

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE  
FAKULTA LESNICKÁ A DŘEVAŘSKÁ  
KATEDRA HOSPODÁŘSKÉ ÚPRAVY LESŮ



Fakulta lesnická  
a dřevařská

# Možnosti využití bezpilotních prostředků v praxi hospodářské úpravy lesů

Disertační práce

**Doktorand:** Ing. Jaroslav Kubišta

**Školitel:** doc. Ing. Peter Surový, PhD.

2022

## Zadání



**Česká zemědělská univerzita v Praze  
Fakulta lesnická a dřevařská**

### **ZADÁNÍ DISERTAČNÍ PRÁCE**

Autor práce:	Ing. Jaroslav Kubišta
Studijní program:	Lesní inženýrství
Obor:	Hospodářská úprava lesa
Vedoucí práce:	doc. Ing. Peter Surový, PhD.
Garantující pracoviště:	Katedra hospodářské úpravy lesů
Jazyk práce:	Čeština
Název práce:	<b>Možnosti využití bezpilotních prostředků v praxi hospodářské úpravy lesů</b>
Název anglicky:	<b>Possibilities of the use of unmanned aerial vehicles in the practice of forest management</b>
Cíle práce:	Ověřit jakým způsobem ovlivňují vnější podmínky kvalitu obrazových dat pořízených prostřednictvím vybraného bezpilotního prostředku (UAV). Dále zjistit, zda tyto podmínky mají také vliv na kvalitu fotogrammetrických bodových mračen odvozených z obrazových dat pořízených prostřednictvím UAV. Ověřit zda kvalita fotogrammetrického mračenja ovlivňuje spolehlivost jejich využití pro identifikaci jednotlivých stromů v lesním porostu a pro odhad vybraných dendrometrických veličin (počet stromů, výška porostu apod.).
Metodika:	Pořídit snímky pomocí komerčně dostupného UAV pro ověření prostorového rozlišení v závislosti na vnějších podmínkách. Rekonstruovat metodou Structure from Motion fotogrammetrická bodová mračenja odvozená ze snímků z UAV pořízených v proměnlivých vnějších podmínkách pro dvě vybrané lokality. Pro rekonstrukci využít více možností v rámci dostupných programů. Posoudit kvalitativní parametry těchto bodových mračen. Pomocí detekce jednotlivých stromů ve fotogrammetrických mračenech posoudit vliv vnějších podmínek při pořízení snímků a zpracování bodových mračen na proces identifikace jednotlivých stromů v mračnu a tím na odhad počtu stromů, průměrné a maximální výšky porostu.
Doporučený rozsah práce:	70 - 80 stran včetně grafů a tabulek
Klíčová slova:	UAV, DAP, Prostorové rozlišení, Identifikace jednotlivého stromu
Doporučené zdroje informací:	<ol style="list-style-type: none"><li>DANDOIS, Jonathan P. a Erle C. ELLIS, 2013. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. <i>Remote Sensing of Environment</i> [online]. 136, 259–276 [vid. 2017-07-03]. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2013.04.005</li><li>GOODBODY, Tristan R.H., Nicholas C. COOPS, Peter L. MARSHALL, Piotr TOMPALSKI a Patrick CRAWFORD, 2017. Unmanned aerial systems for precision forest inventory purposes: A review and case study. <i>Forestry Chronicle</i> [online]. 93(1). ISSN 00157546. Dostupné z: doi:10.5558/tfc2017-012</li><li>HONKAVAARA, E., J. JAAKKOLA, L. MARKELIN a S. BECKER, 2006. Evaluation of resolving power and MTF of DMC. <i>International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences</i>. 36. ISSN 17689791.</li><li>IGLHAUT, Jakob, Carlos CABO, Stefano PULITI, Livia PIERMATTEI, James O'CONNOR, Jacqueline ROSETTE, A Ac UK a Gonzalo GUTIÉRREZ QUIRÓS, 2019. Structure from Motion Photogrammetry in Forestry: a Review [online]. [vid. 2020-01-03]. Dostupné z: doi:10.1007/s40725-019-00094-3</li><li>ORYCH, A, 2015. Review of methods for determining the spatial resolution of UAV sensors. In: <i>International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives</i> [online]. s. 391–395 [vid. 2019-05-07]. ISSN 16821750. Dostupné z: doi:10.5194/isprsarchives-XL-1-W4-391-2015</li></ol>
Předběžný termín:	2021/22 ZS - FLD - SDZ

## **Anotace**

Disertační práce zkoumá možnosti využití obrazových dat, získaných prostřednictvím malého dostupného bezpilotního prostředku, pro odvození základních dendrometrických informací o lese s potenciálem využití v rámci hospodářské úpravy lesa.

Zejména cílí na ověření vlivu různých vnějších podmínek během pořízení obrazových dat na jejich kvalitu, stejně jako na kvalitu produktů vzešlých z těchto dat, konkrétně fotogrammetrických mračen a také na kvalitu dendrometrických údajů odvozených z těchto mračen.

Skutečné prostorové rozlišení digitálních snímků zjištěné pomocí kalibračního cíle Siemens star dosahovalo v průměru 2,2násobek teoretického prostorového rozlišení. Skutečné prostorové rozlišení bylo významně ovlivněno letovou výškou bezpilotního prostředku, stejně jako světelnými podmínkami a rychlostí letu.

Z obrazových dat, pořízených prostřednictvím bezpilotního prostředku za proměnlivých vnějších podmínek, byla pomocí postupu Structure from Motion rekonstruována fotogrammetrická bodová mračna (DAP). Jejich prostorová přesnost byla porovnána s referenčním bodovým mračnem získaným pomocí leteckého laserového skenování (ULS). Průměrná vzdálenost bodů od referenčního mračna nabývala hodnoty 0,3 m. Rostoucí výška letu měla negativní vliv na hustotu bodů i prostorovou přesnost odvozeného DAP mračna, nicméně i DAP mračna z nejvyšší letové hladiny 150 m dosahovala stále přijatelné odchylky 0,64 m od referenčního ULS mračna.

DAP mračna byla rekonstruována pomocí dvou rozdílných programů. Komerční Metashape vytvářel v základním nastavení mračna s vyšší hustotou bodů než open-source varianta WebODM. Naopak mračna vzniklá ve WebODM vykazovala lepší prostorovou přesnost. Vliv odlišných světelných podmínek, ani rychlosti letu na prostorovou přesnost bodového mračna se nepotvrdil jako významný.

Pro stanovení šířky plovoucího okna procedury Local Maximum Filter, sloužící k identifikaci jednotlivých stromů v rámci bodového mračna, byl na základě dat Národní inventarizace lesů připraven lineární model se smíšenými efekty odvozující šířku koruny na základě výšky stromu. Tento model byl kalibrován pro výzkumnou lokalitu na základě různých počtů kalibračních vzorků. Jako neoptimalnější se potvrdil model kalibrováný pomocí 5 vzorků.

LMF metodou odhadované počty stromů jak v rámci referenčního ULS tak v rámci DAP bodových mračen byly v porovnání s pozemním měřením nižší. Průměrná relativní chyba dosahovala hodnoty -0,23 u ULS mračna a -0,46 u DAP mračen. Tato chyba se významně lišila podle výšky porostu. Nejhorší výsledky byly jak u ULS, tak u DAP mračen ve výškové kategorii 5-10 m, nejlepší naopak u kategorie 20-30 m.

## **Klíčová slova**

**UAV, Structure from Motion, lokální kalibrace smíšeného modelu šířky koruny, ITD, LMF, dendrometrie, prostorové rozlišení, Siemens star, GRD, WebODM,**

## Annotation

This thesis investigates the possibilities of using image data obtained by a small unmanned aerial vehicle to derive basic dendrometric information about the forest that can be used for forest management.

In particular, the influence of different external conditions during the acquisition of the image data on their quality as well as on the quality of the products derived from these data, namely photogrammetric clouds and last but not least the quality of the dendrometric data derived from these clouds, was verified.

The Siemens star calibration target was successfully used to verify the actual spatial resolution of the digital images. The actual spatial resolution was on average 2.2 times the theoretical spatial resolution. The actual spatial resolution was significantly affected by the flight altitude of the drone as well as the lighting conditions and the flight speed.

Photogrammetric (DAP) point clouds were reconstructed from image data acquired by an unmanned vehicle under variable external conditions using the Structure from Motion method. Their spatial accuracy was compared with a reference point cloud obtained by unmanned aerial laser scanning (ULS). The average distance of the points from the reference cloud was 0.3 m. Increasing flight altitude negatively affected the point density and spatial accuracy of the derived DAP cloud, but even DAP clouds from the highest flight altitude of 150 m still achieved an acceptable deviation of 0.64 m from the ULS reference cloud.

DAP clouds were reconstructed with two different programs commercial Metashape in the basic settings produced clouds with a higher point density than the open-source variant WebODM. On the contrary, the clouds formed in WebODM showed better spatial accuracy.

The influence of different illumination conditions and flight speed on the spatial accuracy of the point cloud was not confirmed to be significant.

To determine the width of the floating window of the Local Maximum Filter procedure used to identify individual trees within the point cloud, a linear mixed effects model based on National Forest Inventory data was created that derived canopy width from tree height. This model was calibrated for the research site using a different number of calibration samples.

The model calibrated with 5 samples was found to be the most optimal.

The number of trees estimated by the LMF method was lower than the ground measurements in both the reference ULS and the point clouds from DAP. The average relative error of tree count was -0.23 for ULS clouds and -0.46 for DAP clouds. This error varied considerably depending on the height of the trees. The worst results for both ULS and DAP were obtained in the 5-10m height category, and the best in the 20-30m category.

## Prohlášení

Prohlašuji, že jsem disertační práci na téma **Možnosti využití bezpilotních prostředků v praxi hospodářské úpravy lesů** vypracoval samostatně pod vedením doc. Ing. Petera Surového, Ph.D. Dále prohlašuji, že jsem uvedl veškeré literární prameny a publikace, ze kterých jsem čerpal. Jsem si vědom, že zveřejněním disertační práce souhlasím s jejím zveřejněním dle zákona č. 111/1998 Sb. o vysokých školách v platném znění, a to bez ohledu na výsledek její obhajoby.

V Praze dne 03.12.2021

.....  
Ing. Jaroslav Kubišta

## **Poděkování**

Především bych velmi rád poděkoval svému školiteli, doc. Ing. Peteru Surovému, Ph.D. za jeho vedení v průběhu celého mého studia, řadu cenných rad a nespočet konzultací – bez vás by to nebylo možné.

Mé poděkování také patří všem kolegům, se kterými jsem měl tu čest pracovat a diskutovat, zejména musím vyzdvihnout Radima Adolta za jeho příkladnou trpělivost a vstřícnost.

V neposlední řadě chci poděkovat mé rodině a blízkým za podporu, díky níž jsem mohl toto studium uskutečnit.

# Obsah

<b>1</b>	<b>ÚVOD</b> .....	<b>15</b>
<b>2</b>	<b>CÍLE PRÁCE</b> .....	<b>17</b>
<b>3</b>	<b>ROZBOR PROBLEMATIKY</b> .....	<b>18</b>
<b>3.1</b>	<b>UAV</b> .....	<b>18</b>
3.1.1	UAV platformy .....	18
3.1.2	Snímací zařízení .....	24
<b>3.2</b>	<b>Fotogrammetrie</b> .....	<b>25</b>
3.2.1	Rozdělení fotogrammetrie.....	26
3.2.2	Structure From Motion .....	28
<b>3.3</b>	<b>Laserové skenování</b> .....	<b>31</b>
<b>3.4</b>	<b>Sběr dat</b> .....	<b>32</b>
3.4.1	Nastavení fotoaparátu.....	33
3.4.2	Parametry letové mise.....	34
<b>3.5</b>	<b>Individuální a plošný přístup</b> .....	<b>36</b>
3.5.1	Model šířky koruny .....	36
<b>3.6</b>	<b>Zkušenosti s využitím bodových mračen pro odvozování dendrometrických veličin a dalších charakteristik lesních porostů</b> .....	<b>37</b>
3.6.1	Identifikace jednotlivých stromů.....	37
3.6.2	Výška .....	39
3.6.3	Vliv hustoty bodového mračna.....	40
<b>4</b>	<b>METODIKA</b> .....	<b>41</b>
<b>4.1</b>	<b>Prostorové rozlišení snímků v závislosti na vnějších podmínkách</b> .....	<b>42</b>
4.1.1	Odvození pozemní vzorkovací vzdálenosti (GSD).....	42
4.1.2	Odvození pozemní rozlišovací vzdálenosti (GRD).....	42
4.1.3	Pořízení snímků .....	43
4.1.4	Určení GRD .....	46
<b>4.2</b>	<b>Kvalita fotogrammetrických (DAP) bodových mračen odvozených ze snímků pořízených v různých vstupních podmínkách</b> .....	<b>47</b>
4.2.1	Výzkumné lokality .....	47
4.2.2	Letové mise.....	49
4.2.3	Zpracování snímků.....	51
4.2.4	Bodová mračna .....	52

