úřadu zeměměřického a katastrálního představuje zobrazení reliéfu České republiky v digitálním tvaru, a to ve formě výšek diskrétních bodů v nepravidelné trojúhelníkové síti (TIN). Body mají souřadnice X, Y, H, kde H představuje nadmořskou výšku ve výškovém referenčním systému BpV s úplnou střední chybou výšky 0,18 m v odkrytém terénu a 0,3 m v lesních oblastech. Data byla získána metodou leteckého laserového skenování v letech 2009–2013. DMR 5G je základní zdrojovou databází pro tvorbu vrstevnic map velkých měřítek a různých počítačových vizualizací výškopisu na různých úrovních podrobnosti. Při zpracování dat bylo území rozděleno na čtverce 1 x 1 m a v každém tomto čtverci byl vybrán jeden pravděpodobný reprezentativní bod reliéfu jako bod s nejnižší výškou. Data jsou distribuována v textovém formátu (ČÚZK, 2016b).

3.3 Letecké měřické snímky

Letecké měřické snímky byly poskytnuty Českým úřadem zeměměřickým a katastrálním. Snímky pásma „střed“ z roku 2010 byly pořízeny centrální projekcí a mají rozlišení 25 cm. Data jsou distribuována ve formátu TIFF (ČÚZK, 2017a). Rok pořízení snímků byl zvolen tak, aby byla datová sada co nejbližší datu pořízení dat LLS v KRNAP (2012). Z těchto dat bude odvozen DMP metodou *high density image matching*.

3.4 Ortofoto

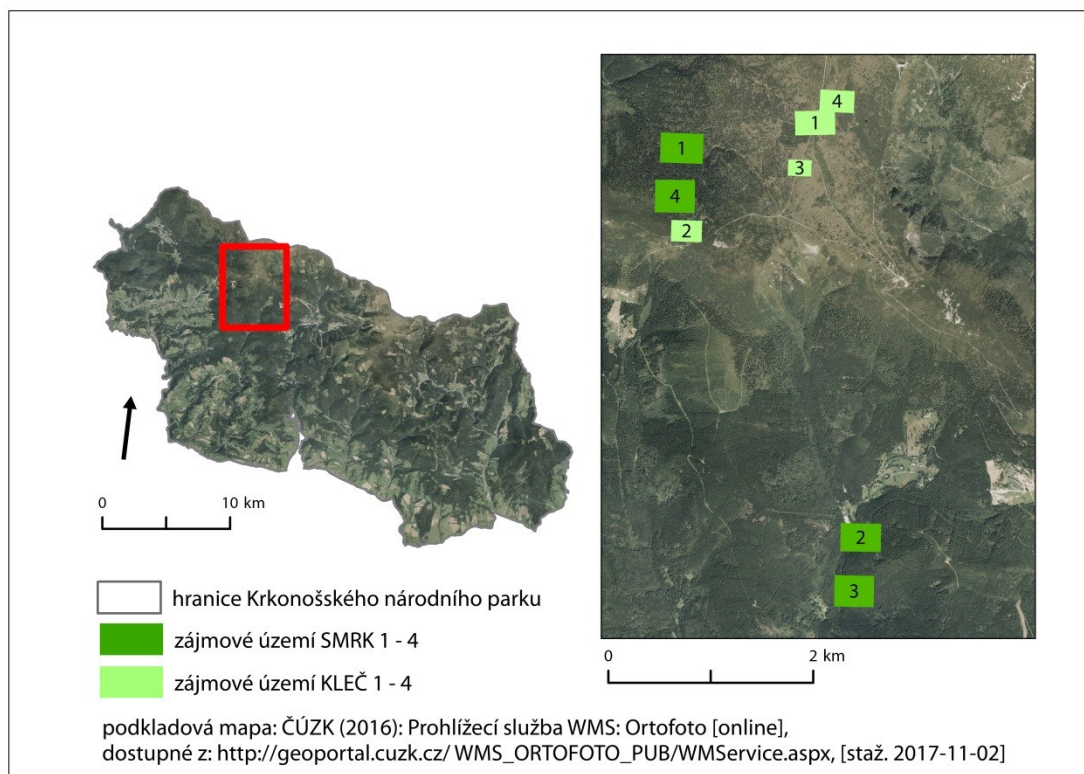
Ortofoto České republiky představuje periodicky aktualizovanou sadu barevných ortofota v kladu mapových listů Státní mapy v měřítku 1 : 5000. Ortofota jsou zdánlivě bezešvá, protože švy jsou vedeny po přirozených liniích. Snímky pásma „střed“ z roku 2010 mají rozlišení 0,20 m. V současné době se snímkování území republiky provádí ve dvouleté periodě (ČÚZK, 2017b).

3.5 Data leteckého laserového skenování KRNAP

Data leteckého laserového skenování z lokálního snímání území Krkonošského národního parku společností GEODIS byla získána od Správy KRNAP. Snímání proběhlo v první polovině roku 2013 v rámci projektu KRKONOŠE v INSPIRE – společný GIS pro ochranu přírody, který je podpořen z Operačního programu Přeshraniční spolupráce ČR-PR 2007–2013. Cílem projektu bylo pořízení kompletních geoprostorových dat pro území celého KRNAPu, tj. 550 km² a jejich následné vyhodnocení. Hustota mračna laserových bodů je 5 bodů/m². Tak vysoká hustota byla požadována z důvodu velkých výškových rozdílů v národním parku. Snímkování trvalo celkem 16 letových dní. Pomocí leteckého skeneru RIEGL LMS Q-680i bylo naskenováno 553 letových řad. Následovalo relativní i absolutní vyrovnání mračna bodů. Data jsou ve formátu *.las*. (Puchrik, Nýdrle, 2013).

3.6 Zájmová území

Vzhledem k celému zaměření práce bylo za zájmové území vybráno osm oblastí na území KRNAPu. Jde o lokality s porostem monokultury smrku ztepilého (*Picea abies*) a vegetaci nad horní hranicí lesa, kde byl zkoumán porost borovice kleče (*Pinus mugo*). Rozmístění zájmových lokalit v rámci KRNAP můžeme vidět v obrázku 4.



Obr. 4: Rozmístění zájmových území v rámci KRNAP

4 METODIKA

4.1 Příprava dat

Získaná data nebylo možné ihned použít pro požadované aplikace, nejprve bylo nutné je upravit a sjednotit. Data získaná od Správy KRNAP nebyla ve stejném souřadnicovém systému jako data z ČÚZK. Proto bylo nutné je transformovat ze souřadnicového systému UTM 33 do souřadnicového systému S-JTSK. Soubory *las* byly nejprve převedeny do formátu *txt*. Dále byly tyto soubory *txt* transformovány. Aby byla transformace přesná, bylo nutné využít nástroj pro převod souřadnic na geoportálu ČÚZK. Vzhledem k objemu převáděných dat byl využit program, který je v tomto nástroji využíván - ETJTZU 2014. Tento software však neumí kombinovat různé polohové a výškové souřadnicové systémy, proto je nutné nejprve připravit vstupní soubory tak, aby vyhovovaly požadovaným parametrům ETRS89 (BLh).

4.2 Tvorba bodového mračna z leteckých měřických snímků


Dalším metodickým krokem v práci bylo vygenerování bodového mračna z leteckých měřických snímků metodou *high density image matching*, která je popsána v kapitole 2.2.3. Do softwaru SURE jsou letecké měřické snímky k vytvoření modelu povrchu vkládány ve formátu *tiff*. V prvním kroku postupu jsou vygenerovány pro každou stereodvojici epipolární snímky. V dalším kroku se na vygenerovaných epipolárních snímcích provede párování obrazu s vysokou hustotou hledaných bodů (*dense matching*). Zároveň jsou v tomto kroku vypočteny paralaxy pro danou stereodvojici. V řetězci nástrojů je obraz I_b , který je dále nazýván základním obrazem, porovnáván s určitým počtem N blízkých/shodných obrazů, které vedou k sérii stereomodelů $M_n=1, \dots, n$. U datasetů s vysokým překryvem včleněných obrazů jsou v těchto stereomodelech výškové informace odhadnuty redundantně. Ve třetím modulu SW SURE je tato redundance využívána k odstranění chyb a zvyšování přesnosti určované výšky bodu. Tím jsou propojeny pouze výškové mapy stereomodelů, které sdílejí stejný základní obraz $I_b, I_m, i = 1, \dots, 1_n$. Výsledkem je výškový rastr nebo bodové mračno s ohledem na základní obraz I_b . Informace o tom, které stereomodely by měly být zahrnuty

do procesu rekonstrukce, jsou definovány maticemi propojení/konektivity. Ty jsou uloženy jako soubory ASCII a předány jednotlivým modulům. Pro malé datasey mohou být matrice konektivity specifikovány ručně (Rothermel et al., 2012).

4.3 Porovnání bodových mračen

Aby mohly být mezi sebou datasey porovnávány, bylo nutné převést je všechny do jednotného formátu. DMP 1G a DMR 5G, které jsou dodávány v textových souborech jako seznam souřadnic, bylo třeba převést do podoby bodů. To bylo provedeno v SW ArcGIS pomocí funkce *ASCII to 3D Feature*.

Jako nástroj pro porovnání výškových odchylek jednotlivých datových sad byl vybrán SW DTM Analyst, v1.0. Tento nástroj mezi sebou porovnává dva DMR nebo DMP. Jeden z nich je zvolen jako referenční, druhý jako analyzovaný. Během analýzy dojde k tomu, že je na bodech referenčního souboru provedena triangulace. Na výběr je několik typů, při zpracování této práce byla vybrána Delaunayho triangulace. K trojúhelníkům takto vytvořeného TINu jsou pak nahrány body analyzované datové sady, které jsou následně do trojúhelníků promítnuty (Obr. 5). V místech průmětu je pak interpolací dopočítána výška referenčního bodu, která je porovnána s výškou bodu analyzovaného. Výstupem programu je tabulka obsahující souřadnice referenčních bodů, interpolovaných výšek a rozdílů výšek mezi zkoumanými datovými sadami.



Obr. 5: Princip porovnání výšek bodů v SW DTM Analyst (TIN z referenčních bodů, červené body – analyzované, zelený bod – interpolací dopočtená hodnota z referenčního bodu)

Vzhledem k zaměření práce byla mezi sebou porovnávána bodová mračna DMP 1G, DMP z KRMAP a bodové mračno vytvořené HDIM. Jako referenční byl zvolen DMP 1G s menší hustotou bodů. K němu byl analyzován DMP z KRMAP a HDIM. Poté byly mezi sebou

porovnány i datové sady KRNAP a HDIM, kdy jako referenční byla zvolena datová sada KRNAP.

4.4 Tvorba DMP klasickou metodou

Pro lepší představu přínosů metody *high density image matching* byl v SW PCI Geomatica extenze *Ortho Engine* vytvořen DMP klasickou metodou stereofotogrammetrie. Prvním krokem v softwaru bylo správné nastavení prostředí projektu. Byla vybrána možnost matematické metody modelování – *Aerial Photography*, typ kamery *Digital/Video*, způsob, jakým bude vypočítána vnější orientace, z vloženého textového souboru. Dále bylo definováno zobrazení *KRON D211*, což je souřadnicový systém (S-JTSK) s převrácenými osami. Na základě kalibračního protokolu kamery Ultra CAM X byly zadány parametry kamery: konstanta komory, radiální distorze čočky, šířka snímku, výška snímku. Dále byly načteny snímky, se kterými se dále pracovalo, a také soubor s prvky vnější orientace. Poté byly generovány epipolární dvojice snímků. Následovalo generování digitálního modelu terénu v nejvyšší dosažitelné podrobnosti (parametr *DEM detail – high*). Vytvořený rastr byl dále porovnán s DMP vytvořeným metodou HDIM (kapitola 5.2).

4.5 Tvorba výškových modelů porostu

Výškový model porostu (CHM) je v podstatě normalizovaný digitální model povrchu. V této práci byly nDSM v podobě bodového mračka využívány při porovnání jednotlivých datových sad a k identifikaci a modelování stromů v porostu. V podobě rastrové pak sloužily hlavně při objektové klasifikaci.

Tvorba bodového mračka představujícího nDSM byla provedena pomocí SW DTM Analyst. Jako referenční zde bylo nastaveno bodové mračko DMP, jako analyzované mračko pak DMR. Dopočtené rozdíly mezi měřenými a interpolovanými body představovaly relativní výšku objektů či porostů na povrchu – tedy nDSM.


Dále bylo vytvořeno bodové mračko obsahující nejen body nDSM vytvořeného z DMP 1G a DMR 5G, ale také body z nDSM HDIM. První zmíněné mračko však obsahovalo mnohonásobně (někdy až 120 x) menší množství bodů než mračko z HDIM. Tento fakt je způsoben rozdílnou hustotou bodů. Krok byl proveden proto, aby mohlo být zjištěno, zda kombinace řídkého bodového mračka z dat LLS a hustšího bodového mračka z HDIM může přinést nějaké vylepšení tak, jak je popsáno v literatuře (kapitola 2.4).

Další rastry nDSM (z dat HDIM a KRNAP) byly vytvořeny k následnému využití v objektové klasifikaci. Při jejich tvorbě bylo nejdříve nutné interpolovat jednotlivá bodová

mračna. Byla aplikována interpolace *natural neighbor*, velikost pixelu byla zvolena 20 cm, aby bylo možné každému pixelu ortofota přiřadit jeden pixel výškového modelu. V rozšířeném nastavení interpolace byl tedy ještě přiřazen rastr, podle kterého by se měly pixely nového rastru vytvořit, aby si vzájemně odpovídaly. Rastry datové sady z ČÚZK pak byly od sebe odečteny (1G-5G, HDIM – 5G) a datová sada z dat KRNAP také (DSM KRNAP – DMR KRNAP).

4.6 Identifikace jednotlivých stromů

Výstupem tohoto kroku je vektorová vrstva s polygony ohraničujícími jednotlivé zájmové porosty. U korun smrku navíc jeden pixel v každém polygonu, který představuje vrchol koruny. K detekci jednotlivých stromů bylo zapotřebí využít objektovou klasifikaci. Podobně jako v práci Paris a Bruzzone (2015), kdy byla k vymezení jednotlivých stromů využita optická data. Předpokládaný výsledek této fáze je vidět v obrázku 6. Kromě jednotlivých korun jsou také určeny jejich vrcholky.



Obr. 6: Určení vrcholku koruny (a), vymezení jednotlivých korun z optických dat (b) (zdroj: Paris, Bruzzone, 2015)

Postup vedoucí k vymezení zájmových porostů a jednotlivých korun byl proveden v SW eCognition. Vzhledem k tomu, že na jednotlivých vybraných územích se nenacházely pouze požadované porosty, bylo nutné pro oddělení jednotlivých stromů provést také klasifikaci, při níž by se oddělila třída požadovaného porostu od třídy obsahující stíny či podrost.

V ortofotoech s rozlišením 0,2 m a pásmy *red, green, blue* byla provedena segmentace obrazu, k níž byl využit algoritmus *multiresolution segmentation*, který spadá do kategorie *bottom-up* algoritmů. Na počátku se tedy pracuje s každým pixelem jako samostatným

segmentem a následně jsou na základě nastavených vah parametrů připojovány další pixely, čímž segmenty rostou. Rozhodovací fáze při slučování je založena na kritériu homogenity, které je popsáno jako podobnost mezi sousedními obrazovými objekty. Dvojice obrazových objektů, v našem případě pixelů, s nejmenším nárůstem v definovaném kritériu je sloučena. Proces slučování končí v momentě, kdy nejmenší zvýšení homogenity překročí prahovou hodnotu definovanou uživatelem (tzv. *Scale Parameter*). Proto čím vyšší je nastavená hodnota *Scale Parameter*, tím více je umožněno sloučení a naopak (Darwish et al., 2003). Tento parametr udává, jak velké rozdíly v obrazu najde, čím je jeho hodnota vyšší, tím menší rozdíly jsou nalezeny. Dále byly nastavovány váhy tvaru a kompaktnosti, které mohou nabývat hodnot 0–1. Zvolené segmentačních parametry u jednotlivých území i porostů jsou shrnuty v tabulce 1, 2 a 3.

Následně byla provedena klasifikace, při níž bylo nutné oddělit zájmové porosty – smrk ztepilý a borovici kleč od ostatní vegetace a terénu.

4.6.1 Objektová klasifikace porostu borovice kleče

Během klasifikace byl využit index GRVI (*Green Red Vegetation Index*), jako jeden z mála vegetačních indexů totiž nevyužívá pásmo NIR, které ve snímcích nebylo obsaženo. Výpočet tohoto indexu je následující:

$$GRVI = \frac{\rho_{green} - \rho_{red}}{\rho_{green} + \rho_{red}} \quad (3)$$

Na základě indexu GRVI je možné oddělit vegetaci od umělých povrchů, kterými byly v případě této práce cesty. Dále bylo využito spektrálních vlastností jednotlivých porostů. Nastavené parametry u klasifikace borovice kleče jsou shrnuty v tabulce 1. Borovice kleč často tvoří celistvé porosty, u nichž nelze jednotlivé stromy oddělit, tudíž nemohly být vymezeny jednotlivé stromy. Pokud však jednotlivé borovice stojí osamocně, byly již při počáteční segmentaci odděleny (Obr. 7). K vyklasifikování samostatně stojících borovic by mohl být použit také parametr kulatosti. V případě všech čtyř vybraných území však byly samostatné borovice klasifikovány správně, proto tento parametr nemusel být do klasifikace zahrnut. Výsledky objektové klasifikace, při níž byla použita pouze optická data, ukázaly, že v jednom snímku od sebe nelze dobře rozlišit dva druhy vegetace smrk/borovici.



Obr. 7: Segmentace obrazu – samostatně rostoucí borovice kleč a vedle ní problematicky klasifikovaný smrk se stínem

Tab. 1: Parametry segmentace a klasifikace u porostu borovice kleče na základě optických dat (kap. 4.4.1) – mezi jednotlivými pravidly klasifikace je logický operátor AND

		kleč 1	kleč 2	kleč 3	kleč 4
segmentace	scale parameter	35	30	25	25
	shape	0,5	0,5	0,5	0,5
	compactness	0,8	0,8	0,5	0,7
klasifikace	KLEČ	$GRVI \geq 0,015$	$GRVI \geq 0,015$	$GRVI \geq 0,015$	$GRVI \geq 0,015$
		$G_{mean} < 90$	$G_{mean} < 80$	$G_{mean} < 95$	$G_{mean} < 79$
		$R_{mean} < 92$	$R_{mean} < 77$	$R_{mean} < 92$	$R_{mean} < 79$
		-	$B_{mean} < 60$	-	-
	OST. NÍZ. VEGETACE	$GRVI < 0,015$	$GRVI < 0,015$	$GRVI < 0,015$	$GRVI < 0,015$
	UMĚLÉ OBJEKTY	$B_{mean} > 120$	$B_{mean} > 120$	$B_{mean} > 120$	$B_{mean} > 120$
		-	-	-	$GRVI < 0$
	STÍNY	$R_{mean} < 55$	$R_{mean} < 40$	$R_{mean} < 61$	$R_{mean} \leq 55$
	VODA	-	-	-	$25 < R_{mean} > 36$

Z předchozího odstavce vyplývá, že pokud je třeba klasifikovat a odlišit od sebe porost borovice a ojedinelé smrky, je třeba využít ke klasifikaci ještě jiná než optická data. Dále tedy bylo navrženo, aby byl při klasifikaci využit také nDSM. To by mohlo přispět k rozlišení smrků od borovice v jednom obraze. Postupně tedy byly použity při klasifikaci 3 druhy nDSM. První z nich byl vytvořen odečtením DMR 5G a DMP 1G, další z dat KRNAP a poslední odečtením modelu z HDIM a DMR 5G.

DMP 1G a DMR 5G jsou vytvořeny z bodového mračka s hustotou 1,5 bodu/m². Použitím těchto dat by mohla být klasifikace usnadněna k oddělení vyšší vegetace od povrchu. Do celého procesu objektové klasifikace byla přidána další úroveň segmentace – podrobnější a již pouze na třídu *kleč* a *stíny*, protože segmenty kleče obsahovaly také samostatně stojící smrky, které nebyly při první, hrubší segmentaci odděleny. Do objektové klasifikace byl dále přidán parametr průměrné hodnoty nDSM. Po bližším prozkoumání však bylo zjištěno, že ve všech zájmových lokalitách borovice kleče se tyto hodnoty u segmentů smrku neliší nijak markantně od hodnot segmentů kleče. Může to být způsobeno tím, že vzhledem k hustotě bodů v DMP 1G a DMR 5G nebyl smrk zasažen laserovým paprskem vůbec nebo ve vrcholové části. Ani hodnoty směrodatné odchylky rozdílu výšek se mezi porostem ostatní nízké vegetace a kleče nelišily. Z toho důvodu tato data nebyla dále použita při klasifikaci borovice kleče.


Mnohem vhodnější výšková data by však mohla být data LLS pořízená KRNAP a z nich vytvořený nDSM. Jejich hustota 5 bodů/m² by měla být již dostačující k vymezení jednotlivých korun smrků v souvislém porostu borovice. Tento předpoklad byl potvrzen v lokalitě borovice kleče 1. Je však nutné zmínit také fakt, že ne všechny identifikované smrky byly určeny správně. Vzhledem k tomu, že výška nDSM je vypočítána průměrem pixelů v jednotlivých segmentech, je velmi rozdílná od reálné výšky porostu v metrech. Mezní hodnoty jednotlivých tříd jsou shrnuty v tabulce 2, u třídy *stíny*, *umělé objekty* a *voda* zůstaly nastaveny hodnoty spektrálních atributů. Již za použití parametru výšky, byla ve snímku kleče 1 vyklasifikována většina smrků správně. Jak je popsáno v následující kapitole, problémem u vymezení jednotlivých smrků je to, že tvoří stíny, čímž ztěžují identifikaci celé koruny. Při použití výškových dat však tento problém odpadá.