4.2.5	Porovnání bodových mračen .....	53
<b>4.3</b>	<b>Vliv vstupních podmínek a kvality bodového mračna na přesnost odvozování vybraných výstupů.....</b>	<b>55</b>
4.3.1	Referenční data .....	55
4.3.2	Model šířky koruny .....	57
4.3.3	Ověření využití modelu pro identifikaci jednotlivých stromů v ULS bodovém mračnu .....	62
4.3.4	Identifikace jednotlivých stromů v rámci fotogrammetrických (DAP) mračen.....	64
<b>5</b>	<b>VÝSLEDKY .....</b>	<b>64</b>
<b>5.1</b>	<b>Prostorové rozlišení snímků v závislosti na různých vstupních podmínkách .....</b>	<b>64</b>
<b>5.2</b>	<b>Kvalita fotogrammetrických (DAP) bodových mračen odvozených ze snímků pořízených v různých vstupních podmínkách .....</b>	<b>68</b>
5.2.1	Pokrytí výzkumné lokality .....	68
5.2.2	Hustota bodů .....	71
5.2.3	Polohová přesnost.....	73
<b>5.3</b>	<b>Vliv vstupních podmínek a kvality bodového mračna na přesnost odvozování vybraných výstupů.....</b>	<b>76</b>
5.3.1	Ověření kalibrace modelu.....	76
5.3.2	Kalibrace modelu pro výzkumnou lokalitu Skorkov .....	78
5.3.3	Identifikace jednotlivých stromů v rámci ULS mračna .....	79
5.3.4	Identifikace jednotlivých stromů v rámci fotogrammetrických (DAP) mračen.....	81
<b>6</b>	<b>DISKUZE.....</b>	<b>85</b>
<b>7</b>	<b>ZÁVĚR .....</b>	<b>89</b>
<b>8</b>	<b>SEZNAM LITERATURY A POUŽITÝCH ZDROJŮ.....</b>	<b>91</b>
<b>9</b>	<b>PŘÍLOHY .....</b>	<b>102</b>



## Seznam používaných symbolů a zkratk

3D	Tři dimenze
ABA	Area Based Approach
AFIS	Letištní informační služba
AGL	Above Ground Level
ALS	Airborne Laser Scanning
AMSL	Nadmořská výška
ARP	Vztažný bod letiště
ATZ	Letištní provozní zóna neřízeného letiště
C2CDistMean	Mean Cloud-to-Cloud Distance
CSF	Cloth Simulation Filter
CTR	Řízený okrsek letiště
CW	Crown Width
DAP	Digital Aerial Photogrammetry
DBH	Diameter at Breast Height
DPZ	Dálkový průzkum země
DSM	Digital Surface Model
DTM	Digital Terrain Model
Eq	Equation
EU	Evropská Unie
GRD	Ground Resolved Distance
GSD	Ground Sampling Distance
CHM	Canopy Height Model
ICP	Iterative Closest Point
IMU	Inertial Measurement Unit
ISO	International Organization for Standardization
ITD	Individual Tree Detection
Lat	Latitude
LHP	Lesní hospodářský plán
LMF	Local Maximum Filtering
Lon	Longitude
LP	Letecké práce
MPE	Mean Percentage Error
MSE	Mean Signed Error
MVS	Multi-view stereo
nDSM	normalised Digital Surface Model
NIL	Národní inventarizace lesů
NMGround	Non-Matching Ground points

ODM	OpenDroneMap
PE	Percentage Error
PL	Provozovatel letiště
RMSE	Root Mean Square Error
rRMSE	relative Root Mean Square Error
ŘLP	Řízení letového provozu
SBET	Smoothed Best Estimated Trajectory
SE	Signed Error
SfM	Structure from Motion
SIL	Souhrnné informace o lese
Sm.odch.	Směrodatná odchylka
UA	Unmanned Aircraft
UAV	Unmanned Aerial Vehicle
UAS	Unmanned Aerial System
ULS	Unmanned aerial Laser Scanning
ÚCL	Úřad civilního letectví
VRS	Virtual Reference Station
WebODMenh	WebODM s optimalizovaným nastavením
WebODMstd	WebODM se standardním nastavením
WGS	World Geodetic System

## Seznam tabulek

Tabulka 1 Příklad kategorizace UAV podle hmotnosti (Anderson a Gaston 2013) .....	19
Tabulka 2 Specifikace DJI FC300X fotoaparátu.....	42
Tabulka 3 Přehled snímků kalibračního cíle .....	45
Tabulka 4 Výzkumné lokality.....	47
Tabulka 5 Detaily letových dní.....	50
Tabulka 6 Charakteristiky sad snímků standardních letových misí .....	52
Tabulka 7 Přehled značení jednotlivých nastavení .....	53
Tabulka 8 Zkusné plochy .....	56
Tabulka 9 Rozdělení zkusných ploch podle maximální výšky .....	57
Tabulka 10 Přehled datové sady NIL .....	57
Tabulka 11 Model f1 a model f2 .....	59
Tabulka 12 Označení rovnic pro odvození šířky koruny z výšky stromu.....	62
Tabulka 13 Zjištěné hodnoty GSD a GRD.....	65
Tabulka 14 Model závislosti GRD na výšce letu, rychlosti letu a expozičním čase (Všechny nezávislé proměnné jsou standardizovány pomocí průměru a jednonásobku směrodatné odchylky). .....	67
Tabulka 15 Vlastnosti DAP bodových mračen .....	68
Tabulka 16 Vlastnosti vybraných 63 DAP bodových mračen s pokrytím >80%.....	69
Tabulka 17 GLM závislosti pokrytí výzkumné lokality na výšce letu, software, lokalitě a rychlosti letu.....	70
Tabulka 18 GLM závislosti hustoty DAP bodového mračna na výšce letu, software, lokalitě a rychlosti letu.....	72
Tabulka 19 GLM závislosti polohové přesnosti DAP bodového mračna na výšce letu, software a lokalitě.....	74
Tabulka 20 p-hodnoty Dunnova testu pro nRMSE odhadu podle počtu kalibračních vzorků (tučně p-hodnota<0.05) .....	78
Tabulka 21 Výsledky kalibrace.....	78
Tabulka 22 P-hodnoty Dunnova testu vlivu funkce použité pro LMF na chybu určení počtu stromů z ULS oproti pozemnímu šetření (tučně p-hodnota<0,05) .....	80

Tabulka 23 Relativní chyba mezi LMF identifikací a pozemním šetřením v rámci zkusných ploch.....	81
Tabulka 24 p-hodnoty Kruskal-Wallisova testu.....	83
<b>Seznam obrázků</b>	
Obrázek 1 Ustanovení č. 16 předpisu L2 Doplněk X zákona č. 49/1997 Sb.....	22
Obrázek 2 Provoz v ATZ a prostorech třídy G a E podle předpisu L2 Doplněk X zákona č. 49/1997 Sb. ....	23
Obrázek 3 Provoz v CTR a dalších prostorech podle předpisu L2 Doplněk X zákona č. 49/1997 Sb.....	23
Obrázek 4 Náhled mapového nástroje DronView .....	24
Obrázek 5 Schéma SfM pracovního postupu s vyznačením jednotlivých hlavních kroků. Zpracováno podle (Iglhaut et al. 2019) .....	30
Obrázek 6 DJI Phantom 3 Professional .....	41
Obrázek 7 (a) Siemens star kalibrační cíl s počtem sektorů $n=18$ ;(b) Rozostřený střed kalibračního cíle o průměru $d$ .....	43
Obrázek 8 Snímek kalibračního cíle Siemens star (a) letová výška 5m;(b) letová výška 30m .....	44
Obrázek 9 Střední oblast (šedě) snímku .....	45
Obrázek 10 Identifikace rozostřené středové oblasti s (a) a bez prahování (b) .....	46
Obrázek 11 Umístění výzkumných lokalit.....	48
Obrázek 12 Výzkumná lokalita Skorkov .....	48
Obrázek 13 Výzkumná lokalita Skalice .....	49
Obrázek 14 Dráha letu u standardní (a) a zvláštní (b) mise .....	51
Obrázek 15 Postup pořízení a zpracování dat.....	55
Obrázek 16 Zkusné plochy na lokalitě Skorkov .....	56
Obrázek 17 Model f1 - diagnostické grafy .....	60
Obrázek 18 Model f2 - diagnostické grafy .....	61
Obrázek 19 Graf závislosti GRD a GSD na letové výšce.....	65
Obrázek 20 Graf vztahu mezi GRD a expozičním časem .....	66

Obrázek 21 Graf vztahu mezi GRD a rychlostí letu UAV .....	66
Obrázek 22 Pokrytí výzkumné lokality bodovým mračenem v členění podle použitého software (a) a výzkumné lokality (b). Zahrnuje všech 78 bodových mračen.....	68
Obrázek 23 Boční pohled na rekonstruované bodové mračno (zeleně) s terénem (šedě) lokality Skorkov při letové hladině 75m(modře) (a) a 100m(červeně)(b) .....	69
Obrázek 24 Efekty vybraných proměnných výška letu, rychlost letu, software a výzkumná lokalita na GLM predikované pokrytí výzkumné lokality DAP bodovým mračenem. ....	71
Obrázek 25 Hustota bodů DAP mračen v členění podle použitého software (a) a výzkumné lokality (b). Zahrnuje pouze vybraných 63 bodových mračen s pokrytím nad 80%.....	72
Obrázek 26 Efekty vybraných proměnných výška letu, rychlost letu, software a výzkumná lokalita na GLM predikovanou hustotu DAP bodového mračna. ....	73
Obrázek 27 Průměrná vzdálenost bodů DAP mračen od referenčního ULS mračna v členění podle použitého software (a) a výzkumné lokality (b). Zahrnuje DAP mračna s pokrytím lokality nad 80% (63 bodových mračen).....	74
Obrázek 28 Efekty vybraných proměnných výška letu, software a výzkumná lokalita na GLM predikovanou polohovou přesnost DAP bodového mračna.....	75
Obrázek 29 Příklad kalibrace modelu pro jednu náhodně vybranou inventarizační plochu. (a) náhled kalibrace se třemi kalibračními vzorky, plné body kalibrační vzorky, přerušovaná čára nekalibrovaný model, plná čára kalibrovaný model;(b) porovnání kalibrace, plná čára model s různým počtem kalibračních vzorků a přerušovaná čára nekalibrovaný model. ....	77
Obrázek 30 Vliv počtu kalibračních vzorků, 0 znamená nekalibrovaný model pouze s pevnými efekty.....	77
Obrázek 31 Kalibrace modelů pro výzkumnou lokalitu Skorkov (a) model f1 pro všechny skupiny dřevin; (b) model f2 pro skupiny dřevin Borovice lesní a Duby. ....	79
Obrázek 32 relativní chyba mezi počtem stromů určených z ULS mračna a pozemním šetřením v členění podle použité funkce pro LMF(a) a dále podle výškové kategorie zkusných ploch (b) .....	80
Obrázek 33 Relativní chyba (a) počtu stromů; (b) průměrné výšky; (c) maximální výšky mezi LMF identifikací a pozemním šetřením v rámci zkusných ploch .....	82

Obrázek 34 Náhled zkusné plochy 32 (růžový kruh) s menšími stromky v severovýchodní části identifikovanými pod úrovní hlavního porostu (značky označují polohu vrcholu jednotlivých stromů, barva odpovídá jejich výšce na škále od modré u nejnižších po červenou u nejvyšších)..... 83

Obrázek 35 Relativní chyba určení počtu stromů na jednotlivých zkusných plochách v členění podle výškových tříd zkusných ploch a dále podle výšky letu (a), rychlosti letu (b), expozičního času (c) a použitého software (d) ..... 84

# 1 Úvod

Snaha sledovat a hodnotit stav lesů úzce souvisí zejména s jejich využíváním. Nicméně první zmínky o zalesnění našich zemí souvisely spíše s prostupností krajiny a lze je najít již u řeckého geografa Ptolemaia (z 2. pol. 2. stol. n. l.). Intenzivnější využívání lesů souvisí nejprve s kolonizací lesní půdy započaté u nás ve druhé polovině 12. století zejména kláštery. V pozdější době (14. století) pak zvýšená spotřeba dříví vyvolávala postupně potřebu omezit exploataci a začít lesy chránit a odpovědněji obhospodařovat. Příkladem je v této souvislosti návrh zákoníku *Maiestas Carolina* připravovaný Karlem IV, který obsahoval přísná opatření na ochranu lesů. Nejstarším lesním řádem vydaným u nás je pak Chebský lesní řád z roku 1379. V souvislosti s vlastnictvím lesů a také zvýšeným zájmem o dříví vznikala potřeba lesy ohraničovat a popisovat, díky čemuž lze dohledat informace k vybraným majetkům již od 12. století (Nožička 1957). Tyto informace, v počátcích omezené nejčastěji pouze na výměru, doprovázenou jednoduchými informacemi o jakosti dříví z hlediska jejich využití. Snahy o dosažení trvalé produkce dříví vyústily postupem času ve formulaci principů trvale udržitelného obhospodařování lesů, s nimiž úzce souvisí potřeba dostatečně podrobných informací o lesních zdrojích primárně pro jejich vlastníky, ale i pro stát, z jehož strany v průběhu historie postupně narůstala regulace lesního hospodářství.

Významným impulzem pro další zpřesňování a ověřování informací (nejen) o lesích napříč vlastnickými poměry byly mimo jiné i daňové potřeby státu, které vedly ke vzniku katastru nemovitostí. Ten byl také v počátcích základním zdrojem informací o lesích na úrovni celého státu, rozšiřovaným ad-hoc doplňováním dalších podrobností o stavu lesů pro účely dohledu státu. První statistické šetření stavu lesů v samostatné Československé republice bylo provedeno již v roce 1920 a poskytuje poměrně detailní informaci o našich lesích v té době (Nožička 1957).

V souvislosti s významným navýšením podílu lesů vlastněných státem v průběhu 20. století narostla postupně plocha lesa popsaného v rámci jednotně zpracovaného lesního hospodářského plánu (LHP) natolik, že bylo možné tento zdroj využít pro sumarizaci informací o lesích v celém státu. V roce 1950 tak byly vydány výsledky tzv. inventarizace lesů, která vznikla souhrnem všech aktuálně platných lesních hospodářských plánů a poskytla nebyválně detailní informace. V letech 1960 a 1970

byla tato inventarizace aktualizována, opět na základě LHP, které byly aktualizovány průběžně. Lze tak říci, že publikovaná informace byla v průměru pět let stará, protože vznikala souhrnem jednotlivých LHP u nichž od zpracování uplynulo od jednoho do deseti roků. To platí u tohoto datového zdroje, od roku 1979 publikovaného každoročně, dodnes. Výstupy této sumarizace jsou dnes dostupné v rámci tzv. Souhrnných informací o lese (SIL) online na adrese <https://eagri.cz/public/app/uhul/SIL/Default.cshtml>.

V souvislosti s privatizací tvorby lesních hospodářských plánů po roce 1995 a také s potřebou dalších informací vyvolanou nárůstem významu celospolečenských funkcí lesa, které nemohly být získány prostřednictvím LHP, byla v roce 2001 zahájena Národní inventarizace lesů (NIL). Na rozdíl od předcházejících inventarizací, které vznikaly souhrnem jednotlivých LHP, je NIL výběrové šetření prováděné na inventarizačních plochách striktně jednotnou metodikou s propracovaným několika stupňovým systémem kontrol, což zaručuje důvěryhodnost výsledků na úrovni státu a jednotlivých krajů. První kolo NIL proběhlo v letech 2001 až 2004, druhé pak 2011 až 2015 a od roku 2016 pokračuje šetření nepřetržitě s dobou návratu na konkrétní inventarizační plochu pět let. Výsledky NIL jsou dostupné jednak v samostatných publikacích prvního (Vašíček et al. 2007) a druhého (Kučera a Adolt 2019) kola a také online na adrese <http://nil.uhul.cz>.

Zjišťování informací o lese, ať už pro vypracování LHP, NIL, nebo jiné účely, představuje značně náročnou a nákladnou činnost, což vedlo a vede ke snahám o maximální efektivitu a racionalizaci. Tyto snahy jsou realizovány v rámci možností vědecko-technického rozvoje. Jako jeden z příkladů může sloužit i využití výpočetní techniky, jejíž nástup umožnil například výše zmíněnou každoroční aktualizaci souhrnných informací o lese z LHP již od roku 1979. Další významnou oblastí se značným potenciálem pro zjišťování informací o lese je pak dálkový průzkum země, jehož využití má, v kombinaci s pozemním šetřením, v lesnictví letitou historii, a to zejména na základě leteckých a satelitních snímků, doplňovaných v posledních letech i daty pořizovanými pomocí bezpilotních leteckých prostředků. Jako příklad využití DPZ v celostátním měřítku na podkladu leteckých snímků může sloužit pravidelně aktualizovaná mapa detekce těžeb, nebo ze satelitních dat realizované šetření zdravotního stavu lesů prostřednictvím indexu listové plochy – obojí dostupné online zde: <https://geoportál.uhul.cz/mapy/MapyDpz.html>.



Bezpilotní letecké prostředky – Unmanned Aerial Vehicles (UAV) se v poslední době stávají stále dostupnější a přestaly tak již dávno být výsadou armády a vybraných vědeckých pracovišť. V současné době je možné v dostupné cenové hladině pořídit uživatelsky snadno ovladatelné UAV, které jsou schopny provádět snímkování s potenciálem dobrého využití pro sledování aktuální situace. To platí mimo jiné i v lesních porostech, kde je pozorování „z vrchu“ velmi vítaným úhlem pohledu umožňujícím získání nových informací s velkou podrobností.

Stejně jako se zvyšuje dostupnost UAV rozšiřuje se také portfolio programového vybavení určeného pro zpracování dat pořízených za pomoci UAV. I díky tomu, že některé z těchto programů jsou dostupné jako open-source opět platí, že pořizování a práci s daty získanými prostřednictvím UAV se může věnovat stále širší pole uživatelů.

Přesto zůstávají stále některé nedostatečně rozpracované oblasti, jako například exaktní stanovení minimálních požadavků pro provedení sběru dat s ohledem na očekávanou kvalitu výstupu. Lze nalézt řadu doporučení, která směřují k pořizování obrazového materiálu prostřednictvím UAV za optimálních podmínek, ale minimální přípustné hodnoty například světelných podmínek, nebo vliv letové hladiny na přesnost se v literatuře příliš neobjevují.

Práce si klade za cíl rozpracovat tuto část, ověřit dopady různých letových výšek a různých světelných podmínek na kvalitu fotogrammetrického bodového mračka rekonstruovaného metodou Structure from Motion (SfM) a především z něj odvozených vybraných charakteristik lesního porostu a přispět tak k rozšíření využití UAV v běžné lesnické praxi.

## 2 Cíle práce

Cílem práce je rozbor možností využití datových zdrojů pořízených prostřednictvím UAV v rámci běžné praxe hospodářské úpravy lesů, respektive dendrometrie. Zejména se snaží ověřit dopad variabilních vnějších podmínek na kvalitu obrazových dat pořízených prostřednictvím UAV, stejně jako na výstupy jejich následného zpracování v podobě fotogrammetrických bodových mračen a v neposlední řadě na jejich využití pro identifikaci jednotlivých stromů a následný odhad vybraných dendrometrických veličin.

Vybrané veličiny:

- odhad počtu stromů v porostu
- odhad výšky jednotlivých stromů
- odhad průměrné výšky porostu

## 3 Rozbor problematiky

### 3.1 UAV

Bezpilotní letadlo/letecký prostředek (UAV) je podle Nařízení Evropského parlamentu a Rady (EU) 2018/1139 ze dne 4. července 2018 (EU 2018) jakékoli letadlo provozované nebo projektované pro autonomní provoz nebo pro pilotování na dálku bez pilota na palubě.

UAV představují ekonomicky výhodnější alternativu pro pořizování dat v rámci omezeného území s potenciálem výrazně většího rozlišení, v porovnání s tradičními leteckými pilotovanými prostředky (Pajares 2015). Rozvoj využití UAV v poslední době lze dokumentovat například nárůstem počtu publikací s tématem využití UAV v databázi Web of Knowledge, jak dokumentuje například (Goodbody et al. 2017).

UAV lze systematicky rozdělit na vlastní platformu zajišťující let, navigaci a stabilizaci a dále pak snímací zařízení určené pro pořizování dat určených pro využití v rámci dálkového průzkumu země (DPZ). Míra integrace obou částí se u různých UAV liší. Existují univerzální platformy připravené pro instalaci široké škály snímacích zařízení i kompaktní UAV, kde nelze snímací zařízení oddělit od platformy.

#### 3.1.1 UAV platformy

Rozdělení UAV platform podle různých kritérií jako je například hmotnost, nebo typu konstrukce lze nalézt v řadě publikací, například (Anderson a Gaston 2013).

Podle hmotnosti:

**Tabulka 1 Příklad kategorizace UAV podle hmotnosti** (Anderson a Gaston 2013)

	<b>Hmotnost</b>	<b>Akční rádius</b>	<b>Doba letu</b>
Velké	nad 100kg	500km	až 2 dny
Střední	cca 50kg	500km	10 hodin
Malé a Mini	5 až 30kg	do 10km	do 2 hodin
Micro a Nano	do 5kg	do 10km	do 1 hodiny

podle typu konstrukce:

- UAV s pevným křídlem (*fixed wing*)
- UAV s rotujícím křídlem (*rotary wing*) – označované nejčastěji jako multirotory, nebo multikoptéry. Při širším výkladu tato kategorie může zahrnovat i stroje typu vrtulník (jeden až dva poháněné nosné rotory doplněné případně pomocným rotorem), nebo i vírník (kde je nosný rotor roztáčen pasivně pomocí aerodynamických sil působících na rotor při pohybu zajišťovaném pomocí tažné, nebo tlačné vrtule poháněné motorem), nicméně využití těchto konstrukcí je u UAV v současné době zcela marginální, protože byly díky rozvoji v elektronice nahrazeny konstrukčně jednoduššími multirotory.

Výhodou UAV s pevným křídlem je jednodušší konstrukce, vyšší dolet, vyšší rychlost a v neposlední řadě výpadek pohonné jednotky nemusí automaticky pro tento typ UAV znamenat fatální havárii. Naopak nevýhodou je potom nutnost dostatečného prostoru pro start a přistání, nemožnost nulové horizontální rychlosti a v neposlední řadě také komplikovanější stabilizace snímacích zařízení.

Naopak UAV s rotujícím křídlem jsou technicky náročnější a mají výrazně vyšší spotřebu energie, což limituje jejich maximální dobu letu i akční rádius. Výhodou je zde možnost letu s nulovou horizontální i vertikální rychlostí a tím například start, přistání ale i vlastní let v omezeném prostoru (Goodbody et al. 2017). Vertikální start a přistání umožňují využít výkonnější zařízení pro stabilizaci snímacího zařízení, které je tak více nezávislé na orientaci vlastního prostředku než v případě UAV s pevným křídlem (Anderson a Gaston 2013). Zásadní nevýhodou tohoto typu UAV je pak riziko pádu jako následek zastavení některého z rotorů. Toto riziko je možné eliminovat zvýšeným počtem rotorů. Například pro UAV se třemi rotory je porucha na jednom z nich automaticky důvodem pádu, zatímco v případě UAV s osmi rotory může být možné přistát kontrolovaně i při poruše až čtyř z nich (v závislosti na pozici rotorů s poruchou).

Pro pohon může být v případě UAV s pevným křídlem využit i spalovací motor, což významně zvyšuje akční rádius, nicméně většina UAV využívaných pro monitoring lesů pracuje s pohonem elektrickým. UAV s rotujícím křídlem jsou (s výjimkou strojů typu vrtulník, nebo vírník) poháněna výhradně elektrickými motory jejichž bezprostřední odezva na řídicí impulzy je základní podmínkou pro stabilizaci letu prostředků tohoto typu.

V našich podmínkách je zdaleka nejdůležitější kategorizace UAV z pohledu legislativy.

Pro provoz UAV platil u nás až do konce roku 2020 letecký předpis L2 označovaný jako Doplněk X zákona č. 49/1997 Sb. z roku 2014 (Česko 2014), který popisuje UAV takto:

Bezpilotní letadlo (UA) - letadlo určené k provozu bez pilota na palubě.

Bezpilotní systém (UAS) - systém skládající se z bezpilotního letadla, řídicí stanice a jakéhokoliv dalšího prvku nezbytného k umožnění letu, jako například komunikačního spojení a zařízení pro vypuštění a návrat. Bezpilotních letadel, řídicích stanic nebo zařízení pro vypuštění a návrat může být v rámci bezpilotního systému více.

Podle váhy dělí předpis dále UAV na kategorie:

- do 0,91 kg,
- od 0,91 do 7 kg,
- 7 až 20 kg a
- nad 20 kg.

Podle těchto kategorií a způsobu užití pak předpis stanoví podmínky provozu viz Obrázek 1.

Maximální výška letu UAV je tímto předpisem omezena na 300 metrů nad terénem - Above Ground Level (AGL), která platí v tzv. letovém prostoru G, tedy například mimo řízené okrsky letišť (CTR), letištní provozní zónu letiště s neřízeným prostorem (ATZ) nebo další omezené prostory. Pravidla jsou graficky znázorněna v Obrázek 2 a Obrázek 3, kde označení:

1 znamená lety bez koordinace,

2 splnění podmínek provozovatele letiště (PL) + koordinace s letištní informační službou (AFIS),

3 splnění podmínek PL + koordinace s AFIS,

4 souhlas/povolení Úřadu civilního letectví (ÚCL)


5 letové povolení příslušného stanoviště řízení letového provozu (ŘLP). ŘLP může dále požadovat: stálé obousměrné spojení a odpovídač sekundárního radaru,

6 povolení ÚCL (nebo v případě leteckých prací (LP) koordinace s ŘLP + koordinace s PL). ŘLP může dále požadovat: stálé obousměrné spojení a odpovídač sekundárního radaru,


7 Povolení ÚCL (nebo v případě LP koordinace s ŘLP + koordinace s PL) + letové povolení ŘLP. ŘLP může dále požadovat: stálé obousměrné spojení a odpovídač sekundárního radaru

Tabulka 1 (viz ust. 16)										
ř.	maximální vzletová hmotnost	≤ 0,91 kg		> 0,91 kg a < 7 kg		7 – 25 kg		> 25 kg		bezpilotní letadlo provozované mimo dohled pilota
-	účel použití ----- požadavek	rekreačně sportovní	výdělečné, experimentální, výzkumné	rekreačně sportovní	výdělečné, experimentální, výzkumné	rekreačně sportovní	výdělečné, experimentální, výzkumné	rekreačně sportovní	výdělečné, experimentální, výzkumné	
1	evidence letadla	ne	ano	ne	ano	ne	ano	ano	ano	ano
2	evidence pilota	ne	ano	ne	ano	ne	ano	ano	ano	ano
3	praktický a teoretický test pilota	ne	ano	ne	ano	ne	ano	ano	ano	ano
4	povolení k létání	ne	ano	ne	ano	ne	ano	ano	ano	ano
5	povolení k provádění LP a LČPVP	nelze	ano	nelze	ano	nelze	ano	nelze	ano	nelze
6	označení UA: ID štítek / ID štítek + pozn. značka	ne / ne	ano / ano	ano / ne	ano / ano	ano / ne	ano / ano	ano / ne	ano / ano	ano / ano
7	min. ve vzdálenosti (m): vzlet, přistání / osoby, stavby / osídlený prostor	bezpečná	bezpečná	bezpečná	bezpečná	bezpečná, ale minimálně 50/100/150	bezpečná, ale minimálně 50/100/150	bezpečná, ale minimálně 50/100/150	bezpečná, ale minimálně 50/100/150	bezpečná, ale minimálně 50/100/150
8	pojištění: běžný provoz / LVV (mil. Kč)	ne / 0,25	dle nař. č. 785/2004 <sup>1</sup>	ne / 1	dle nař. č. 785/2004 <sup>1</sup>	ne / 3 od 20 kg dle nař. č. 785/2004 <sup>1</sup>	dle nař. č. 785/2004 <sup>1</sup>	dle nař. č. 785/2004 <sup>1</sup>	dle nař. č. 785/2004 <sup>1</sup>	dle nař. č. 785/2004 <sup>1</sup>
9	dozor	ne	ne	ne	ne	ne	ne	ano	ano	ne
10	„failsafe“ systém	ne	ano	ano	ano	ano	ano	ano	ano	ano
11	provozní příručka UAS	ne	ano	ne	ano	ne	ano	ne	ano	ne
12	hlášení událostí	ne	ano	ne	ano	ne	ano	ano	ano	ano

Obrázek 1 Ustanovení č. 16 předpisu L2 Doplněk X zákona č. 49/1997 Sb.