Tab. 2: Parametry segmentace a klasifikace porostu borovice kleče při použití nDSM z dat KRNAP

		kleč 1	kleč 2	kleč 3	kleč 4
segmentace	scale parameter	10	7	10	7
	shape	0,5	0,5	0,5	0,5
	compactness	0,8	0,8	0,5	0,7
klasifikace	SMRK	≥ 0,7	> 0,7	≥ 0,5	> 0,6
	KLEČ	0,04 < nDSM > 0,7	0,05 < nDSM ≥ 0,7	0,04 < nDSM > 0,5	0,09 < nDSM ≥ 0,6
	OST. NÍZ. VEGETACE	≤ 0,04	≤ 0,05	≤ 0,04	≤ 0,09

Dalším výškovým modelem, který měl být použit při objektové klasifikaci, byl model vytvořený odečtením DMR 5G od DMP HDIM. Při vizualizaci nDSM však bylo vidět, že v modelu porostu borovice kleče vznikly vrcholy, nikoliv plošší objekty, které by více připomínaly vyžadovaný porost. Toto můžeme vidět v obrázku 8. Z tohoto důvodu data nebyla k objektové klasifikaci v lokalitách borovice kleče využívána, protože hodnoty výšek by byly značně nadhodnoceny a nemohly by být odlišeny jednotlivé smrky. Výstupy objektové klasifikace při použití jak pouze optických dat tak také dat výškových je možné vidět v příloze 9 až 12.

Porost borovice kleče má charakteristický tvar, který nelze zjednodušeně aproximovat rotačním tělesem. Protože jde o poměrně plochý objekt bez výraznějších výškových změn, nelze určit ani vrchol koruny. Dále se tedy práce vymezením jednotlivých stromů, určením výšky či modelací borovice kleče nezabývá. Určení výšky může být pouze relativní, a to na základě porovnání absolutní výšky segmentu borovice s okolními segmenty představujícími terén či nízkou vegetaci. Rozdíly absolutních výšek však v modelu DSM KRNAP tak v modelu DSM HDIM nabývaly hodnot v řádech decimetrů.



Obr. 8: Vizualizace nDMSM HDIM borovice kleče


4.6.2 Objektová klasifikace porostu smrku ztepilého

Při klasifikaci porostu smrku ztepilého bylo nutné nastavit při segmentaci diametrálně odlišné parametry než u borovice, jsou shrnuty v tabulce 3. V území s porostem smrku 1 a 4 nebylo možné téměř vůbec oddělit třídu *ostatní nízká vegetace* a *smrk*, jelikož obě třídy vykazovaly velmi podobné spektrální atributy ve všech třech pásmech.

Tab. 3: Parametry segmentace a klasifikace u porostu smrku ztepilého při použití nDSM
KRNAP a nDSM HDIM


	smrk 1	smrk 2	smrk 3	smrk 4
scale parameter	5	5	5	5
shape	0,8	0,8	0,8	0,8
compactness	0,5	0,5	0,5	0,5
hodnoty nDSM KRNAP	≥ 1	≥ 1	≥ 1	$\geq 0,8$
hodnoty nDSM HDIM	$\geq 2,5$	$\geq 3,5$	≥ 5	≥ 4

Zdrojem problémů při segmentaci a následné klasifikaci porostu smrku ztepilého jsou dva fakty. Prvním z nich je ten, že smrk na rozdíl od borovice kleče tvoří stíny, což způsobuje, že segmenty jsou odděleny tak, že jeden z nich představuje polovinu koruny, která není ve stínu, a druhý obsahuje zastíněnou část koruny a navíc celý stín stromu (Obr. 9). Proto by bylo bez markantních manuálních úprav nemožné využít klasifikaci založenou pouze na spektrálních atributech k oddělení jednotlivých korun. Druhým problémem je velice hustý porost smrku v územích 2 a 3.



Obr. 9: Segmentace obrazu – ortofoto (a), reálné koruny smrků (b), segmenty se stíny (c)


Dále tedy bylo stejně jako u borovice kleče využito nDSM ke zpřesnění objektové klasifikace. Parametry segmentace byly opět odlišně nastaveny a to tak, aby vznikly drobnější segmenty. Jednotlivé smrky tak byly tvořeny shlukem několika segmentů. Zájmovou třídou byla třída *smrk*, proto se práce nezabývá oddělením dalších tříd tak, jak tomu bylo v případě u porostu borovice kleče. Prvním nDSM, který měl být použit, byl model vytvořený z DMR 5G a DMP 1G. Před samotnou objektovou klasifikací byl model vizualizován v ArcScene a bylo zjištěno, že z důvodu menší hustoty bodů, ze kterých je tvořen dochází ke značnému vyhlazení povrchu (Obr. 10). Smrky jsou zřejmě zasaženy laserem pouze zřídka, a proto výsledný model neodpovídá skutečnosti. Proto dále nebyl, podobně jako u porostu borovice kleče, použit.




Obr. 10: Vizualizace nDSM vytvořeného z DMR 5G a DMP 1G

Jak je patrné z prvního modelu, který je vytvořen z dat LLS s nejnižší hustotou, pro identifikaci jednotlivých stromů je třeba hustota vyšší než $1,5 \text{ bodu/m}^2$. V modelu jsou některé stromy identifikovatelné. Tato situace nastala tehdy, když se laserový paprsek odrazil od vyšší části stromu. V místech, kde se tomu tak nestalo, je výška povrchu pravděpodobně podhodnocena.

Dalším použitým nDSM byl model vytvořený z dat KRNAP. Jak můžeme vidět na obrázku 11, jednotlivé stromy jsou v modelu zřetelné. Tento model byl tedy použit k oddělení třídy *smrk*. Podobně tomu bylo i u dalšího modelu vytvořeného z DMR 5 G a DMP HDIM (Obr. 12).



Obr. 11: Vizualizace nDSM vytvořeného z dat KRNAP




Obr. 12: Vizualizace nDSM vytvořeného pomocí DMR 5G a dat HDIM

Po této úpravě (segmentaci s nižším *Scale* parametrem) byl však jeden strom tvořen více segmenty. K určení samostatných stromů bylo zapotřebí vyhledat pixely lokálních maxim, kolem kterých by se na základě algoritmu *region grow* vytvořilo okolí představující jednu korunu. Problém však nastal již při samotném hledání lokálních maxim. SW eCognition totiž vyhledá pouze segment, jehož průměrná výška tvoří lokální maximum, ale nikoli jeden určitý pixel. Proto byl navržen jiný postup pro vymezení jednotlivých stromů a následný výpočet jejich výšky.

4.6.3 Nalezení jednotlivých stromů přímo v bodovém mračnu

Na základě studia literatury (Reitberger et al., 2009; Höfle, Hollaus, 2010; Eysn et al., 2011) byl po neúspěšném pokusu o vymezení jednotlivých stromů na základě optických dat navržen postup, který se snaží vyhledat jednotlivé stromy přímo v bodovém mračnu. Aproximací vrcholů stromů je vždy lokální maximum v daném bodovém mračnu (Obr. 13). Jako body náležící stromu jsou vybrány ty body, které splňují podmínku určené vzdálenosti souřadnic x, y od souřadnic x, y zjištěného vrcholu stromu. Tato vzdálenost představuje poloměr koruny, který je nutné stanovit na základě manuálního měření ve snímku. V případě, že by bylo třeba vypočítat přesně například objem koruny, bylo by nutné znát každý poloměr stromu ve zkoumané oblasti. V rámci tohoto skriptu je výstupem nejen složka se soubory *txt*, kdy body každého stromu jsou obsaženy v jednom souboru, ale také seznam souřadnic všech lokálních maxim, které byly v dané oblasti nalezeny. Tyto *txt* jednotlivých stromů pak budou použity při porovnávání dvou datových sad použitých k modelování (DMP KRNAP a DMP HDIM). Původně byl skript aplikován přímo na bodové mračno DMP, ukázalo se však, že výběr maxim pak markantně ovlivňuje sklon terénu. Pokud je celá lokalita ve svahu, najde se určený počet maxim spíše v horní části území, kdežto okolí, které nedosahuje takové výšky, je úplně zanedbáno. Proto byl k výběru

maxim a následnému modelování stromů využít nDSM, který vliv terénu na výběr maxim eliminuje. Tento nDSM v podobě bodového mračna byl vytvořen pomocí SW DTM Analyst. Ke každému bodu DMP byla tedy interpolována výška DMR, Rozdíl měřené a interpolované výšky pak představoval výšku objektů na povrchu - nDSM.



Obr. 13: Lokální maxima určující polohu stromu v modelu vegetace (zdroj: Reitberger et al., 2009)

4.7 Geometrický model stromů a určení výšky

Po kroku, ve kterém jsou nalezeny jednotlivé stromy, následuje jejich modelování. K vytvoření geometrických modelů stromu byl využit RANSAC algoritmus použitý v práci Sedláčkové (2012). Východiskem je to, že strom roste ve směru gravitace a má přibližně kuželovitý tvar. Algoritmus navržený Tittmannem et al. (2011) modeluje jednotlivé stromy z porostu do podoby rotačního paraboloidu, využívá při tom RANSAC.

Vstupy algoritmu jsou bodové mračno K , které náleží jedné koruně stromu a prahová hodnota *threshold*, která určuje, kdy datový bod odpovídá modelu. Dále jsou vstupem ještě dvě funkce. První z nich je *fitting*, která pro podmnožinu bodů $S \subseteq X$ nalezne optimální proložení bodů paraboloidem. Druhou je funkce *distance*, jež určí vzdálenost libovolného bodu od modelu nalezeného funkcí *fitting*.

Jednotlivé kroky algoritmu jsou následující:

- 1, najít bod s nejvyšší souřadnicí z (tento bod je považován za vrchol stromu/paraboloidu, je označen v)

- 2, **maxInliers** nastavit na 0
- 3, zvolit náhodně 2 body z množiny **K** a přidat k nim ještě bod **v**
- 4, pro tyto body spočítat funkcí **fitting** model paraboloidu
- 5, funkcí **distance** zjistit vzdálenost všech bodů **K** od modelu
- 6, body, které jsou blíže než **treshold** označit jako **inliers**, vzdálenější než **treshold** označit jako **outliers**
- 7, spočítat počet bodů v **inliers**
- 8, je-li tento počet větší než **maxInliers**, pak si zapamatovat zvolený model jako dosavadní nejlepší a **maxInliers** nastavit na počet bodů v **inliers**
- 9, pokud ještě neproběhl zadaný maximální počet iterací **max**, pokračovat znovu krokem 3

Jedním z limitů algoritmu je to, že algoritmus jako vrchol stromu označí nejvyšší nalezený bod v datech spadajících do jedné koruny stromu (přesněji lokální maximum v konvexním tvaru) (viz podkapitola 4.6.3). Tento bod však nemusí nutně představovat vrchol stromu, protože je možné, že laserový paprsek se odrazil od nižší části stromu, ne přímo od vrcholku koruny. Dalším limitem je, že algoritmus rozdělí body do dvou kategorií – na body náležící povrchu koruny stromu (tzv. *inliers*) a body do povrchu koruny stromu nenáležící (tzv. *outliers*). To na základě blízkosti k hypotetickému modelu (zjednodušenému matematicky popsatelnému tělesu). Jako nejvhodnější je pak vybrán model, který s určitou vzdálenostní tolerancí prochází co nejvíce naměřenými body. Není ale zaručeno, že model prochází opravdu po povrchu koruny (Titmann et al., 2011 in Sedláčková, 2012).

Algoritmus RANSAC podle Tittmanna byl dále doplněn o postupné načítání souborů *txt* představujících všechny vygenerované stromy z předchozího kroku. Výšku stromu pak představovala hodnota souřadnice *z*, jelikož se jednalo o nDSM. Dále bylo třeba, aby byly modely stromů ze dvou datových sad mezi sebou porovnatelné. Proto byl navržen postup, kdy se ke každému stromu z dat LLS KRNAP na základě souřadnic *x* a *y* přiřadí strom, který je nejbližší a je vytvořen z dat HDIM. Takto vytvořené dvojice pak mohou být mezi sebou porovnány.