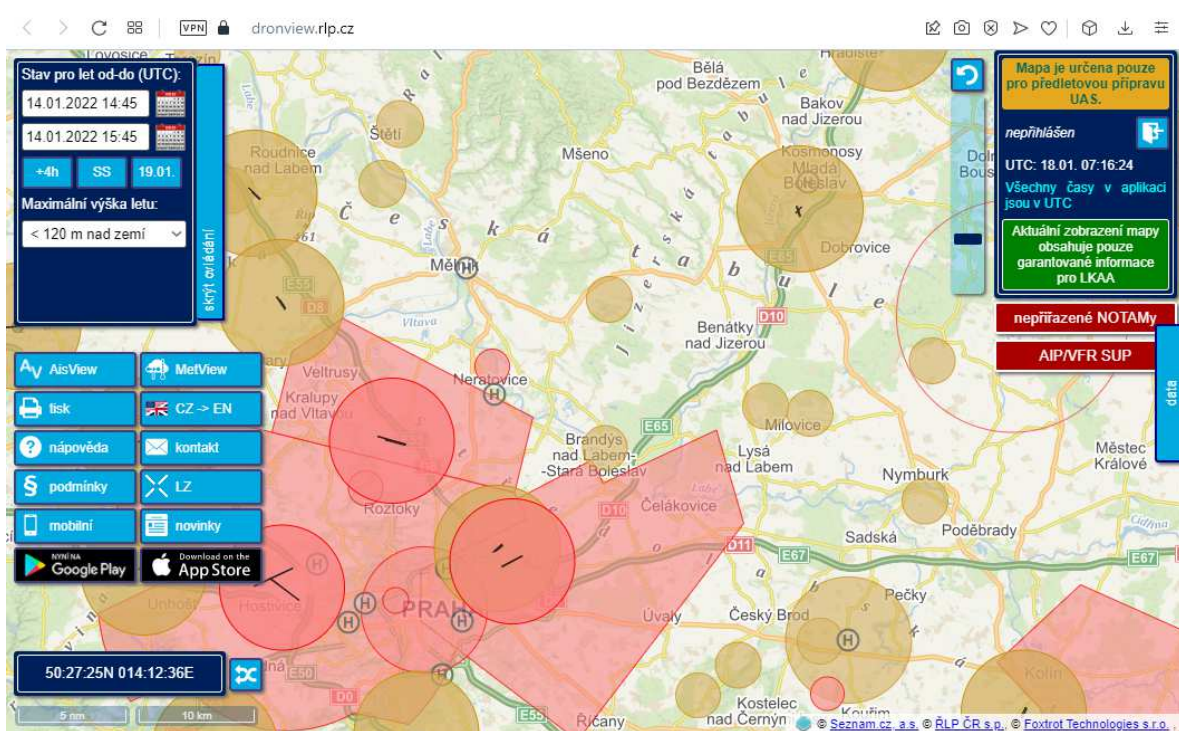
Obrázek 2 Provoz v ATZ a prostorech třídy G a E podle předpisu L2 Doplněk X zákona č. 49/1997 Sb.



Obrázek 3 Provoz v CTR a dalších prostorech podle předpisu L2 Doplněk X zákona č. 49/1997 Sb.

V době dokončování této práce v roce 2021 je u nás nově platné rozdělení bezpilotních prostředků do kategorií Otevřená, Specifická a Certifikovaná podle prováděcího nařízení Komise (EU) 2019/947 ze dne 24. května 2019 o pravidlech a postupech pro provoz bezpilotních letadel (Evropská Komise 2019), které se liší z pohledu legislativních omezení a požadavků. Mimo jiné například pro kategorii Otevřená je nově omezena výška letu na 120 m AGL.

V rámci postupu digitalizace byl zpracován Mapový nástroj ŘLP ČR, s. p. pro předletovou přípravu dálkově řídicích pilotů UAV v České republice, který obsahuje aktuální informace o omezení letových činností ve vztahu ke vzdušnému prostoru, označovaný jako DronView dostupný na adrese <http://dronview.ans.cz/> Obrázek 4. Tento nástroj významně zjednodušuje předletovou přípravu a zabraňuje možným narušením letového provozu.



Obrázek 4 Náhled mapového nástroje DronView

### 3.1.2 Snímací zařízení

Snímací zařízení využívaná ve spojení s UAV platformou lze v zásadě rozdělit na aktivní (laser, radar) a pasivní (fotoaparát) snímače. Podrobnější členění lze nalézt například v (Colomina a Molina 2014). Nejčastěji se v současné době v literatuře uváděných studiích v lesnictví setkáváme se snímači pracujícími:



- ve viditelném pásmu (méně pak multi a hyperspektrální) jejichž výstupy jsou dále zpracovávány pomocí fotogrammetrických postupů a
- laserovými skenery.

Výstupem fotogrammetrického zpracování jsou jednak ortomozaiky v podobě rastrů a jednak bodová mračna zobrazující 3D strukturu snímaného povrchu.

Výstupem laserového skenování lesa jsou bodová mračna zachycující body nejen na povrchu, ale i uvnitř sledovaného lesního porostu.

Při zpracování bodových mračen lze odvodit několik běžně využívaných výstupů:

- Digitální model terénu – Digital Terrain Model (DTM) který obsahuje body klasifikované jako zem.
- Digitální model povrchu – Digital Surface Model (DSM) odvozený z bodů na povrchu zobrazovaného prostoru. Zahrnují tedy například koruny stromů, nebo střechy staveb apod.
- Pro monitoring lesních porostů se pak většinou používá normalizovaný model povrchu (nDSM) označovaný někdy také jako Canopy Height Model (CHM) který je výsledkem jednoduché úpravy podle Eq 1.

$$nDSM = DSM - DTM \quad \text{Eq 1}$$

## 3.2 Fotogrammetrie

Fotogrammetrie je obecně definována jako vědní obor, který se zabývá zpracováním informací o objektech na základě exaktního měření. Záznam ve formě fotografie lze provádět digitálně nebo klasicky analogovou formou světlocitlivé vrstvy (neboli běžnou fotografií). Obraz lze získat pomocí různých zařízení, jejichž výstupní přesnost se liší. Záznam s nízkou přesností svedou běžné amatérské fotoaparáty, nicméně pro detailní a přesné záznamy je potřeba mít speciální měřičské fotogrammetrické komory. Díky těmto pořízeným snímkům lze zpracovávat okolní realitu. Body a polohy bodů na pořízených snímcích umožňují dále určit velikost, tvar nebo umístění objektu měření v prostoru. Taktéž je možné zjistit vzájemnou polohu v prostoru mezi jednotlivými body a vyhodnotit polohopis či výškopis. (Pavelka 2003)

## 3.2.1 Rozdělení fotogrammetrie

Fotogrammetrie lze dělit podle následujících kritérií (Böhm 2002):

- polohy stanoviště
- počtu vyhodnocovaných snímků
- způsobu zpracování snímků
- druhu záznamu výstupních hodnot

### 3.2.1.1 Dělení podle polohy stanoviště

Podle polohy, z níž byl zpracováván snímek pořízen, se fotogrammetrie dělí na pozemní a leteckou.

Pozemní fotogrammetrie má fotogrammetrickou komoru umístěnou na pevném bodě, který je geodeticky zaměřen. Fotografická i technická náročnost vybavení je oproti letecké fotogrammetrii mnohem menší, stejně tak jako náročnost na stav počasí. Naproti tomu nevýhodou je fakt, že velmi často dochází k zakrývání předmětů měření a tím vzniká velké množství nevyhodnotitelných oblastí. Tato metoda je tedy ideální v případě, že jsou objekty v podobné vzdálenosti od přístroje a zároveň většina z nich výškově rozrůzněná (stěny budov, členitý skalnatý terén, lomy). Pozemní fotogrammetrie má dosah kolem 500 m, nicméně její závislost je zejména na typu použité měřičské komory.

U letecké metody je poloha pořizovaného snímku umístěna v pohybujiícím se nosiči. Mezi takové nosiče patří zejména letadla, vrtulníky či UAV. Snímaná plocha je podstatně větší než u pozemní fotogrammetrie a zároveň se za jednotku času zpracuje výrazně větší oblast území. V případě využití digitální fotografie se v literatuře používá označení Digital Aerial Photogrammetry (DAP)

### 3.2.1.2 Dělení podle počtu vyhodnocovaných snímků

Fotogrammetrii lze také dělit podle počtu vyhodnocovaných snímků na:

- jednosnímkovou a
- dvousnímkovou.

Jednosnímková fotogrammetrie využívá jednotlivých měřičských snímků. Touto metodou lze určit pouze rovinné souřadnice předmětu, neboť je možné na snímku

měřit právě jen souřadnice rovinné. Možnými objekty snímání jsou tedy již zmíněné rovinné objekty (například stěny budov) a tak je tato metoda hojně využívána ve zvláštních případech v archeologii, architektuře a stavebnictví. Často se tato metoda využívá v letecké fotogrammetrii pro možné zjištění polohopisné složky rovinnatého území.

Pro vyhodnocování prostorových souřadnic objektů z dvojic snímků se využívá fotogrammetrie dvousnímkové, při níž musí být předmět měření zobrazen současně na obou snímcích. Použití stereoskopického vjemu k vyhodnocení snímků je označeno jako stereoskopická fotogrammetrie, nebo také stereofotogrammetrie. Ta je dnes nejčastěji využívána především díky svým univerzálním vlastnostem. (Böhm 2002).

### **3.2.1.3 Dělení podle způsobu zpracování snímků**

Fotogrammetrii, respektive metody zpracování lze dělit na analogové, analytické a digitální (Böhm 2002).

Analogové metody využívají opticko-mechanická zařízení. Jedná se o značně složité přístroje, které napodobují modelově stav odpovídající vlastnímu snímání. Pro jejich obsluhu je nezbytný dobře vyškolený a zacvičený personál.

Analytické metody používají pro převod snímkových souřadnic do geodetických prostorové transformace prováděné pomocí počítačů. Tyto metody umožňují zpracování prakticky libovolných snímků.

Digitální metody využívají již na vstupu digitální obraz.

### **3.2.1.4 Dělení podle druhu záznamu výstupních hodnot**

Podle záznamu výstupních hodnot lze fotogrammetrické metody dělit na grafické, kdy při vyhodnocení snímků se na kreslicím stole v reálném čase vykresluje vyhodnocená data a číselné, u kterých jsou výstupem souřadnice jednotlivých vyhodnocovacích bodů ukládané přímo do paměti počítače.

### 3.2.2 Structure From Motion

Structure from motion (SfM) je postup založený do značné míry na principech tradiční stereoskopické fotogrammetrie, která využívá, analogicky k lidskému vidění, pro odhad hloubky dvou bodů se známou vzájemnou relativní pozicí. Prostorový vjem je ale možné docílit i z jednoho pozorovacího bodu, pokud se objekt, nebo pozorovatel pohybují. SfM v tomto směru kombinuje oba principy s využitím sekvencí vzájemně se překrývajících snímků s rozdílnými úhly pořízení (Iglhaut et al. 2019). Ty poté slouží pro generování 3D mračna bodů. Podstatou SfM je překrývání velkého množství snímků, které výsledně vytvoří 3D mračno bodů, z něhož lze odvodit jak digitální model povrchu (DSM), tak v některých případech (v závislosti na stupni zakrytí terénu porostem) i digitální model terénu (DTM). Nosičem fotoaparátu pro pořízení snímků využitelných ke zpracování pomocí SfM bývá nejčastěji UAV. (Wallace et al. 2016)

SfM představuje nízkonákladovou fotogrammetrickou metodu pro topografickou rekonstrukci s vysokým rozlišením. SfM pracuje na stejných principech jako stereoskopická fotogrammetrie. Zásadní odlišností je zde fakt, že na rozdíl od konvenční fotogrammetrie, zde orientace a poloha kamery nemusí být stanoveny předem, ale jsou odvozovány na základě vysoce redundantních opakovaných procedur založených na databázi bodů automaticky extrahovaných ze sady několika překrývajících se snímků. SfM tak významně rozšiřuje portfolio fotoaparátů využitelných pro fotogrammetrické zpracování. (Westoby et al. 2012).