5 VÝSLEDKY

5.1 Porovnání bodových mračen

Výstupy SW DTM Analyst, ve kterém byla mezi sebou porovnávána bodová mračka DMP, byly shrnuty v následujících tabulkách 4 –6. V prvním řádku je vždy průměrná hodnota rozdílu výšek, v druhém pak medián. V posledním je směrodatná odchylka rozdílu výšek, která byla spočtena podle vzorce (3).

$$\sigma = \sqrt{\sum \frac{(z-\bar{z})^2}{(n-1)}}, \quad (3)$$

kde z je hodnota souřadnice z , \bar{z} aritmetický průměr všech souřadnic z a n počet hodnot z .

Tab. 4: Rozdíly mezi DMP 1G a DMP KRNAP

	kleč 1	kleč 2	kleč 3	kleč 4	smrk1	smrk2	smrk3	smrk4
\bar{z} [m]	-0,18	-0,06	-0,25	-0,12	3,01	14,61	16,34	5,36
\tilde{z} [m]	-0,14	-0,21	-0,24	-0,10	2,19	17,08	19,21	4,33
σ [m]	0,21	1,05	0,20	0,31	4,98	9,47	7,70	6,04

Tab. 5: Rozdíly mezi DMP 1G a DMP HDIM

	kleč 1	kleč 2	kleč 3	kleč 4	smrk1	smrk2	smrk3	smrk4
\bar{z} [m]	1,54	-0,89	2,90	0,68	-0,64	-0,14	-0,73	-2,03
\tilde{z} [m]	1,37	-1,00	2,63	0,71	-0,73	-0,23	-0,49	-1,27
σ [m]	2,82	1,19	2,83	1,67	4,75	5,05	3,81	7,07

Tab. 6: Rozdíly mezi DMP KRNAP a DMP HDIM

	kleč 1	kleč 2	kleč 3	kleč 4	smrk1	smrk2	smrk3	smrk4
\bar{z} [m]	1,66	-0,78	3,27	0,85	-3,40	-3,71	-15,71	-6,81
\tilde{z} [m]	1,58	-0,66	3,03	0,94	-0,98	-1,06	-18,98	-5,87
σ [m]	2,60	0,76	2,83	1,65	0,38	5,17	8,78	0,36

U porostu borovice kleče můžeme vidět mezi jednotlivými datovými sadami DMP 1G a DMP KRNAP poměrně malé rozdíly výšek pohybující se u všech lokalit do 0,3 m. DMP 1G je v tomto případě v průměru nižší než DMP z KRNAP. Tento jev může být způsoben

například rozdílnou hustotou porovnávaných dat. V modelu, kde je hustota 1,5 bodu/m², pravděpodobně nemohou být zdaleka všechny objekty, které jsou obsaženy v bodovém mračnu o hustotě 5 bodů/m². U další porovnávané dvojice – DMP 1G a DMP HDIM můžeme vidět podobný jev jako u poslední dvojice dat DMP KRNAP a DMP HDIM. Průměry rozdílů výšek se pohybují v kladných hodnotách (DMP 1G a DMP KRNAP jsou pod DMP HDIM) až na lokalitu kleč 2, která má hodnoty záporné. Rovněž u kleče 1 a kleče 3 průměry rozdílů přesahují hranici 1,5 m. V území kleč 2 může být rozdílnost oproti jiným územím způsobena tím, že se zde nachází větší počet smrků, které mohou hodnoty průměru markantně posunout. Problém u rozdílnosti dat HDIM může způsobovat také to, že smrk vrhá stín, čímž nedojde v daném místě ke korelaci obrazu. Proto jsou body na tomto místě buď doplněny interpolací, nebo chybí.

Dále bylo navrženo porovnat mezi sebou bodová mračna DMP pouze v území s porostem smrku a mimo něj. Bylo tedy využito výstupů z objektové klasifikace, při níž byl použit nDSM z HDIM. S každým územím se tedy rozdíly výšek počítaly dvakrát, jednou pro smrky a podruhé pro území mimo ně. Výsledky této analýzy můžeme vidět v následujících tabulkách 7 – 9.

Tab. 7: Průměrné rozdíly výšek při porovnání v porostu borovice kleče a mimo něj (porost oddělen objektovou klasifikací na základě optických dat – viz kapitola 4.6.1)

	KLEČ 1		KLEČ 2		KLEČ 3		KLEČ 4	
	porost [%]	bez porostu [%]	porost [%]	bez porostu [%]	porost [%]	bez porostu [%]	porost [%]	bez porostu [%]
	44,2	55,8	65,8	34,2	17,5	82,5	28,8	71,2
1G x KRNAP [m]	-0,40	1,01	-0,13	0,10	-0,32	-0,23	-0,15	-0,10
1G x LMS [m]	1,01	1,96	-1,02	-0,62	2,59	2,97	0,03	0,89
LMS x KRNAP [m]	2,05	1,98	-0,85	-0,66	3,07	3,27	0,25	1,01

Tab. 8: Průměrné rozdíly výšek při porovnání v porostu smrku ztepilého a mimo něj (porost oddělen objektovou klasifikací na základě nDSM KRNAP – viz kapitola 4.6.2)

	SMRK 1		SMRK 2		SMRK 3		SMRK 4	
	porost [%]	bez porostu [%]	porost [%]	bez porostu [%]	porost [%]	bez porostu [%]	porost [%]	bez porostu [%]
	27,4	72,6	88,6	11,4	92,9	7,1	32,0	68,0
1G x KRNAP [m]	3,29	2,76	15,86	4,84	17,32	5,24	5,48	5,27
1G x HDIM [m]	-2,91	-0,31	-0,47	3,68	-0,87	4,30	-9,20	-1,07
HDIM x KRNAP [m]	-5,54	-2,56	-14,24	-0,74	-15,89	-0,76	-8,32	-6,10

Tab. 9: Průměrné rozdíly výšek při porovnání v porostu smrku ztepilého a mimo něj (porost oddělen objektovou klasifikací na základě nDSM HDIM – viz kapitola 4.6.2)

	SMRK 1		SMRK 2		SMRK 3		SMRK 4	
	porost [%]	bez porostu [%]	porost [%]	bez porostu [%]	porost [%]	bez porostu [%]	porost [%]	bez porostu [%]
	47,9	52,1	90,7	9,3	96,9	3,1	64,2	35,8
1G x KRNAP [m]	4,65	1,43	15,47	5,05	16,62	7,25	6,56	3,03
1G x HDIM [m]	-3,07	0,18	-0,58	4,50	-0,99	6,57	-4,61	2,63
HDIM x KRNAP [m]	-7,49	-0,55	-14,05	-0,46	-16,35	-0,69	-10,91	-0,44

Z tabulek výše je zřejmé, že největší rozdíly mezi výškami bodových mračen se nachází v oblastech náležících porostu smrku. Tyto hodnoty jsou vyšší, než pokud jsou vypočteny pro celé území bez ohledu na porost. V oblastech bez vysokých stromů jsou naopak průměry rozdílů výšek nižší, což ukazuje, že data se od sebe nejvíce liší patrně v oblastech vysoké vegetace.

5.2 Porovnání rozdílů vytvořených rastrů

Bodové mračno převedené do TINu a následně rastru bylo dále porovnáváno ve dvou podobách. Nejprve samotné modely povrchu, dále pak vytvořené nDSM, které představují porosty v zájmových lokalitách.

Z modelů povrchu byly vytvořeny rastry, které byly mezi sebou odečteny. Vznikly tak rastry rozdílů výšek jednotlivých modelů. Vytvořené mapy rozdílů jsou v příloze 1 až 8. Díky zobrazení rozdílů můžeme vidět, ve kterých oblastech se od sebe modely nejvíce liší a kde na sebe modely nejlépe přiléhají.

V příloze 1 můžeme vidět, že mezi DMP 1G a DMP KRNAP se největší rozdíly nachází v oblastech porostu borovice kleče. DMP KRNAP je zde nad DMP 1G. V příloze 2 je jev podobný, v oblastech terénu jsou rozdíly nejmenší, nad porostem smrku ztepilého jsou pak rozdíly největší a dosahují zde vyšších hodnot než v prvním případě. DMP 1G je zde v oblastech porostu většinou nad DMP KRNAP. Rozdíly výšek mezi DMP 1G a DMP HDIM jsou vidět v příloze 3 a 4, opět největší rozdíly jsou v místech vegetace. DMP HDIM je tady vyšší než DMP 1 G, proto záporné hodnoty. Porovnání DMP HDIM a DMP KRNAP (přílohy 5 a 6) ukazuje, že DMP HDIM je ve většině míst vyšší než DMP KRNAP, což odpovídá i porovnání bodových mračen.

Rastr rozdílů výšek mezi DMP získaného pomocí HDIM a DMP získaného klasickou obrazovou korelací můžeme vidět v přílohách 7 a 8. V příloze 7 jsou rozdíly poměrně stejně rozloženy v celém území, největší se pak nachází v horní části v místech porostu borovice

kleče. V příloze 8 jsou největší rozdíly opět nad vegetací, v oblastech jednotlivých stromů se pak DMP HDIM nachází nad druhým DMP, v jejich blízkém okolí je pak opačný a rozdíly zde dosahují hodnot až několika metrů.

5.3 Objektová klasifikace

Výsledky objektové klasifikace můžeme vidět v přílohách 9 až 12. Jak bylo zmíněno výše, bez dat LLS nebo HDIM by nebylo možné odlišit od sebe borovici kleč a smrk ztepilý v jedné scéně. Rozdíly objektové klasifikace pouze na základě optických dat a objektové klasifikace, při níž byla využita výšková data, můžeme porovnat v přílohách 10 až 12. Výsledky objektové klasifikace založené pouze na optických datech u smrkových porostů nebyly vhodné k dalšímu použití, protože nedosahovaly dobrých výsledků, nejsou tedy přiloženy. Dále můžeme vidět, že mezi výsledky objektové klasifikace v porostu smrku ztepilého, při které byla použita data LLS a data HDIM obsahující výšky, není markantní rozdíl (přílohy 11 a 12).

5.4 Modely stromů a jejich výška

Výsledek výběru lokálního maxima můžeme vidět na příkladu vybraného smrku v obrázku 14. Jak je vidět, lokální maximum nalezené v datech KRNAP je nižší než maximum nalezené v datech HDIM.

V příloze 13 můžeme vidět, kde byla nalezena a vybrána lokální maxima představující vrcholky korun smrků. Dále jsou přiloženy geometrické modely některých smrků vytvořené na základě RANSAC algoritmu (přílohy 14 a 15), jedná se o dvojice stromů – první z nich je vytvořený na základě nDSM KRNAP a druhý na základě nDSM HDIM. V příloze 14 a 15 je také vidět, jak vypadalo původní bodové mračno, ze kterého byl poté vytvořen zjednodušený geometrický model. To, jak se mezi sebou lišily výšky stromů v jednotlivých lokalitách, můžeme vidět shrnuté v tabulce 10.

Vzhledem k tomu, že při použití kombinace dvou bodových mračen nDSM z DMP 1G a DMR 5G a nDSM HDIM nedošlo ke změnám nalezených maxim, není toto uvedeno ve výsledcích. Nalezená maxima ve všech případech odpovídala maximům nalezeným v nDSM HDIM. Tento jev je způsoben tím, že body HDIM jsou ve vrcholových partiích stromů vždy nad DMP 1G.