Odlišnost SfM od klasické fotogrammetrie shrnuje (Iglhaut et al. 2019) takto ve třech základních aspektech:

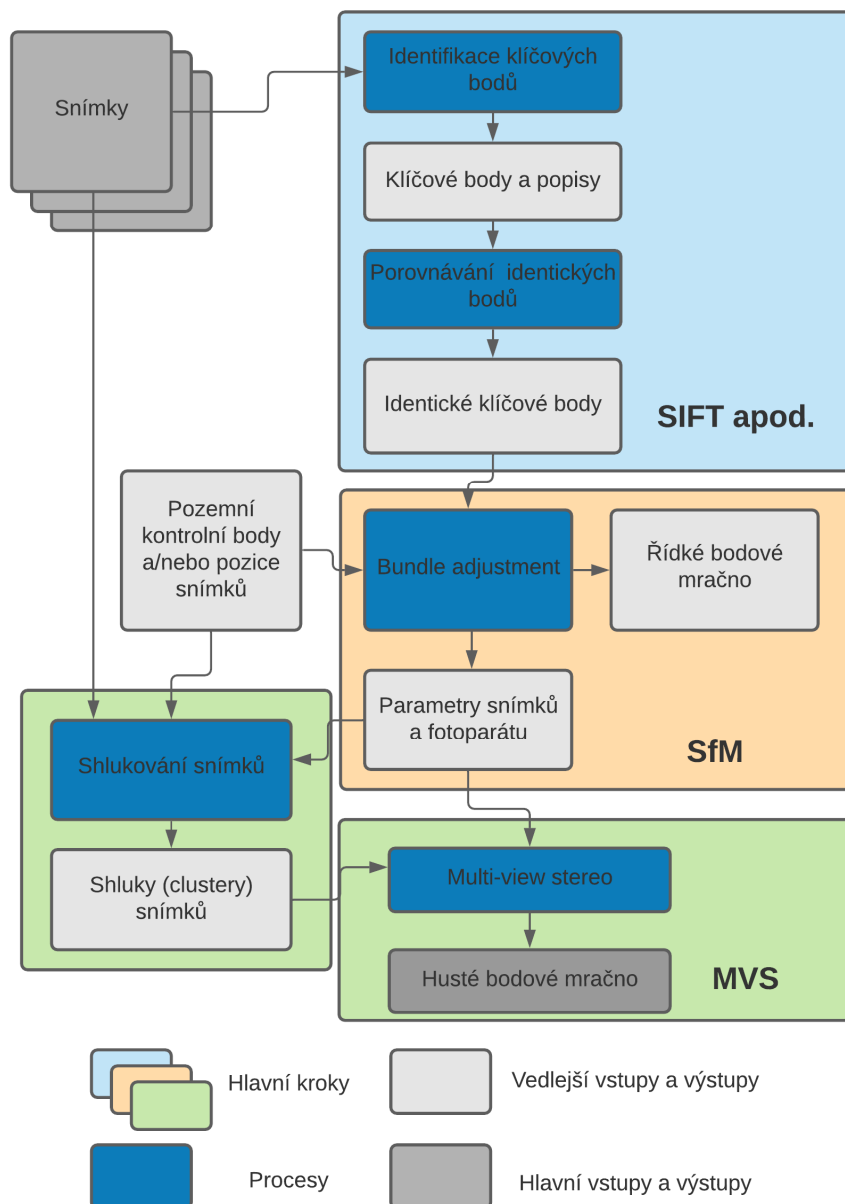
1. jednotlivé prvky mohou být automaticky identifikovány ve snímcích pořízených z různých úhlů a vzdáleností, což znamená velký přínos pro možnosti využití malých nedostatečně stabilních UAV,
2. výpočty v algoritmech zpracování mohou být řešeny bez předchozí znalosti pozice fotoaparátu nebo pozemních kontrolních bodů (které ale mohou být do výpočtů zahrnuty) a
3. kalibrace kamery může být řešena automatizovaně během samotného procesu.

SfM tak umožňuje rekonstrukci bodového mračna i ze značně různorodých snímků za předpokladu dostatečného překryvu a pořízení jedním fotoaparátem. Velkou

výhodou je rovněž fakt, že nemusí být známy prvky vnitřní ani vnější orientace fotoaparátu.

Označení celého procesu tvorby 3D modelu jako SfM je zjednodušení, které však bývá v literatuře užíváno. Tvorba 3D modelu zahrnuje několik kroků, z nichž pouze jeden tvoří vlastní SfM. Celý proces sestává z následujících kroků (Iglhaut et al. 2019) viz také Obrázek 5:

1. Identifikace tzv. *keypoints* tedy klíčových bodů reprezentujících stejný prvek obrazu v jednotlivých snímcích. Klíčové body jsou identifikovány ve všech snímcích a identické body jsou propojeny napříč snímky kde se vyskytují. Nejčastěji využívaným algoritmem pro tuto část je *Scale-invariant feature transform* (SIFT) (Lowe 2004). Výstupem tohoto algoritmu jsou identifikátory jednotlivých bodů na snímku, které jsou nezávislé na měřítku a orientaci.
2. Následuje ověření identifikovaných identických bodů v jednotlivých snímcích, na základě kterého je tato identifikace zpřesněna.
3. Výstup je dále využit v samotném SfM postupu, kdy dochází k výpočtu pozice a parametrů jednotlivých snímků a tvorbě tzv. řídkého bodového mračka (které se skládá ze souboru klíčových bodů připravených v předchozích krocích. V průběhu tohoto kroku probíhá tzv. *bundle adjustment* který vychází nejprve z náhodně vybrané sekvence identických klíčových bodů a doplňujících parametrů a pozic fotoaparátu a nelineárního zpřesnění (Shum et al. 1999).
4. Výstupy SfM fáze jsou dále transformovány na základě známých pozic pozemních kontrolních bodů a/nebo snímků.
5. Následuje fáze tvorby hustého bodového mračka označovaná jako *Multi-view stereo* (MVS), kterému předchází shlukování snímků do clusterů. Výsledkem je husté bodové mračno doplněné o spektrální informace ze zdrojových snímků. Toto husté bodové mračno představuje nejvýznamnější výstup celého procesu. Z tohoto výstupu jsou dále odvozovány DSM a také ortomozaiky



**Obrázek 5** Schéma SfM pracovního postupu s vyznačením jednotlivých hlavních kroků. Zpracováno podle (Iglhaut et al. 2019)

Hlavní problémy, kterým čelí SfM v současné době shrnuje (Iglhaut et al. 2019) do čtyř okruhů:

**Opakovatelnost/reprodukovatelnost.** SfM díky své dostupnosti umožňuje zachytit stav lesních porostů výrazně častěji, než je tomu u ostatních technik. Což zároveň zdůrazňuje i vliv nevyhnutelných rozdílů v osvětlení, atmosférických a sezónních podmínkách. Tyto rozdíly ovlivňují přímo obrazová data a tím pádem i výsledky SfM. Tyto důvody zdůrazňují nezbytnost odvození patřičných postupů a protokolů

pro pořizování snímků v různých podmínkách a také modelů zohledňujících rozdíly v obrazových datech.

**Dostupnost DTM.** SfM je omezena na rekonstrukci povrchů viditelných na snímcích. Při použití v lesích je tak možné odvozovat informace o terénu pouze tam, kde vznikají větší porostní mezery a terén není zakrytý vegetací. Tento nedostatek lze eliminovat kombinací s datovými sadami digitálního modelu terénu odvozených z jiných zdrojů, nejčastěji z leteckého laserového skenování (ALS). Nicméně i tam kde není DTM dostupný v potřebném rozlišení, nebo vůbec, je možné, jak dokumentuje (Giannetti et al. 2018), dosáhnout odhadů zásoby lesních porostů srovnatelných s ALS daty a to jak v rovinném, tak hornatém terénu.

**Nedostatek protokolů pro pořízení a zpracování dat.** Úspěch SfM postupů pro pořízení dat zachycujících stav lesa do značné míry v současné době závisí na zkušenostech pracovníka zajišťujícího pořízení snímků a/nebo jejich další zpracování v procesu SfM. Protokoly pro sběr i zpracování dat zajišťující očekávanou kvalitu výstupů SfM při různých podmínkách nejsou zatím dostatečně zpracovány a jejich návrh je zatím spíše v rané fázi, viz například (Eltner et al. 2016).

**Problémy s identifikací klíčových bodů.** Les se svojí detailní, vysoce proměnlivou strukturou, která se ale zároveň často opakuje v pravidelných vzorcích, společně s možným pohybem vlivem větru, představuje v některých případech značnou výzvu pro algoritmy identifikující klíčové body v jednotlivých snímcích. Selhání těchto algoritmů pak může vést k neúspěchu v rekonstrukci bodového mračka. Větší počet klíčových bodů v rámci jednoho snímku podporuje úspěšnost identifikace shodných klíčových bodů v jednotlivých překrývajících se snímcích. Využití větší vzdálenosti od snímaného povrchu tak přispívá k lepším výsledkům identifikace klíčových bodů. V případě nižších vzdáleností je pak doporučováno náležitě zvýšit překryv jednotlivých snímků.

### 3.3 Laserové skenování

Lidar (Light Detection and Ranging) představuje dynamicky se rozvíjející technologii aktivního skenování. Základním principem je měření času mezi vysláním a návratem laserového paprsku, pomocí něhož lze odvodit vzdálenost mezi předmětem který paprsek odrazil a zařízením. Při znalosti přesné polohy

zařízení nesoucí Lidar a orientace vyslaného paprsku lze velmi přesně určit polohu objektu od něhož se paprsek odrazil v prostoru (Dolanský 2004).

Využití Lidaru pro letecké skenování – *Airborne Laser Scanning* (ALS) představuje efektivní metodu zjišťování velmi přesných a detailních informací o povrchu, terénu, ale do určité míry i vnitřní struktury porostů, což tuto metodu předurčuje jako ideální pro monitoring lesních porostů.

V některých zdrojích je rozlišován pojem *Unmanned aerial Laser Scanning* (ULS) odlišující jednoznačně využití laserového snímače neseného bezpilotním prostředkem.

Nicméně i přes pokrok a zvyšující se dostupnost v této oblasti stále platí, že ULS bodová mračna představují výrazně nákladnější alternativu než v případě DAP.

### 3.4 Sběr dat

Při plánování letu UAV pro sběr dat je třeba vycházet z minimálních požadavků na kvalitu pořizovaných snímků a z nich odvodit jednak nastavení snímače a jednak parametrů letové mise (rychlost, výška atp.).

Důležité aspekty použitého snímacího zařízení a nastavení parametrů letové mise ve vztahu k SfM detailně rozpracovává (Iglhaut et al. 2019) případně také (Kučelka a Surový 2017). Zdůrazňují nezbytnost zajištění dostatečně ostrých dobře exponovaných snímků, ale mimo jiné také například význam kontrastu textury povrchu pro identifikaci klíčových bodů v SfM.

Je vhodné uvést, že programy určené pro plánování a provedení letové mise jsou předmětem soustavného vývoje reagujícího na poptávku uživatelů. Součástí tohoto vývoje je také řešení vzájemného vztahu mezi parametry nastavení snímače a parametry letové mise tak, aby byla výsledná data co nejkvalitnější v rámci daných možností. Přesto nechávají programy dostatek příležitosti do nastavení vstoupit a upravit je v případě potřeby.



### 3.4.1 Nastavení fotoaparátu

Klíčovými parametry nastavení expozice snímků jsou především clona, expoziční čas a ISO. Tyto tři parametry dohromady tvoří takzvaný expoziční trojúhelník (O'Connor et al. 2017)

#### 3.4.1.1 Clona

Nastavení clony definuje množství světla, které vniká do optické soustavy fotoaparátu a přímo ovlivňuje expozici a ostrost fotografie. Velikost clony se popisuje tzv. clonovým číslem, což je podíl ohniskové vzdálenosti a průměru otvoru, kterým vniká světlo do fotoaparátu.

Vyšší hodnoty clonového čísla znamenají menší otvor a zároveň pro výslednou fotografii také větší hloubku ostrosti, tedy rozsah objektů, které budou ostré.

Nastavení clony má také vliv na vznik optických vad a dalších jevů ovlivňujících ostrost fotografie.

Optimální nastavení clony pro daný fotoaparát/objektiv, kdy dochází k nejmenšímu zkreslení obrazu vlivem vad, se označuje jako tzv. sweet spot. Pro snímkování lesních porostů se doporučuje nastavení clony odpovídající právě této hodnotě (Kuželka a Surový 2017).

#### 3.4.1.2 Expoziční čas

Expoziční čas je doba, po kterou je v případě digitálního fotoaparátu zachytáváno světlo na obrazovém senzoru během expozice snímku. Příliš dlouhý expoziční čas může vést ke vzniku pohybové neostrosti výsledného snímku.