Obr. 14: Bodové mračno náležící jednomu stromu a nalezená maxima, zleva – smrk v datech HDIM + lokální maximum (červeně), smrk v datech LLS + lokální maximum (červeně), obě mračna najednou (HDIM tmavě zelená, maximum HDIM červeně, LLS světle zelená, maximum LLS žlutě).

Tab. 10: Rozdíly zjištěných výšek stromů z dat HDIM a dat KRNAP

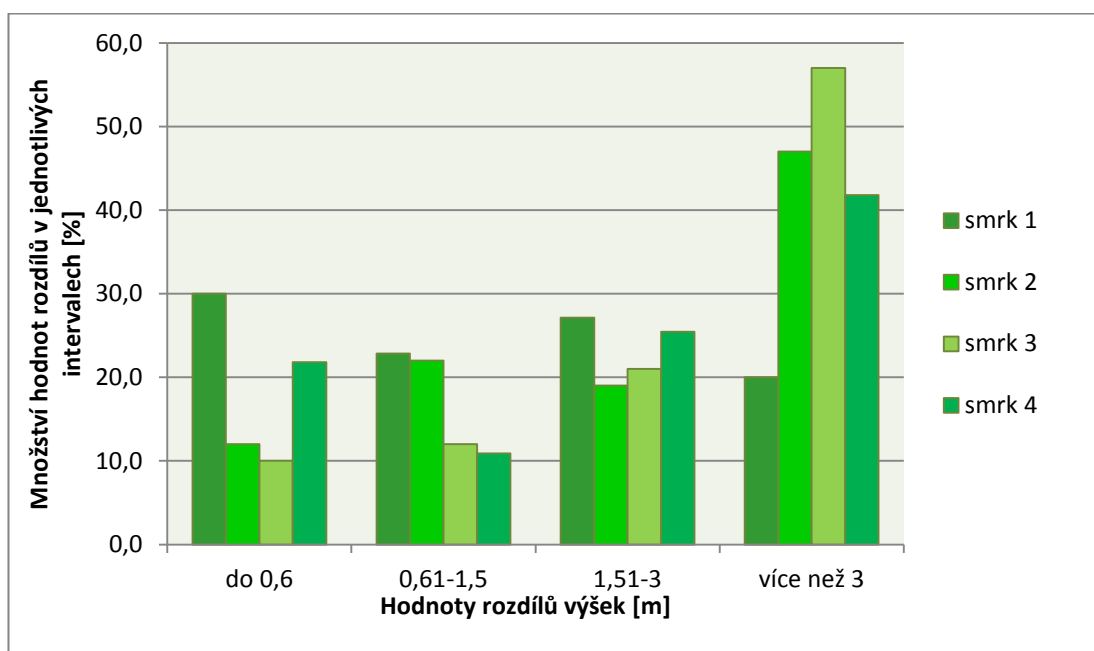
	smrk 1	smrk 2	smrk 3	smrk 4
\bar{z} [m]	1,47	2,68	3,22	2,44
σ [m]	1,83	1,86	1,74	2,93

Dále byly porovnávány četnosti jednotlivých rozdílů zjištěných výšek. Výsledky tohoto porovnání jsou shrnuty v grafu 1. Hodnoty rozdílů byly rozděleny do 4 intervalů.

Z grafu 1 vyplývá, že v lokalitě smrk 1 bylo zjištěno nejvíce hodnot rozdílů do 0,6 m oproti zbylým územím. Stejně tak výskyt odchylek nad 3 m je v této lokalitě nejnižší. Podobný jev můžeme vidět v tabulkách 8 a 9, kde jsou porovnána bodová mračna v celých zájmových územích. Hodnota průměrné hodnoty rozdílů výšek v lokalitě smrk 1 je podobná při porovnání celých bodových mračen i při porovnání rozdílů výšek stromů. Ve všech porovnáních totiž lokalita smrk 1 vykazuje mezi daty KRNAP a HDIM nejmenší rozdíly.

Poněkud rozdílný jev můžeme vidět v případě lokalit 2 a 4, kdy při porovnání celé lokality měla druhou nejnižší hodnotu průměru rozdílů mezi KRNAP a HDIM lokalita smrk 2. Při porovnání pouze samostatných stromů v menším vybraném území pak druhou nejnižší hodnotu průměru rozdílů má lokalita 4. Můžeme pozorovat slabý vztah mezi hodnotami

průměru rozdílů výšek a hustotou porostu. V lokalitách 1 a 4 jsou stromy řidší než v lokalitách 2 a 3. Proto můžeme usuzovat, že v hustších porostech je identifikace vrcholu stromu obtížnější, snadno zaměnitelná za jiný „vysoký“ bod, který ve skutečnosti není vrcholem stromu. Tomuto faktu odpovídá také četnost odchylek větších než 3 m u lokalit 2 a 3. V tomto intervalu se nachází více než 45 % rozdílů všech porovnávaných stromů.



Graf 1: Rozložení hodnot rozdílů v intervalech

Dále si můžeme povšimnout toho, že rozdíl výšek zřejmě závisí také na hustotě porostu. V územích 1 a 4 jsou stromy poměrně daleko od sebe, určení lokálního maxima je také poměrně úspěšné. V grafu je patrné, že tyto dvě území dosahovala daleko vyšší četnosti odchylek rozdílů výšek v intervalu do 0,6 m.


V přílohách 14 a 15 jsou zobrazeny vytvořené modely stromů. Je zde patrné, jak nastavený poloměr šířky koruny ovlivní výběr bodů. Data KRNAP tvoří jakýsi válec, jeho podstava je vidět na povrchu terénu. Data HDIM dopadají pouze malou částí až na terén, spíše zabírají svrchní část koruny, ale je zřejmé že jsou také ovlivněna výběrem bodů. Pro zjištění výšky stromu to není až tak podstatné, ale pokud by bylo třeba zajistit jiné charakteristiky stromu, například objem koruny, byl by to problém. Pokud se zase nastaví poloměr koruny větší, může se stát, že výběr bude obsahovat dva stromy tedy dvě maxima.

6 DISKUZE

6.1 Data

V první části metodického postupu bylo nutné mezi sebou porovnat několik datových sad, se kterými se pak dále pracovalo. K porovnání byl využit SW DTM Analyst, jehož funkce je blíže popsána v kapitole 4.3. Možné příčiny rozdílů mezi daty jsou shrnuty v následujících odstavcích.

Digitální model povrchu 1G je primárně vytvořen z dat leteckého laserového skenování. Některé oblasti byly snímány v jarním období a nebylo tak možné zachytit body na povrchu porostů. Proto bylo na ČÚZK přistoupeno k tomu, že data nacházející se uvnitř polygonů lesů v ZABAGED byla nahrazena body získanými obrazovou korelací (stereofotogrammetricky). Tyto body byly vytvořeny ÚHÚL a na základě výměny dat s ČÚZK byly tedy doplněny do dat LLS. V obrázku 15 můžeme vidět, že v oblastech, kde k tomuto doplnění došlo, jsou body v pravidelné mřížce.



Obr. 15: Body DMP 1G – v pravidelné mřížce doplněné ÚHÚL

Z odstavce výše je zřejmé, že průměrné hodnoty rozdílů mezi DMP 1G a DMP HDIM jsou takové proto, že tato data vznikla podobným způsobem – stereofotogrammetricky a metodou *high density image matching*.

Rozdíly mezi jednotlivými modely jsou ještě patrnější, pokud oddělíme zvlášť území, které bylo na základě objektové klasifikace zařazeno do třídy *kleč* a třídy *smrk*. V tabulkách 7 až 9 je vidět, že větší rozdíly v modelech se nachází přímo nad body představujícími porost. Nikoliv nad těmi, co představují terén.

Po důkladnější analýze DMP KRNAP bylo zjištěno následující. DMP KRNAP, použitý v této práci, velice často prochází vegetačním krytem až na zem, model získaný z LLS tedy neodpovídá přesně definici DMP. V té je uvedeno, že jde o speciální typ digitálního modelu terénu, ve kterém je obsažen reliéf a navíc povrch objektů na terénu (vegetace, jiné objekty) (slovník VÚGTK, 2017), protože paprsek proniká vegetací často až na terén a není tedy možné zachytit vegetaci. Za vegetaci je zde považován lesní porost či kosodřevina. V tomto případě jde nejspíše o zředěné mračno bodů, kdy byly vybrány nejvyšší body v mřížce 1x1 m. Oproti tomu DMP vytvořený z leteckých měřických snímků není podobným jevem ovlivněn, jelikož při tvorbě modelu se neřeší to, co je pod vegetací, řeší se pouze to, co je ve snímku. Proto terén pod vegetací vůbec neovlivňuje obsah bodového mračna.

Porovnáním bodových mračen z dat optických a laserových se zabývá White et al. (2013). Jako klíčový rozdíl mezi těmito daty uvádí schopnost laserových dat zasáhnout jak vegetaci, tak terén pod ní, zatímco bodová mračna z optických dat jsou omezena na charakterizování horní obálky lesa, což vychází ze samotného principu pořizování dat. Dále uvádí, že zpracovaná optická data mohou dostatečně zajišťovat odhady atributů lesních porostů jako je např. výška nebo objem, a to s přesností, která by byla dosažena i daty LLS.

6.2 Metodické řešení

6.2.1 Objektová klasifikace

Objektovou klasifikací na územích s lesními porosty se v dnešní době zabývá mnoho autorů (Sullivan et al., 2009; De Joinville, 2010; Mc Lean, Congalton, 2011). V této práci měla objektová klasifikace sloužit k tomu, aby byly odděleny jednotlivé porosty a následně vymezeny jednotlivé stromy. Většina autorů využívá ke klasifikaci nejen pásma RGB, ale také pásmo blízké infračervenému – NIR. S využitím NIR se dá vypočítat celá řada vegetačních indexů, které jsou pak více či méně vhodné ke stanovení klasifikačního pravidla. Použití pásma NIR by mohlo napomoci při oddělování jednotlivých segmentů korun smrků, které byly zasaženy stínem.

Podobně jako v této práci De Joinville (2010) využívá dvě úrovně segmentace. Nejprve byl obraz rozsegmentován s nastavením měřítkového parametru s vysokou hodnotou a segmenty byly rozklasifikovány do dvou tříd na *lesní porost* a *ostatní*. Následovala další úroveň segmentace, a poté další klasifikace, která již byla aplikována pouze na třídu lesního porostu. Na rozdíl od této práce však byla využita klasifikace řízená, tudíž byly manuálně vybírány trénovací plochy. Lesní porost byl pak rozklasifikován do pěti tříd na základě hodnot NIR (De Joinville, 2010). Další autoři se zabývali také objektovou klasifikací k identifikaci rozložení jednotlivých druhů stromů (Hájek, 2005; Král, 2015). Objektovou klasifikací borovice kleče ve své práci rozebírali Tremml et al. (2010). Rozdílem oproti této práci byla data, na základě kterých byla klasifikace provedena. Jednalo se o černobílé snímky ze dvou období, sledován byl vývoj porostu borovice kleče jako expanzivního druhu v Hrubém Jeseníku. Výsledkem klasifikace bylo získat dvě třídy a to třídu *kleč* a *ostatní* a posoudit odlišnosti výskytu borovice kleče v časové řadě. Objektově orientovaný přístup byl aplikován na historické snímky proto, že má lepší schopnosti klasifikovat obrazy s omezeným spektrálním rozlišením (Halounová, 2004). Podobně tomu bylo i v této práci, jelikož snímky obsahovaly pouze pásma RGB.

6.2.2 High density image matching

Metodu založenou na *high density image matching* ve svých pracích využívá čím dál tím větší množství výzkumníků (Haala, Rothermel, 2012; Haala, Cavegn, 2016 aj.). Důvodem je, že její výsledky mohou konkurovat datům LLS, která jsou jednat více ekonomicky náročná a nejsou pořizována v tak krátkém časovém intervalu.


Další výhodou metody *high density image matching* oproti klasické fotogrammetrii je možné využít najednou více snímků a získat tak husté bodové mračno, které vystihuje žádané objekty daleko lépe než pouze ze dvou snímků. Je také možné využít šikmých snímků a takto modelovat různé objekty. Pokud by bylo k vytvoření modelu povrchu využito více snímků překrývajících se v požadované lokalitě, mohlo by být dosaženo hustšího bodového mračna, které by ještě lépe vystihovalo objekty na zemském povrchu.

6.2.2 Fúze dat HDIM a LLS

Fúze dat laserového skenování a dat optických byla analyzována v několika studiích. Detailní analýzy poukázaly na fakt, že kombinace zmíněných dat vede k přesnějším odhadům charakteristik lesních porostů (Pari, Bruzzone, 2015). Laserová a optická data byla porovnávána také ve studii Erdodyho a Moskala (2010). Analýza proběhla na třech postupně vytvořených modelech. První model byl vytvořen pouze z dat LLS, druhý pouze z optických dat a právě poslední model byl vytvořen fúzí dat získaných z LLS a leteckých snímků (Erdody, Moskal, 2010). Data LLS poskytují velice přesné 3D body, ale nedostatek hran

(*breaklines*) a texturových informací. Naopak optická data s vysokým prostorovým rozlišením poskytují přesnější hrany a informace o textuře. Kombinací obou typů dat je možné odstranit většinu nevýhod, které jsou spojeny s jednou z metod získávání prostorových dat, díky kombinaci jsou kompenzovány metodou druhou (Hu et al., 2011).

V této práci však byla data získanými metodou HDIM doplňována data LLS, která měla hustotu 1,5 bodu/m². Zkoumána byla dále výška jednotlivých stromů, což by bylo pouze s daty LLS (DMP 1G) zcela nemožné. Kombinace obou bodových mračen však pro zjišťování výšky stromů neměla žádný přínos. Body LLS doplňovaly mračno HDIM v nižších partiích stromu, proto by tento krok mohl přinést vylepšení modelů stromů (Obr. 16) v případě, že by byla vyřešena problematika nastavení poloměru koruny, o které se pojednává v následující kapitole.



Obr. 16: Bodové mračno HDIM(zeleně) doplněné body z DMP 1G (červeně)

6.2.3 Identifikace jednotlivých stromů, nastavení poloměru koruny

Identifikace jednotlivých stromů měla být výsledkem objektové klasifikace. Základem tedy měla být optická data, podobně jako v práci Paris a Bruzzone (2015). Autoři identifikovali jednotlivé stromy a následně vymezovali jednotlivé koruny za pomoci optických dat, které dále kombinovali s daty LLS. Podobnou tematikou se zabývala práce Ke a Quackenbush (2011), jednalo se o porovnání jednotlivých algoritmů sloužících k vymezení stromů z optických dat s vysokým rozlišením. Algoritmy mohou být rozděleny do dvou hlavních skupin, první z nich jsou algoritmy sloužící k detekci jednotlivých stromů a druhou z nich pak algoritmy k vymezení koruny. Autoři dále uvádějí, že mnoho dalších autorů se snaží často tyto dva algoritmy propojit, podobně tomu je v této práci, kdy je nejprve detekováno umístění stromu, dále pak jeho vymezení, nikoliv však na základě optických dat.

V SW eCognition lze identifikovat jednotlivé stromy, pokud jsou pravidelně vysázeny a vypadají všechny zhruba stejně. Na základě vzorového výřezu, ve kterém jsou manuálně určeny vrcholy stromů, pak jsou dohledány všechny stromy v území. Suárez (2003) využívá kombinace SW eCognition a SW ArcView k identifikaci jednotlivých stromů z porostu. Proces obsahuje několik základních kroků, z nichž prvním je segmentace obrazu. Následuje pak export v podobě vektorů. Dále jsou tyto segmenty otevřeny v ArcView a poté jsou vybrány segmenty klasifikované jako smrky. Poslední fází je potom určení centroidů každého segmentu představujícího smrk, které jsou dále považovány za vrchol stromu.

Nakonec bylo přistoupeno k tomu, že za vrcholy jednotlivých stromů bude považováno vždy lokální maximum v bodovém mračnu. Vstupem však kromě bodového mračna byl také přibližný počet stromů zjištěný manuálně a také průměr koruny, což je určitý limit ve využití metodiky na větší lesní celky, kde stromy rostou nepravidelně. Algoritmus vyhledávající maxima by mohl být vylepšen tím, že by maxima nebyla hledána přímo v celém bodovém mračnu, ale využívalo by se posuvného okna. To by mělo velikost nastavenou podle poloměru korun v území. Podobně jako je popsáno v práci Chen et al. (2016), kde se v bodovém mračnu dat LLS vyhledává lokální maximum. Poloměr koruny je vypočten na základě následujícího vztahu (4):

$$\text{velikost koruny} = 1,7425 \cdot h^{0,5566}, \quad (4)$$

kde h je výška stromu zjištěná na základě měření ve výškovém modelu vegetace.

Algoritmus vymezující jednotlivé koruny smrků v této práci je omezen tím, že je pro celé území nastaven pouze jeden poloměr koruny, a to na základě manuálního měření ve snímcích. Tímto nedostatkem pak může být způsobeno to, že pokud se jedná o strom, který je vyšší než ostatní a má zároveň větší průměr koruny, nalezne se na jeho koruně další lokální maximum, které však nepředstavuje vrchol stromu. Na nastavení poloměru koruny dále závisí to, jak bude vybrané bodové mračno proloženo rotačním paraboloidem. Pokud se jedná o strom větší než je nastavený poloměr, body vybrané jako náležící stromu tvoří jakýsi válec, který neaproximuje reálný tvar stromu (přílohy 14 a 15).

Nastavení poloměru by mohlo být zpřesněno na základě vykreslení výškového profilu bodů nacházejících se mezi dvěma maximy. V nejnižším místě by pak byla zjištěna vzdálenost souřadnic x , y od lokálního maxima. Pokud by se toto provedlo mezi všemi okolními maximy, byly by zjištěny přibližné hranice jedné koruny.

6.2.5 RANSAC algoritmus

RANSAC algoritmus využitý v této práci aproximuje korunu smrku vymezenou na základě určení lokálního maxima a vybraných bodů v určité vzdálenosti souřadnic x , y od tohoto

maxima. Lokální maximum je zde bráno jako vrchol koruny, tedy její střed, pokud předpokládáme, že se jedná o středově souměrný strom. U dat získaných laserovým skenováním však není možné zjistit, zda bod, který je lokálním maximem, opravdu odpovídá vrcholu koruny. Je totiž pravděpodobné, že ve velké většině případů se paprsek neodrazil přesně od vrcholku koruny – to je spíše náhodný jev. Proto by bylo vhodné, aby u dat LLS nebylo považováno lokální maximum za vrchol stromu ani za jeho střed, protože pak dochází ke zkreslení výsledného modelu. Vylepšením by mohlo být to, že by vrchol vymodelovaného paraboloidu sice byl ve stejné výšce jako nalezené lokální maximum, ale nebyl by považován zároveň za střed koruny. Při RANSAC algoritmu by se pak hledalo nejlepší proložení paraboloidem všech bodů nezávisle na středu koruny. To by zřejmě přineslo aproximaci koruny smrku více vystihující skutečnost, než když je lokální maximum považováno za vrchol i střed koruny.

6.2.6 Výška stromu a další charakteristiky

V této práci je učení výšky stromu spojeno s nalezením lokálního maxima v nDSM představujícího vrchol koruny stromu. Hodnota souřadnice z tohoto maxima pak představuje výšku stromu.

Z odstavců výše vyplývá, že pro určení dalších charakteristik jednotlivých stromů či celých porostů je nutné znát poloměr koruny. Pokud by byl tento atribut zjištěn, například manuálně, bylo by možné vypočítat například výčetní tloušťku kmene, která je definována jako průměr kmene ve výšce 1,3 m nad zemí (ÚHÚL, 2003). K výpočtu je možné použít například regresní model (5) podle Heuricha (2008).

$$dbh = b_0 + b_1 \cdot v + b_2 \cdot r + b_3 \cdot v^2 + b_4 \cdot r^2, \quad (5)$$

kde $b_0 - b_4$ jsou konstanty regresního modelu, v je vypočtená výška stromu a r změřený poloměr koruny. Předpokladem úspěšnosti výpočtu modelu je kalibrace modelu, kterou je nutné provést na datech naměřených v terénu.

Na základě výčetní tloušťky kmene je možné dopočítat výčetní plochu kmene (plocha kruhu o výčetní tloušťce 1,3 m nad zemí). Potom lze stanovit plošně i výčetní plochu porostu (ÚHÚL, 2003).

Pokud by se objektovou klasifikací zajistilo oddělení jednotlivých korun stromů v porostu do segmentů, jak bylo nejprve zamýšleno v této práci. Mohl by pak být automaticky určován poloměr koruny a následně by mohla být vypočtena střední výška porostu, která charakterizuje výškovou vyspělost porostu. Je to výška průměrného stromu, který má průměrnou výčetní tloušťku kmene, průměrnou výčetní základnu nebo průměrný objem (ÚHÚL, 2003).

7 ZÁVĚR

Hlavním cílem této práce bylo navrhnout a ověřit metodiku využití bodového mračna vytvořeného z optických dat metodou *high density image matching* k modelování lesních porostů a zjišťování charakteristik na úrovni jednoho stromu a porovnání s metodou LLS. Závěrem je možné uvést, že použitá optická data s velikostí pixelu cca 25 cm mohou přinést podrobné informace o lesním porostu na takovéto úrovni. Bodové mračno vytvořené metodou *high density image matching* vystihuje dobře výškový model lesa – *canopy height model*. Proto je možné říci, že pokud je provedeno letecké laserové skenování s dostatečnou hustotou k vytvoření modelu reliéfu, je následně možné využít optická data, která jsou Českým zeměměřickým úřadem pořizována každé dva roky, ke sledování vývoje lesních porostů a charakteristik až na úroveň jednoho stromu.

Postup, který byl navržen k identifikaci korun stromů a jejich následnému vymezení by v takovéto podobě mohl být využitelný k inventarizaci porostů v hospodářských lesích, kde jsou v jednotlivých lokalitách stromy přibližně stejného stáří, a tudíž mají podobnou výšku a poloměr koruny. Další výzkum je zajisté možný v oblasti vymezení jednotlivých stromů v SW eCognition. Možnosti dalšího vylepšení zůstávají zajisté ve zpřesnění určení vrcholku koruny a také v nastavení poloměru koruny, který je v nepravidelném porostu proměnlivý.

LITERATURA

AZIZI, Z., NAJAFI, A., SOHRABI, H. (2014): Forest Canopy Density Estimating, Using Satellite Images. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 37, s. 1127–1130.

BACHMAN, C. G. (1979): Laser radar systems and techniques. Artech House, 203 s.

BADEA, D.; JACOBSEN, K. (2008): Filtering process of LIDAR data. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 37, s. 815–820.