Při snímkování z bezpilotních prostředků je možné odhadnout maximální expoziční čas, při kterém nedojde pohybem dronu k pohybové neostrosti, z rychlosti letu a pozemní vzorkovací vzdálenosti (GSD) viz 3.4.2.3. Aby pohyb nebyl ve fotografii patrný, je nezbytné, aby vzdálenost, kterou bezpilotní prostředek uletí během exponování snímku, byla menší, než polovina GSD (Kuželka a Surový 2017).

(O'Connor et al. 2017) uvádí že uletěná vzdálenost během expozice by měla být menší než 1,5násobek GSD

### 3.4.1.3 ISO

Hodnota ISO určuje nastavení citlivosti snímače fotoaparátu na dopadající světlo. Vyšší hodnoty ISO odpovídají vyšší citlivosti. Zároveň ale dochází ke snížení kvality snímku, především ke zvýšení šumu. Proto je v praxi třeba nastavovat co nejnižší hodnoty ISO, při kterých ale ještě stále dochází ke správné expozici snímku v závislosti na nastavené cloně a expozičním čase (Kuželka a Surový 2017).

## 3.4.2 Parametry letové mise

### 3.4.2.1 Výška letu

Výška letu má zásadní vliv na prostorové rozlišení pořízených snímků. Čím nižší výška tím detailnější snímek. Zároveň je výška letu určující pro plochu povrchu pokrytou jedním snímkem a tím pro množství snímků nezbytných k pokrytí dané oblasti při dodržení nezbytných překryvů. Hledání vhodné výšky je tak hledáním kompromisu mezi potřebným detailem a efektivitou.

(Udin a Ahmad 2014) porovnává geografickou přesnost modelu odvozeného ze snímků z UAV pořízených při různých výškách nad terénem 40, 60, 80 a 100 m. Střední chyba se pohybovala v rozmezí od 0,249 po 0,296 metrů. Podle těchto závěrů je tedy možné dovozovat, že z pohledu geografické přesnosti není vliv výšky v uvedeném intervalu nijak zásadní.

### 3.4.2.2 Rychlost letu

Rychlost je opět jedním z parametrů letu, který má zásadní dopad na kvalitu pořízených snímků a zároveň na velikost území, které lze nasnímat během jedné mise, jejíž délka je omezená kapacitou akumulátorů UAV. Optimální rychlost letu tak představuje kompromis, při kterém je rychlost dostatečně pomalá na to, aby nedocházelo k rozmazání snímků vlivem pohybu (zde je značná závislost na světelných podmínkách, které určují rychlost závěrky) a zároveň nedochází ke zbytečnému omezení rozsahu snímaného území. Základní limity rychlosti ve vztahu k expozičnímu času jsou uvedeny v kapitole 3.4.1.2.

### 3.4.2.3 Prostorové rozlišení

Prostorové rozlišení snímku popisuje jeho geometrickou kvalitu a určuje, jaký typ objektů bude možné korektně zobrazit. Prostorové rozlišení snímku lze popisovat pomocí různých parametrů.

V literatuře nejčastěji zmiňovaným parametrem bývá tzv. pozemní vzorkovací vzdálenost – *Ground Sampling Distance* (GSD), což je vzdálenost, v pozemních jednotkách, mezi středy dvou nejbližších prvků obrazu (dva obrazové body, pixely snímku). Jedná se nicméně o čistě teoretickou hodnotu, která bere v úvahu pouze geometrii snímače a vzdálenost od zobrazovaných objektů (Orych 2015).

Skutečné rozlišení senzoru závisí na dalších limitujících faktorech zobrazovacího systému, který nikdy nemá 100% přenos a obvykle zavádí další artefakty. Pro určení skutečného prostorového rozlišení snímku je možné využít tzv. pozemní rozlišovací vzdálenost – *Ground Resolved Distance* (GRD). GRD snímku je určována na základě vizuální analýzy speciálních kalibračních cílů. (Orych 2015)

Jedním z vhodných kalibračních cílů je tzv. Siemens star. Má podobu kruhu rozděleného do pravidelných kontrastních sektorů. Počet sektorů se může lišit, čímž umožňuje různé úrovně přesnosti. Změřením průměru středu cíle, který se na snímku jeví jako rozmazaný je možné určit GRD (Orych 2015)(Dabrowski et al. 2015).

Informace o konkrétních požadavcích, respektive podmínkách, které musí být splněny, aby bylo dosaženo očekávané kvality výstupu, v tomto případě prostorového rozlišení, nejsou zatím v literatuře dostatečně podrobně popsány (Lee a Sung 2016)(Meißner et al. 2018).

Poměrně málo zkoumanou oblastí se jeví rovněž stanovení potřebného prostorového rozlišení, nebo GSD, respektive GRD, které umožní rozpoznání určitých objektů na snímku. Jiné rozlišení bude nezbytné pro rozpoznání korun stromů ve stádiu kmenoviny a jiné pro určení počtu jedinců obnovy.

(O'Connor et al. 2017) uvádí jako minimum pro zobrazení určitého objektu alespoň pět pixelů – to znamená, že pro zobrazení objektu o velikosti 10 cm musí být GSD maximálně 2 cm.

(Pouliot et al. 2002) uvádí pro zobrazení korun jedinců v rámci obnovy alespoň 15 pixelů na jeden stromek.

## 3.5 Individuální a plošný přístup

Při odhadech jednotlivých parametrů lesních porostů na základě dálkového průzkumu země (DPZ) se v literatuře vyskytují v zásadě dva přístupy. První z nich je založen na identifikaci jednotlivých stromů – *Individual Tree Detection* (ITD) a určení příslušné veličiny pro tento strom. Druhý přístup je založen na odhadu příslušné veličiny pro určitou plochu – *Area Based Approach* (ABA). ITD by primárně mělo přinášet detailnější a lepší výsledky, ale díky značným problémům při identifikaci jednotlivých jedinců tomu tak v řadě případů není (Tompalski et al. 2015).

V rámci individuálního přístupu je vždy východiskem identifikace jednotlivého stromu, pro níž existuje řada metod, které lze podle (Ke a Quackenbush 2011) rámcově zatřídit do čtyř skupin:

- filtr lokálního maxima -*Local Maximum Filtering* (LMF),
- binarizace snímku (image binarization),
- analýza měřítka (scale analysis) a
- template matching.

LMF je poměrně často využívaný postup založený na hledání nejvyšších bodů mračna, nebo rastru v určitém prostoru, který je označován jako okno. Stanovení optimální velikosti okna, v němž se identifikuje maximální výška je naprosto klíčovým faktorem pro úspěšnost metody. Příliš velké okno vede k opominutí některých stromů, příliš malé okno naopak přináší nesprávnou identifikaci více vrcholů v rámci koruny jednoho stromu. Proto bylo v řadě studií místo pevné velikosti okna využito okno variabilní, které, zvláště u rozmanitějších lesních porostů, přináší lepší výsledky. Volba optimální šířky okna je předmětem řady inovativních přístupů, jako třeba využití semivariance sousedních pixelů (Wulder et al. 2000), kontextuální analýzy (Culvenor 2002), nebo modelu šířky koruny (Popescu et al. 2003).

### 3.5.1 Model šířky koruny

Množství studií potvrzuje, že rozměry koruny ovlivňuje celá řada parametrů mimo samotnou výšku stromu. Ta vykazuje spíše menší korelaci s rozměry koruny a proto modely pro odhad rozměrů koruny pracují častěji s jinými nezávislými

proměnnými, nejčastěji s výčetní tloušťkou (Fu et al. 2013)(Gill et al. 2000)(Bechtold 2003).

Ovšem pro využití modelu šířky koruny v rámci LMF nejsou zpravidla dostupné jiné vstupní parametry než právě výška. Jako možné řešení se nabízí využití modelu se smíšenými efekty, do kterého vstupuje jako náhodný efekt lokalita. Lokální kalibrace takového modelu (Lappi 1991)(Lynch et al. 2005) by mohla pomoci k odvození optimálního odhadu šířky koruny na dané lokalitě, který by mohl následně posloužit jako vhodný rozměr plovoucího okna pro ITD pomocí LMF.

Lokální kalibrace modelu je často využívaný postup například pro modely výšek(Lynch et al. 2005)(Trincado et al. 2007) objemu(Lappi 1991)(Calama a Montero 2006) nebo morfologických křivek(Trincado a Burkhart 2006). Tento postup umožňuje efektivní využití modelů se smíšenými efekty a přináší kvalitativní nárůst spolehlivosti odhadů na základě pouze malého počtu kalibračních měření.

### **3.6 Zkušenosti s využitím bodových mračen pro odvozování dendrometrických veličin a dalších charakteristik lesních porostů**

Přesnost dosahovaná při odhadu vybraných parametrů lesního porostu prostřednictvím UAV se značně liší mezi jednotlivými studiemi. Příčiny rozdílů spočívají pravděpodobně jak v použitých metodách a jejich konkrétním nastavení, tak v různém vybavení a také v rozdílných konkrétních podmínkách. Severské jehličnaté lesy se svou obecně jednodušší strukturou dosahují lepších výsledků než bohatěji strukturované listnaté a smíšené lesy. Obdobně v rovinných terénech lze očekávat dosažení lepších výsledků než v horách (Puliti et al. 2015).

#### **3.6.1 Identifikace jednotlivých stromů**

Při porovnání výsledků získaných analýzou bodového mračka vytvořeného postupem SfM s daty naměřenými na zkusných plochách (Puliti et al. 2015) uvádí u parametru počet stromů hodnotu relativní střední kvadratické chyby (Relative RMSE – rRMSE) ve výši 39%. V rámci stejného experimentu dosahuje podstatně

lepších výsledků při odhadech porostních dendrometrických veličin – horní výšky, kruhové základny i zásoby (rRMSE 3,64%, 15,38% respektive 14,95%).

Úspěšnosti detekce jednotlivých stromů v rozmezí 49 až 75% v rámci DAP bodových mračen rekonstruovaných SfM postupem ze snímků pořízených pomocí UAV s pevným křídlem dosahoval (Guerra-Hernández et al. 2018). Přitom lepších výsledků 75% dosahovalo DAP bodové mračno vzniklé ze snímků pořízených za optimálních světelných podmínek jasného dne na začátku září v porovnání s 49% u DAP mračna ze snímků vzniklých za slabšího osvětlení v průběhu listopadového dne s vyšší oblačností.

(Nevalainen et al. 2017) uvádí dobré výsledky při identifikaci jednotlivých stromů v DAP bodovém mračnu (rRMSE 10%). Jako klíčové faktory, ovlivňující úspěšnost detekce jednotlivých stromů uvádí jednak kvalitu bodového mračna (negativní vliv například velkého zastínění při snímkování apod.) a dále pak postavení stromu v rámci výškové struktury porostu, kde k horším výsledkům při identifikaci dochází u stromů v podúrovni. Jako další významný faktor ovlivňující úspěšnost identifikace uvádí také druh dřeviny, kde borovice a smrk vykazovaly vyšší pravděpodobnost úspěšné identifikace než modřín (rRMSE 9, 10 respektive 16%).

(Kato a Gougeon 2012) s využitím pokročilých postupů (kombinace automatické identifikace vrcholů stromů a korun) při vyhodnocování multispektrálních leteckých snímků dosahují odchylek 2,3% až -15,8% při porovnání vyhodnoceného počtu stromů s počtem kmenů zjištěných pozemním šetřením. Zdůvodnění rozdílů v dosažených výsledcích přikládá mimo jiné i vlivu druhu dřeviny.

Rozdílné výsledky v závislosti na dřevině přináší také (Sperlich et al. 2008) při identifikaci jednotlivých stromů v jehličnatém a listnatém lese (úspěšnost identifikace jednotlivých stromů 87,7% respektive 13,3%). Jako další faktor ovlivňující úspěšnost uvádí hustotu porostu (zápoj), kterou zmiňuje jako jednu z předpokládaných zásadních příčin nízké úspěšnosti u listnatého lesa.

(Jaakkola et al. 2017) dokumentuje využití UAV neseného laserového scanneru, s jehož využitím dosahuje 100% úspěšnosti při identifikaci dominantních stromů (84,2% v případě všech stromů). Zároveň autoři zdůrazňují význam identifikace jednotlivých stromů pro odhady dalších dendrometrických veličin.

(Wang et al. 2016) dosahoval při použití různých metod pro identifikaci jednotlivých stromů úspěšnosti mezi 50 a 140%.

### 3.6.2 Výška

Odhad výšky jednotlivých stromů, nebo různých typů výšek jako porostní dendrometrické veličiny, na podkladu fotogrammetrických metod je poměrně častým předmětem zájmu řady studií. Tyto odhady sdílí stejné problematické momenty jako výše zmiňovaná identifikace jednotlivých stromů.

Hlavním problémem využití SfM pro tento účel je fakt, že pro digitální výškový model CHM (který vzniká jako rozdíl digitálního modelu povrchu DSM a digitálního modelu terénu DTM) a z něj vycházející odhad výšky stromů je vyžadováno snímků jak špiček korun stromů, tak bodů terénu. Jestliže koruna stromu stíní body pod ním, není možné vytvořit v části pod stromem digitální model terénu (Wallace et al. 2016).

Stejně tak (Mlambo et al. 2017) uvádí, že při porovnávání hodnot výšek stromů zjištěných pomocí metody SfM a pozemním měřením docházelo k poměrně slabým výsledkům v porostech s vysokým zápojem, kde samotná metoda SfM nebyla schopná určit dostatek bodů, které by reprezentovaly zem a umožnily tak vytvoření DTM pro odvození výšky z digitálního modelu povrchu.

V případě z lesnického pohledu řídkých porostů olivových sadů dosahovali (Zarco-Tejada et al. 2014) při odhadu výšky na základě SfM generovaného CHM výsledků s rRMSE 13,3%.

Lepších výsledků v lesních porostech lze dosáhnout, mimo jiné i díky využití georeferencování pomocí zaměření referenčních bodů (Panagiotidis et al. 2016). U odhadu výšky jednotlivých stromů na základě SfM dosahuje rRMSE 12,62%.

Problémy s nepřesným DTM vzniklým za pomoci SfM úspěšně eliminuje využití DTM z jiného zdroje, například z laserového skenování. (Messinger et al. 2016) dokumentuje úspěšné užití SfM tímto způsobem pro odhady výšek a jejich prostřednictvím zásob uhlíku.

(Lisein et al. 2013) využívá SfM technologie v kombinaci s ALS DTM pro odhad výšek jednotlivých stromů značně diferencovaných listnatých porostů, kde dosahuje rRMSE 4,7%. U odhadu horní výšky (dominant height), jako porostní charakteristiky se pak dostává k hodnotě rRMSE 8,4%.

Obdobně (Puliti et al. 2015) dosahuje s použitím SfM a ALS DTM u odhadu horní výšky rRMSE 3,6%

Další možnosti zpřesňování spočívají v doplnění dat získaných pomocí UAV o data sebraná s využitím pozemní fotogrammetrie. (Mikita et al. 2016) popisuje postup, při kterém jsou data pořízená UAV kombinována s daty odvozenými z pozemního snímkování za pomoci kamery nesené měřičem při pohybu v porostu. Touto metodou bylo dosaženo vysoké přesnosti při stanovení celé řady dendrometrických veličin, jako je počet stromů (pozice jednotlivých stromů byly určeny s RMSE 0,463m), výška (RMSE 1,016m), tloušťka (RMSE 0,911cm) a objem jednotlivého kmene (RMSE 0,082m<sup>3</sup>).

(Jaakkola et al. 2017) s využitím UAV neseného laserového scanneru provádí sběr dat jak při letu nad porostem, tak ve vlastním porostu. Data pořízená během letů v porostu umožňují odhad výčetní tloušťky s rRMSE 10,4%. Při odhadech výšky, výčetní kruhové základny a objemu jednotlivého kmene dosahuje rRMSE do 20% (5,16%; 19,73% a 19,26%)

Vysoké operativnosti a finanční dostupnosti pořizování snímků pomocí UAV, společně s dostatečnou přesností odhadu výšky úspěšně využívá (Dempewolf et al. 2017) pro zkoumání výškového přírůstu v průběhu periody dvanácti týdnů.

### 3.6.3 Vliv hustoty bodového mračka

Hustota bodového mračka do určité míry předznamenává detail, v jakém je bodové mračko schopné zachytit realitu.

Při porovnávání ALS bodových mraček s různou hustotou v rozmezí 5 až 20 bodů/m<sup>2</sup> dochází (Yao et al. 2014) k závěru, že zvyšování hustoty mračka nad hodnotu 10 bodů/m<sup>2</sup> neznamena automaticky zlepšení výsledků identifikace jednotlivých stromů.

Vliv hustoty ALS mračka na spolehlivost určení vybraných dendrometrických veličin: Loreyova výška (průměrná výška vážená kruhovou základnou), kruhová základna, zásoba a počet stromů, dokumentuje (Magnussen et al. 2010). Porovnával mračka s hustotou 0,25 až 2 body/m<sup>2</sup>. U všech dendrometrických veličin byla zachycena rostoucí spolehlivost s nárůstem hustoty bodového mračka, s nejvýznamnějším zpřesněním u veličiny počtu stromů.

Nárůst spolehlivosti identifikace jednotlivých stromů s rostoucí hustotou bodového mračka uvádí také (Kandare et al. 2016). V rámci porovnávaných hustot od 4 do 60



bodů/m<sup>2</sup> docházelo ke zlepšení výsledků identifikace, nicméně nárůst spolehlivosti se s rostoucí hustotou zpomaloval a stával se spíše marginální.

## 4 Metodika

Vlastní práce byla rozdělena do několika na sebe navazujících částí v souladu s cíli:

1. Prostorové rozlišení snímků v závislosti na různých vstupních podmínkách.
2. Kvalita fotogrammetrických (DAP) bodových mračen odvozených ze snímků pořízených v různých vstupních podmínkách.
3. Vliv vstupních podmínek a kvality bodového mračka na přesnost odvozování vybraných dendrometrických veličin.

Snímkování bylo v rámci celé práce prováděno pomocí kvadrokoptéry DJI Phantom 3 Professional (DJI 2017) s integrovaným fotoaparátem DJI FC300x Obrázek 6, Tabulka 2.



Obrázek 6 DJI Phantom 3 Professional

**Tabulka 2 Specifikace DJI FC300X fotoaparátu**

Senzor	Sony EXMOR 1/2.3" CMOS Effective pixels: 12.4 M
Objektiv	20 mm (35 mm format equivalent) f/2.8 focus at ∞
ISO rozsah	100-1600 (photo)
Čas elektronické závěrky	8 - 1/8000 s
Velikost obrazu	4000×3000px

Všechny výpočty byly provedeny v programu R-Studio verze 1.4.1103 (RStudio Team 2019) s R verzí 4.0.3 (R Core Team 2020) s využitím následujících knihoven: LidR(Roussel a Auty 2021), ForestTools(Plowright a Roussel 2021), sjPlot(Lüdecke 2021), JTools(Long 2020), Readr(Wickham a Hester 2020), GGplot2(Wickham 2016), gtsummary(Sjoberg et al. 2021)

## 4.1 Prostorové rozlišení snímků v závislosti na vnějších podmínkách

### 4.1.1 Odvození pozemní vzorkovací vzdálenosti (GSD)

Pojem pozemní vzorkovací vzdálenost (GSD) na digitálním snímku označuje skutečnou velikost povrchu reprezentovanou jedním pixelem snímku. Jedná se o teoretickou hodnotu, která vychází pouze ze známých hodnot geometrie fotoaparátu (rozlišení senzoru a ohnisková vzdálenost objektivu) a vzdálenosti k zobrazovanému povrchu, nebo objektu. Další faktory, jako například optické vady, nebo obrazový šum nejsou brány v potaz (Orych 2015).

GSD lze odvodit na základě skutečné velikosti pixelu senzoru  $x$ , ohniskové vzdálenosti objektivu  $f$  a vzdálenosti mezi objektivem a cílem  $h$  pomocí vztahu Eq 2.

$$GSD = \frac{x * h}{f} \quad \text{Eq 2}$$

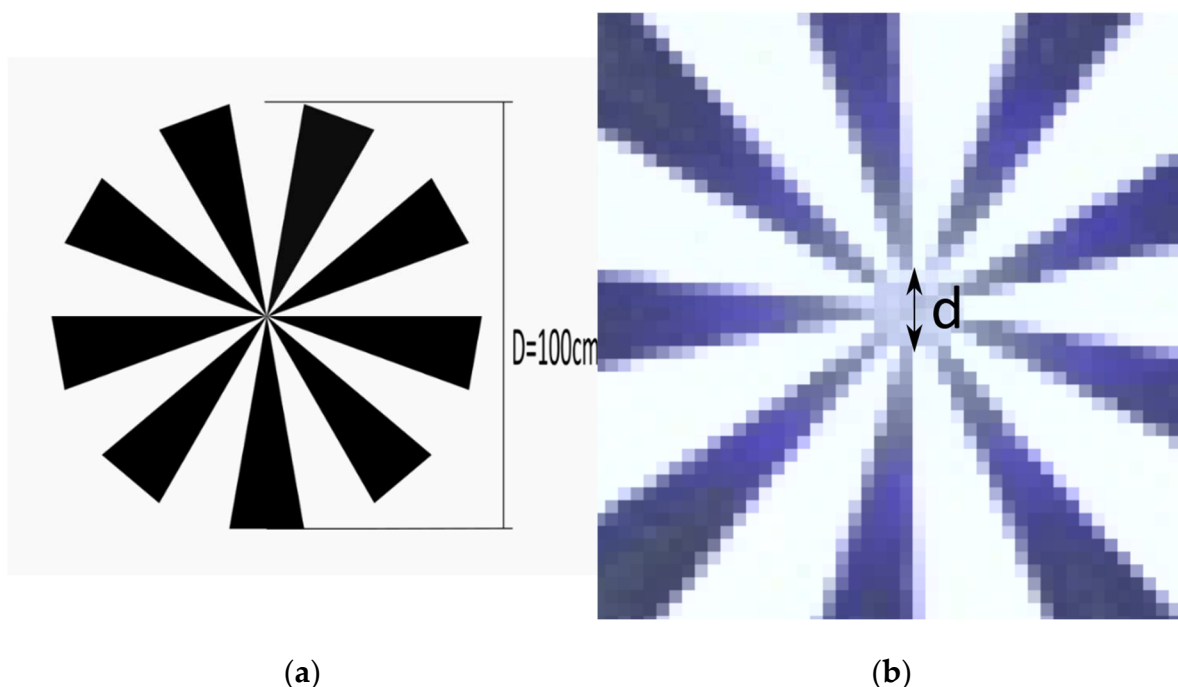
### 4.1.2 Odvození pozemní rozlišovací vzdálenosti (GRD)

Pozemní rozlišovací vzdálenost (GRD) představuje nejmenší rozpoznatelný prvek na snímku. Může být určena za pomoci vizuální analýzy speciálních kalibračních

cílů, jako je třeba Siemens star (Orych 2015). Na rozdíl od GSD je GRD vyhodnocována jako výslednice všech faktorů ovlivňujících prostorové rozlišení snímku.

Siemens star představuje kalibrační cíl vhodný pro stanovení GRD bez nutnosti dalšího speciálního vybavení. V praxi se využívají dva typy tohoto kalibračního cíle – sinusový pro laboratorní účely a binární pro venkovní testy. Binární Siemens star cíl je tvořený několika radiálními sektory se střídající se černou a bílou barvou Obrázek 7(a).

GRD se s využitím kalibračního cíle Siemens star s  $n$  sektory a průměrem  $D$  odvodí podle zjištěného průměru rozostřeného cíle  $d$  viz Obrázek 7(b) pomocí vztahu Eq 3.



Obrázek 7 (a) Siemens star kalibrační cíl s počtem sektorů  $n=18$ ; (b) Rozostřený střed kalibračního cíle o průměru  $d$


$$GRD = \frac{\pi * d}{n} \quad \text{Eq 3}$$

### 4.1.3 Pořízení snímků

Pro ověření hodnot GRD byl využit kalibrační cíl Siemens star s  $n=18$  segmenty (9 bílých a 9 černých) s průměrem 100 cm vytištěný na papír a zalaminovaný pro

ochranu před poškozením Obrázek 7(a). Cíl o těchto rozměrech umožňuje teoreticky zjišťovat GRD v rozmezí od 0 do 17,453 cm.

Cíl byl umístěn na zpevněné ploše v blízkosti Ústavu pro hospodářskou úpravu lesů Brandýs nad Labem v oblasti umožňující bezpečné nerušené snímkování pomocí UAV Obrázek 8.




**Obrázek 8 Snímek kalibračního cíle Siemens star (a) letová výška 5m;(b) letová výška 30m**

Bylo provedeno opakované snímkování Siemens star za různých světelných podmínek, v různých výškách do maxima 150 m a v různých horizontálních rychlostech od nuly do 15 m/s.

Snímkování proběhlo v průběhu čtyř dní, tak, aby bylo dosaženo co nejrůznějších světelných podmínek. Snímky byly pořizovány v různých výškách přibližně po 5 metrech a v různých horizontálních rychlostech letu UAV. Úhel fotoaparátu byl nastaven na 90stupňů (nadir), hodnota ISO byla nastavena na konstantní hodnotu (ISO 100). Fotoaparát DJI FC300x je vybaven pevnou clonou. Díky tomu bylo možné využít hodnotu expozičního času pro popis světelných podmínek v době pořízení snímku.

Někteří autoři zmiňují závislost GRD na vzdálenosti od středu snímku (Honkavaara et al. 2006). Proto byla nejprve provedena selekce snímků, kdy byly vyloučeny všechny snímky, na nichž byl kalibrační cíl zachycen mimo střední oblast, viz Obrázek 9, tak aby byl vliv této proměnné eliminován.



**Obrázek 9 Střední oblast (šedě) snímku**

Ze snímků byly s využitím aplikace Exiftool (Harvey 2016) extrahována metadata o relativní výšce letu, X,Y a Z vektorech rychlosti letu, expozičním čase a hodnoty ISO. Bylo ověřeno dodržení konstantních hodnot nastavení ISO. Byly vyloučeny všechny snímky s Z vektorem rychlosti letu větším než 0,1 m/s. Z jednotlivých vektorů rychlosti byla vypočítána celková rychlost letu.

Tabulka 3 shrnuje charakteristiky výsledné sady snímků podle jednotlivých letových dní.