BERALDIN, J. A.; BLAIS, F.; LOHR, U. (2010): Laser scanning technology. In: Vosselman, G., Maas, H.G. (eds.): Airborne and terrestrial laser scanning, CRC Press, 1. edition, s. 1–44.

CUKROV, G. (2013): Using Stereo Photogrammetry to Create Digital Elevation Models of Planetary Surfaces. Proceedings of The National Conference On Undergraduate Research, San José, 4 s.

ČÚŽK (2016a): Technická zpráva k digitálnímu modelu povrchu 1. generace [online]. [cit. 2017-02-25]. Dostupné z: https://geoportal.cuzk.cz/Dokumenty/TECHNICKA_ZPRAVA_DMP_1G.pdf

ČÚŽK (2016b): Technická zpráva k digitálnímu modelu reliéfu 5. generace.[online]. [cit. 2017-02-25]. Dostupné z: https://geoportal.cuzk.cz/Dokumenty/TECHNICKA_ZPRAVA_DMR_5G.pdf

ČÚŽK (2017a): Letecké měřické snímky – úvod [online]. [cit. 2017-02-25]. Dostupné z: [http://geoportal.cuzk.cz/\(S\(4k1hi2y5bqvww3gb0qguwv11\)\)/Default.aspx?mode=TextMeta&ext=lms&side=lms](http://geoportal.cuzk.cz/(S(4k1hi2y5bqvww3gb0qguwv11))/Default.aspx?mode=TextMeta&ext=lms&side=lms)

ČÚŽK (2017b): Ortofoto České republiky [online]. [cit. 2017-02-25]. Dostupné z: [http://geoportal.cuzk.cz/\(S\(0pizgmyo3upjd1i3yabswpng\)\)/Default.aspx?mode=TextMeta&metadataID=CZ-CUZK-ORTOFOTO-R&metadataXSL=full&side=ortofoto](http://geoportal.cuzk.cz/(S(0pizgmyo3upjd1i3yabswpng))/Default.aspx?mode=TextMeta&metadataID=CZ-CUZK-ORTOFOTO-R&metadataXSL=full&side=ortofoto)

DALPONTE, M., BRUZZONE, L., GIANELLE, D. (2011): A system for the estimation of single-tree stem diameter and volume using multireturn LiDAR data. IEEE Transactions on Geoscience and Remote Sensing, 49, s. 2479–2490.

DARWISH, A., LEUKERT, K., REINHARDT, W. (2003): Image Segmentation for the Purpose of Object-Based Classification. Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings. 2003 IEEE International, 3 s.

DE JOINVILLE, O. (2010): Forest Object-oriented Classification with Customized and Automatic Attribute Selection. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science, 38 (8), s. 669–674.

DOLANSKÝ, T. (2001): Laserové skenování – DMT za letu [online]. [cit. 2017-02-25]. Dostupné z: http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2001/Sbornik/Referaty/dolansky.htm

- DOLANSKÝ, T. (2004):** Lidary a letecké laserové skenování. Univerzita J. E. Purkyně, Ústí nad Labem, 100 s.
- ERDODY, T. L., MOSKAL, L. M. (2010):** Fusion of LiDAR and imagery for estimating forest canopy fuels. *Remote Sensing of Environment*, 114 (4), s. 725–737.
- ERIKSON, M. (2004):** Segmentation and Classification of Individual Tree Crowns in High Spatial Resolution Aerial Images. *Acta Universitatis agriculturae Sueciae. Silvestria*, 320 s.
- EYSN, L., HOLLAUS, M., SCHADAUER, K., RONCAT, A. (2011):** Crown coverage calculation based on ALS data. *Proceedings of SilviLaser 2011, 11th International Conference on LiDAR Applications for Assessing Forest Ecosystems*, s. 1–10.
- GINZLER, C., HOBI, M. L. (2015):** Countrywide stereo-image matching for updating digital surface models in the framework of the Swiss national forest inventory. *Remote Sensing*, 7(4), s. 4343–4370.
- HAALA, N., ROTHERMEL, M. (2012):** Dense Multi-Stereo Matching for High Quality Digital Elevation Models. *PFG Photogrammetrie, Fernerkundungm Geoinformation*, s. 331–343.
- HAALA, N., CAVEGN, S. (2016):** High Density Aerial Image matching: State-of-the-Art and Future Prospects. *The International Archives of the Photogrammetry. Remote Sensing and Spatial Information Sciences*, 41, s. 625–630.
- HÁJEK, F. (2005):** Object - Oriented Classification of Remote Sensing Data for the Identification of Tree Species Composition. Department of Forestry Management, Faculty of Forestry and Environment CUA Prague, 5 s.
- HÁJEK, F., ADOLT, R., TOMANČÁK, O., STUDENÁ, K., KANTOROVÁ, M. (2015):** Využití digitální stereofotogrammetrie jako podpůrných dat pro automatizovanou tvorbu lesnických tematických map [online]. *Symposium GIS Ostrava 2015, Technická univerzita Ostrava* [cit. 2017-10-30]. Dostupné z: http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2015/sbornik/papers/gis2015541fc2eee0551.pdf
- HALOUNOVÁ, L. (2004):** The automatic classification of b&w photos. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34, 6 s.
- HEURICH, M. (2008):** Automatic recognition and measurement of single trees based on data from airborne laser scanning over the richly structured natural forests of the Bavarian Forest National Park. *Forest Ecology and Management*, 255(7), s. 2416–2433.
- HIRSHMÜLLER, H. (2005):** Accurate and efficient stereo processing by Semi Global Matching an Mutual Information. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, San Diego, CA, USA, June 20-26, 2005, 8 s.
- HÖHLE, J., BAYER T., POTŮČKOVÁ, M. (2009):** Automated checking methods of the Digital Terrain Models based on TIN. 29th conference on geometry and computer graphics (JCMF 2009).
- HÖFLE, B., HOLLAUS, M. (2010):** Urban vegetation detection using high density full-waveform airborne lidar data-combination of object-based image and point cloud analysis. *International archives of photogrammetry, remote sensing and spatial information sciences*, 38, s. 281–286.

- HOWARD, J. A. (1991):** Remote Sensing of Forest Resources, theory and application, Chapman & Hall, London, England, 422 s.
- HROUN, V. (2012):** Klasifikace leteckých barevných snímků za použití dat leteckého laserového skenování. Diplomová práce, České vysoké učení technické, Katedra mapování a kartografie, Praha, 46 s.
- HU, X., ZHU, J., YE, L. (2011):** Combined segmentation of lidar point cloud and registered images. ASPRS 2011 Annual Conference Milwaukee, Wisconsin, 8 s.
- HUANG, Y., YU, B., ZHOU, J., HU, C., TAN, W., HU, Z., WU, J. (2013):** Toward automatic estimation of urban green volume using airborne LiDAR data and high resolution remote sensing images. *Front. Earth Sciences*, 7, s. 43–54.
- HYYPÄ, J., INKINEN, M. (1999):** Detecting and estimating attributes for single trees using laser scanner. *Photogrammetric Journal Finland*, 16, s. 27–42.
- CHEN, Q., BALDOCCHI, D., GONG, P., KELLY, M. (2006):** Isolating Individual Trees in a Savanna Woodland Using Small Footprint Lidar Data, *Photogrammetric Engineering & Remote Sensing*, 8, s. 923–932.
- CHUST, G., GALPARSORO, I., BORJA, Á., FRANCO, J., URIARTE, A. (2008):** Coastal and estuarine habitat mapping, using LIDAR height and intensity and multi-spectral imagery. *Estuarine, Coastal and Shelf Science*, 78, s. 633–643.
- JARVIS, A. (2008):** Integration of Photogrammetric and LiDAR Data for Accurate Reconstruction and Visualization of Urban Environments. University of Calgary, 177 s.
- JOHN, J. (2011):** Letecké laserové skenování (ALS/LIDAR) a možnosti jeho využití v archeologii – úvodní informace o projektu. Počítačová podpora v archeologii III, Západočeská univerzita v Plzni, Plzeň, 28 s.
- KE, Y., QUACKENBUSH, L. J. (2011):** A comparison of three methods for automatic tree crown detection and delineation from high spatial resolution imagery. *International Journal of Remote Sensing*, 32, s. 3625–3647.
- KRÁL, K. (2009):** Classification of current vegetation cover and Alpine treeline ecotone in the Praděd Reserve (Czech Republic), using remote sensing. *Mountain Research and Development* 29, s. 177–183.
- KRAUS, K., PFEIFER, N. (1998):** Determination of terrain models in wooded areas with airborne laser scanner data [online]. *ISPRS Journal of photogrammetry and remote sensing*, 53 (4), s. 193–203 [cit. 2017-02-24]. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0924271698000094>
- LEVIN, A., WEISS, Y. (2009):** Learning to Combine Bottom-Up and Top-Down Segmentation. *International Journal of Computer Vision*, 81(1), s. 105–118.
- LI, W., GUO, Q., JAKUBOWSKI, M. K., KELLY, M. (2012):** A New Method for Segmenting Individual Trees from the Lidar Point Cloud. *Photogrammetric Engineering & Remote Sensing*, 1(1), s. 75–84.
- LIANG, X., WANG, Y., JAAKKOLA, A., KUKKO, A.; KAARTINEN, H., HYYPPÄ, J., HONKVAARA, E., LIU, J. (2015):** Forest Data Collection Using Terrestrial Image-

Based Point Clouds from a Handheld Camera Compared to Terrestrial and Personal Laser Scanning. *IEEE Transactions on Geoscience and Remote Sensing*, 53, s. 5117–5132.

LINDBERG, E., HOLMGREN, J. (2017): Individual Tree Crown Methods for 3D Data from Remote Sensing. *Current Forestry Reports*, 3(1), s. 19–31.

MAGNUSSEN, S., BOUDEWYN, P. (1998): Derivations of stand heights from airborne laser scanner data with canopy-based quantile estimators. *Canadian Journal of Forest Research*, 28(7), s. 1016–1031.

MALTAMÖ, M., PACKALEN, P., PEUHKURINEN, J., SUVANTO, A., HYYPPÄ, J. (2007): Experiences and possibilities of ALS based forest inventory in Finland, University of Joensuu, 9 s.

McCOMBS, J. W., ROBERTS, S. D., EVANS, D. L. (2003): Influence of fusing lidar and multispectral imagery on remotely sensed estimates of stand density and mean tree height in a managed loblolly pine plantation. *Forest Science*, 49(3), s. 457–466.

McINTOSH, A., GRAY, A., GARMAN, S. (2012): Estimating canopy cover from standard forest inventory measurements in western Oregon. *Scientific Journal (JRNL)*, 58(2), s. 154–167.

McLEAN, M. G., CONGALTON, R. G. (2011): Using Object-oriented classification to map forest community types [online]. Department of Natural Resources & the Environment University of New Hampshire, 10 s. [cit. 2017-11-15]. Dostupné z: <http://www.asprs.org/wp-content/uploads/2010/12/MacLean.pdf>

MIKITA, T., KLIMÁNEK, M., CIBULKA, M. (2013): Hodnocení metod interpolace dat leteckého laserového skenování pro detekci stromů a měření jejich výšek. *Zprávy lesnického výzkumu*, 2013 (2), s. 99–106.

MORS DORF, F., MEIER, E., KÖTZ, B., ITTEN, K. I., DOBBERTIN, M., ALLGÖWER, B. (2004): LiDAR-based geometric reconstruction of boreal type forest stands at single tree level for forest and wildland fire management. *Remote Sensing of Environment*, 92 (3), s. 353–362.

NÆ SSET, E. (1997): Determination of mean tree height of forest stands using airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 52(2), s. 49–56.

ORŠULÁK, T., PACINA, J. (2012): 3D MODELOVÁNÍ A VIRTUÁLNÍ REALITA [online]. 2001 [cit. 2017-02-25]. Dostupné z: < <http://cevramok.ujep.cz/files/opora-3.pdf> >

PARIS, C.; BRUZZONE, L. (2015): A Three-Dimensional Model-Based Approach to the Estimation of the Tree Top Height by Fusing Low-Density LiDAR Data and Very High Resolution Optical Images. *IEEE Transactions on Geoscience and Remote Sensing*, 53(1), s. 467–480.

PAVELKA, K. (2003): Fotogrammetrie 10. České vysoké učení technické v Praze, Praha, 194 s.

PAVELKA, K. (2006): Laserové skenování – nová technologie sběru prostorových dat. České vysoké učení technické v Praze, Praha, 32 s.

PERSSON, Å., HOLMGREN, J., SÖDERMAN, U. (2002): Detecting and measuring individual trees using an airborne laser scanner. *Photogrammetry Engineering Remote Sensing.*, 68, s. 925–932.

POKORNÝ, T. (2013): Koregistrace dat leteckého laserového skenování a leteckých měřických snímků. Diplomová práce, Přírodovědecká fakulta Univerzity Karlovy, katedra aplikované geoinformatiky a kartografie, Praha, 79 s.

POPESCU, S. C., WYNNE, R. (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), s. 589–604

POTŮČKOVÁ, M. (2004): Image matching and its applications in photogrammetry. Aalborg: Institut for Samfundsudvikling og Planlægning, Aalborg Universitet. (ISP-Skriftserie; No. 314).

PUCHRIK, L., NÝDRLE, J. (2013): Snímkování a letecké laserové skenování Krkonošského národního parku. *Geodis news*, 12(1), s. 24.

REITBERGER, J., SCHNÖRR, C., KRZYTEK, P., STILLA, U. (2009): 3D segmentation of single trees exploiting full waveform LIDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(6), s. 561–574.

REMONDINO, F., EL-HAKIM, S.F., GRUN, A., ZHANG, L. (2008): Turning images into 3-D models - development and performance analysis of image matching for detailed surface reconstruction of heritage objects. *IEEE Signal Processing Magazine*, 25(4), s. 55–65.

REMONDINO, F., DEL PIZZO, S., KERSTEN, T., TROISI, S. (2012): Low-cost and open-source solutions for automated image orientation – A critical overview. *Proc. Euromed 2012*, s. 40–54.

REMONDINO, F., SPERA, M. G., NOCERINO, E., MENNA, F., NEX, F. (2014): State of the Art in High Density Image Matching. *The Photogrammetric Record*, 29(146), s. 144–166.

RÖNNHOLM, P., HONKAVAARAM E., LITKEY, P., HYYPPÄ, H., HYYPPÄ, J. (2007): Integration of Laser Scanning and Photogrammetry. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36, s. 355–362

RÖNNHOLM, P. (2010): Registration Quality – Towards Integration of Laser Scanning and Photogrammetry. Final Report, Euro SDR Project, Aalto University School of Engineering, Finland.

ROTHERMEL, M., WENZEL, K., FRITCH, D., HAALA, N. (2012): SURE: Photogrammetric Surface Reconstruction from Imagery. *Proceedings LC3D Workshop, Berlin*, 9 s.

ROTHERMEL, M. (2015): Oblique image processing in SURE: first experiments and results [online]. nFrames [cit. 2017-02-25].

RUTZINGER, M., HÖFLE, B., HOLLAUS, M., PFEIFER, N. (2008): Object-based point cloud analysis of full-waveform airborne laser scanning data for urban vegetation classification. *Sensors*, 8 (8), s. 4505–4528.

SHAN, J.; TOTH, C. (2008): Topographic laser ranging and scanning: principles and processing. CRC Press, 590 s.

SCHENK, T. (1999): Digital photogrammetry. TerraScience, 428 s.

SCHENK, T.; CSATHÓ, B. (2002): Fusion of LIDAR data and aerial imagery for a more complete surface description [online]. 8 s., [cit. 2017-03-01], Dostupné z: <http://www.isprs.org/proceedings/xxxiv/part3/papers/paper179.pdf>

SEDLÁČKOVÁ, O. (2014): Modelování vybraných geometrických charakteristik lesních porostů z dat LLS. Diplomová práce, Přírodovědecká fakulta Univerzity Karlovy, katedra aplikované geoinformatiky a kartografie, Praha, 2014, 69 s.

SIMA, M. C., NUCHTER, A. (2012): An extension of the Felzenszwalb-Huttenlocher segmentation to 3D point clouds. In: Proceedings of 2012 5th International Conference on Machine Vision (ICMV 12), Wuhan, China, 20–21 October 2012.

SMITH, S. L., HOLLAND, D. A., LONGLEY, P. A. (2004): The importance of understanding error in LiDAR digital elevation models. Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci., 35, s. 996–1001.

SOOYOUNG, K., MCGAUGHEY, R. J., ANDERSEN, H. E., SCHREUDER, G. (2009): Tree species differentiation using intensity data derived from leaf-on and leaf-off airborne laser scanner data. Remote Sensing of Environment, 113 (8), s. 1575–1586.

SUÁREZ, J. C., ONTIVEROS, C., SMITH, S., SNAPE S. (2005): Use of airborne LiDAR and aerial photography in the estimation of individual tree heights in forestry. Computers & Geosciences, 31, s. 253–262.

SUÁREZ, J. C. (2013): Tree counting analysis using eCognition. Forest Research [online]. 18 s. [cit. 2017-11-15], Dostupné z: [https://www.forestry.gov.uk/pdf/tree_counting_with_e-cognition.pdf/\\$file/tree_counting_with_e-cognition.pdf](https://www.forestry.gov.uk/pdf/tree_counting_with_e-cognition.pdf/$file/tree_counting_with_e-cognition.pdf)

SULLIVAN, A., MCGAUGHEY, R. J., ANDERSEN, H. E., SCHIESS, P. (2009): Object-oriented classification of forest structure from light detection and ranging data for stand mapping. Western Journal of Applied Forestry. 24(4), s. 198–204.

ŠÍMA J. (2009): Abeceda leteckého laserového skenování. *Geobusiness*, 8(3), s. 22–25.

TIEDE, D., HOCHLEITNER, G., BLASCHKE, T. (2005): A full GIS-based workflow for tree identification and tree crown delineation using laser scanning. In Proceedings of the ISPRS Workshop CMRT 2005: Object Extraction for 3D City Models, Road Databases and Traffic Monitoring - Concepts, Algorithms, and Evaluation, Vienna, Austria, 29–30 August 2005.

TITTMANN, P., SHAFFI, S., HARTSOUGH, B., HAMANN, B. (2011): Tree detection and delineation from LIDAR point clouds using RANSAC. Proceedings of SilviLaser 2011, 11th International Conference on LiDAR Applications for Assessing Forest Ecosystems, s. 1–23.

TERMINOLOGICKÝ SLOVNÍK ZEMĚMĚŘICTVÍ A KATASTRU NEMOVITOSTÍ (2017): Digitální model povrchu [online]. [cit. 2017-11-15], Dostupné z: http://www.vugtk.cz/slovník/termin.php?jazykova_verze=cz&tid=1049&l=digitalni-model-povrchu

TREML, V., WILD, J., CHUMAN, T., POTŮČKOVÁ, M. (2010): Assessing the change in cover of non-indigenous dwarf-pine using aerial photographs, a case study from the Hrubý Jeseník Mts., the Sudetes. *Journal of Landscape Ecology*, 3(2), s. 90–104.

ÚHÚL Brandýs nad Labem (2003): Inventarizace lesů v České republice 2001–2004 [online]. Ústav pro hospodářskou úpravu lesů Brandýs nad Labem, 136 s., [cit. 2017-10-29] Dostupné z: <<http://www.uhul.cz/nase-cinnost/narodni-inventarizace-lesu/prvni-cyklus-2001-2004>>.

ÚHÚL (2014): Projekt Národní inventarizace lesů. Ústav pro hospodářskou úpravu lesů Brandýs nad Labem [online]. [cit. 23. 1. 2017] Dostupné z: <http://nil.uhul.cz/uvodni-informace/projekt-nil>.

VOSSELMAN, G., MAAS, H. G. (2010): Airborne and Terrestrial Laser Scanning. Whittles Publishing, 318 s.

WASER, L. T., GINZLER, C., KUECHLER, M., BALTSAVIAS, E., HURNI, L. (2011): Semi-automatic classification of tree species in different forest ecosystems by spectral and geometric variables derived from Airborne Digital Sensor (ADS40) and RC30 data. *Remote Sensing of Environment*, 115(1), 76–85.

WEHR, A., LOHR, U. (1999): Airborne laser scanning – an introduction and overview. *ISPRS Journal of Photogrammetry & Remote Sensing*, 54 (2–3), s. 68–82.

WHITE, J. C., WULDER, M. A., VASTARANTA, M., COOPS, N. C., PITT, D., WOODS, M. (2013): The Utility of Image-Based Point Clouds for Forest Inventory: A Comparison with Airborne Laser Scanning. *Forests*, 4(3), s. 518–536.

WULDER, M. A., BATER, C. W., COOPS, N. C., HILKER, T., WHITE, J. C. (2008): The role of LiDAR in sustainable forest management. *Forestry Chronicle*, 84(6), s. 807–826.

YEN, L. C., DAMAN, D., SHAFRY, M., RAHIM, M. (2006): Image Matching Using Relational Graph Representation. *Proceedings of the First International Conference on Computer Graphics Theory and Applications*, s. 400–406.

ZHANG, C., ZHOU, Y., QIU, F. (2015): Individual Tree Segmentation from LIDAR Point Clouds For Urban Forest Inventory. *Remote Sensing*, 7(6), s. 7892–7913.

Seznam příloh

- Příloha 1: Rozdíly mezi DMP 1G a DMP KRNAP, KLEČ 2
- Příloha 2: Rozdíly mezi DMP 1G a DMP KRNAP, SMRK 1
- Příloha 3: Rozdíly mezi DMP 1G a DMP HDIM, KLEČ 2
- Příloha 4: Rozdíly mezi DMP 1G a DMP HDIM, SMRK 1
- Příloha 5: Rozdíly mezi DMP KRNAP a DMP HDIM , KLEČ 2
- Příloha 6: Rozdíly mezi DMP KRNAP a DMP HDIM , SMRK 1
- Příloha 7: Rozdíly mezi DMP HDIM a DMP vytvořeným obrazovou korelací, KLEČ 2
- Příloha 8: Rozdíly mezi DMP HDIM a DMP vytvořeným obrazovou korelací, SMRK 1
- Příloha 9: Výsledky objektové klasifikace založené pouze na optických datech, KLEČ 1
- Příloha 10: Výsledky objektové klasifikace založené na optických datech a nDSM KRNAP KLEČ 1
- Příloha 11: Výsledky objektové klasifikace založené nDSM KRNAP SMRK 1
- Příloha 12: Výsledky objektové klasifikace založené na nDSM HDIM, SMRK 1
- Příloha 13: Nalezená lokální maxima
- Příloha 14: Ukázka modelu smrku ztepilého 1
- Příloha 15: Ukázka modelu smrku ztepilého 2