**Tabulka 3 Přehled snímků kalibračního cíle**

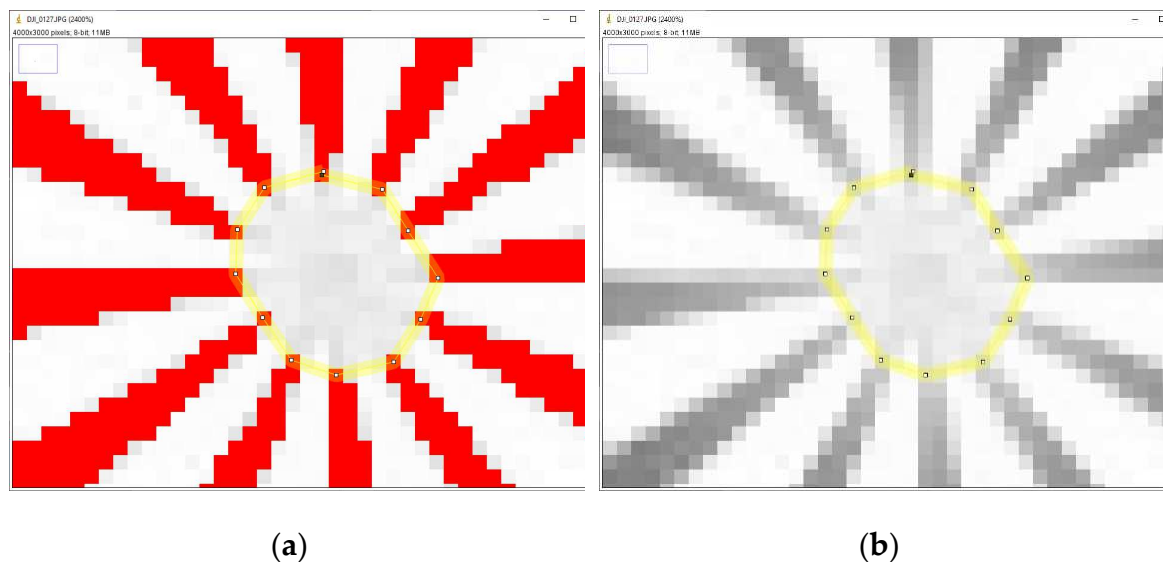
Datum	Počasí	Počet snímků	Výška		Rychlost		Expoziční čas	
			(m AGL)		(m/s)		(s)	
			min	max	min	max	min	max
2019-07-26	Jasno, velmi slabý vítr	21	4,9	105,2	0,0	0,1	1/1750	1/811
2020-01-17	Jasno, velmi slabý vítr	60	30,3	100,8	0,0	14,4	1/514	1/252
2020-10-08	Polojasno, slabý vítr	64	6,2	70,3	0,0	12,6	1/736	1/176
2020-10-24	Oblačno, slabý vítr	39	10,0	70,0	0,0	9,5	1/561	1/336

#### 4.1.4 Určení GRD

Na jednotlivých snímcích byl v programu ImageJ (Schneider et al. 2012) změřen obvod rozostřené oblasti kolem středu cíle. Pro dosažení vyšší objektivnosti měření byla nejprve provedena transformace RGB snímku do 8-bitové škály šedé s využitím funkce ImageJ Type/8-bit, která používá vztah  $\text{gray} = (\text{red} + \text{green} + \text{blue}) / 3$ . Ve výsledném snímku se tak hodnota každého pixelu pohybuje v rozmezí 0 až 255.

Pomocí funkce prahování Obrázek 10(a) byla zvýrazněna oblast s hodnotami mezi nulou a prahovou hodnotou, která byla vizuálně odvozena tak, aby dobře definovala rozostřenou oblast kolem středu. Následně byl v rámci zvýrazněné oblasti identifikován nejbližší bod každého z devíti tmavých radiálních sektorů směrem ke středu jako hranice rozostřené oblasti.

Vzhledem k tomu, že takto identifikovaná rozostřená oblast byla pouze zřídka kruhového tvaru, místo měření průměru byla změřena délka obvodu této oblasti viz žlutý polygon Obrázek 10.



Obrázek 10 Identifikace rozostřené středové oblasti s (a) a bez prahování (b)

Hodnota GRD byla následně vypočtena podle vztahu Eq 3 upraveného pro použití obvodu  $p$  Eq 4.

$$GRD = \frac{p}{n} \quad \text{Eq 4}$$

Rovněž byla vypočtena hodnota GSD podle vztahu Eq 2 na základě známých parametrů fotoaparátu a výšky letu.

Z takto zjištěných hodnot byla zkoumána závislost mezi GRD a GSD, letovou výškou, světelnými podmínkami a horizontální rychlostí při snímkování.


## 4.2 Kvalita fotogrammetrických (DAP) bodových mračen odvozených ze snímků pořízených v různých vstupních podmínkách

### 4.2.1 Výzkumné lokality

Byly zvoleny dvě výzkumné lokality s cílem výběru stanovišť se zastoupením nejčastějších dřevin v ČR, s variabilní prostorovou strukturou a také různým uspořádáním terénu. Obrázek 11, Tabulka 4.


Tabulka 4 Výzkumné lokality

Výzkumná lokalita	Skorkov	Skalice
Pozice WGS 84 (střed)	Lat: 50,2143906N, Lon: 14,7160739E	Lat: 49,9141571N, Lon: 14,8710025E
Plocha	9,309 ha	3,629 ha
Reliéf	rovina	svah se sklonem 20%
Nadmořská výška	188-190m m n.m.	399-431m m n.m.
Druhové složení	borovice(Pinus silvestris), duby (Quercus robur, Quercus rubra)	smrk (Picea abies), buk (Fagus sylvatica)



**Obrázek 11 Umístění výzkumných lokalit**


První z lokalit nazvaná Skorkov leží poblíž Staré Boleslavi. Nachází se zde porosty různých dřevin (s převahou Borovice lesní (*Pinus sylvestris*) a dubů (*Quercus robur*, *Quercus rubra*) v různých růstových fázích, od sotva zajištěných kultur až po porosty v mýtním věku. Jedná se o lokalitu s původně typickým borovým hospodářstvím realizovaným ve více méně pravoúhlých prvcích. Z tohoto uspořádání také vycházelo vytýčení výzkumné lokality, které při obdélníkovém tvaru respektuje hranice jednotek prostorového rozdělení lesa Obrázek 12.



**Obrázek 12 Výzkumná lokalita Skorkov**



Druhá lokalita, označená jako Skalice, leží na území ŠLP Kostelec n.Č.l. v lesním komplexu nad obcí Stříbrná Skalice. Převažuje zde Smrk ztepilý (*Picea abies*) a Buk lesní (*Fagus sylvatica*) s poměrně pestrou prostorovou strukturou Obrázek 13.



Obrázek 13 Výzkumná lokalita Skalice

### 4.2.2 Letové mise

Na každé z výzkumných lokalit bylo provedeno snímkování ve více letových misích, v různých podmínkách (letová výška, světelné podmínky). Celkem bylo provedeno 26 standardních letových misí ve čtyřech letových výškách s cílem postihnout různé světelné podmínky Tabulka 5.

Ve všech případech byla letová mise plánována s podélným i bočním překryvem 75 %. Dráha letu byla orientována rovnoběžně s delší stranou výzkumné lokality Obrázek 14(a).

Zároveň byly provedeny i tři zvláštní mise s cílem zajistit dostatek snímků pořízených z různých úhlů pro provedení optimalizované kalibrace fotoaparátu v programu WebODM. V tomto případě byly provedeny dvě mise (letová výška 100 a 150 m) s dráhou letu kolmou na delší stranu výzkumné lokality Obrázek 14(b) a


jedna mise (letová výška 100 m) s úhlem kamery 75 stupňů pro získání non-nadir snímků.

Ve všech případech byl využit UAV DJI Phantom 3 Professional s integrovaným fotoaparátem FC300X Tabulka 2 s pevnou clonou a konstantním nastavením hodnoty ISO (DJI 2017). Pro plánování letové mise byla využita aplikace DroneDeploy (DroneDeploy 2020) a v případě speciální mise s úhlem kamery 75 stupňů Pix4D (Pix4D SA 2020), protože DroneDeploy toto nastavení neumožňuje.

**Tabulka 5 Detaily letových dní**

Datum	od	do	Lokalita	Počet misí	Výška letu (m) <sup>*)</sup>				Počasí
					75	100	125	150	
17.06.2020	12:54	14:01	Skorkov	2		a		a	zataženo, vysoká oblačnost, slabý vítr
20.08.2020	06:35	07:18	Skorkov	4	a	a	a	a	jasno, klid
21.08.2020	10:31	11:14	Skorkov	4	a	a	a	a	jasno, velmi slabý vítr
03.09.2020	11:21	12:14	Skalice	4	a	a	a	a	oblačno, proměnlivý vítr (termika)
09.09.2020	11:38	12:14	Skalice	4	a	a	a	a	jasno, velmi slabý vítr
19.10.2020	12:45	13:51	Skorkov	4+3	a	abt	a	ab	vysoká protrhávající se oblačnost, slabý vítr
11.11.2020	11:35	12:10	Skalice	4	a	a	a	a	zataženo, vysoká oblačnost, klid

<sup>\*)</sup> a: dráha letu rovnoběžná s delší stranou výzkumné lokality, b: dráha letu rovnoběžná s kratší stranou výzkumné lokality, t: dráha letu rovnoběžná s delší stranou výzkumné lokality úhel fotoaparátu 75 stupňů.



(a)

(b)

**Obrázek 14** Dráha letu u standardní (a) a zvláštní (b) mise

Pro každou z výzkumných lokalit bylo zároveň pořízeno prostřednictvím bezpilotního leteckého laserového skenování (ULS) bodové mračno pomocí sestavy UAV VUX-SYS (RIEGL Laser Measurement System GmbH, Horn, Austria) skládající se z UAV RiCOPTER, VUX-1UAV laser scanner a AP-20 inertial measurement unit (IMU) (Riegl 2019).

Výsledek tohoto skenování byl následně využit jednak jako referenční data pro porovnání kvality DAP bodových mračen, pro odvození DTM a také jako data pro zhodnocení výsledků využití různých funkcí pro určení šířky plovoucího okna v rámci LMF procedury při identifikaci jednotlivých stromů.

### 4.2.3 Zpracování snímků

Pomocí Exiftool aplikace (Harvey 2016) byly z jednotlivých snímků extrahovány EXIF informace o parametrech nastavení fotoaparátu (expoziční čas, clona, ISO) a rychlosti letu (X,Y,Z vektory). Jak bylo již výše zmíněno, clona je v případě tohoto snímače pevná a hodnota ISO byla nastavena jako konstantní (100), proto je možné hodnoty času závěrky využít jako indikátor světelných podmínek v době pořízení snímku.

Pro každou ze sad snímků pořízených v průběhu standardních 26 letových misí bylo provedeno vyhodnocení průměrných hodnot expozičního času a rychlosti letu. Výstupy tohoto vyhodnocení jsou uvedeny v Tabulka 6.

**Tabulka 6 Charakteristiky sad snímků standardních letových misí**

<b>Charakteristika</b>	<b>Skalice, n = 12<sup>1</sup></b>	<b>Skorkov, n = 14<sup>1</sup></b>
Počet snímků	155 (95 to 248)	162 (98 to 252)
Výška letu (m AGL)		
75	3 (25%)	3 (21%)
100	3 (25%)	4 (29%)
125	3 (25%)	3 (21%)
150	3 (25%)	4 (29%)
Expoziční čas (s)	0,017 (0,004 to 0,040)	0,015 (0,004 to 0,067)
Rychlost letu (m/s)	9,04 (5,70 to 11,70)	9,46 (7,50 to 11,80)

<sup>1</sup>Průměr (Rozsah); n (%)

#### 4.2.4 Bodová mračna

Každá sada snímků pořízených v jednotlivých letových misích byla zpracována jak v programu Agisoft Metashape (Agisoft-LLC 2019) tak v programu WebODM (Toffanin et al. 2020) postupem Structure from Motion do podoby bodového mračna. V obou případech bylo využito standardní (defaultní) nastavení, protože odlišnosti obou programů neumožňují zcela objektivně nastavit obdobné parametry zpracování tak, aby bylo možné přímo porovnávat výstup. Defaultní hodnoty tak představují určitou porovnávací hladinu, u níž lze zároveň předpokládat, že představují dobré východisko pro další zpřesňování.

V případě WebODM byla navíc v další verzi využita možnost optimalizace stanovení vnitřních parametrů kamery. Tyto parametry jsou standardně odhadovány během zpracování snímků v rámci procesu vnitřní kalibrace. Manuál (Toffanin 2019) s odkazem na (Fraser 2018) doporučuje pro zlepšení kvality výstupů uložit výsledky vnitřní kalibrace při zpracování sady snímků pořízených v co nejrozmanitějších výškách a úhlech (tedy nejen nadir snímky). Pro tento účel byla provedena rekonstrukce bodového mračna ze všech snímků pořízených v rámci letového dne 19.10.2020 – tedy ze čtyř standardních a tří speciálních letových misí (celkem 1176 snímků), včetně mise s úhlem fotoaparátu 75 stupňů (tedy 15 stupňů

od nadir směru). Výsledky vnitřní kalibrace (nikoliv mračno jako takové) vzniklé v rámci této rekonstrukce byly následně využívány i při rekonstrukci bodových mračen z datových sad jednotlivých misí.

Každá datová sada tak byla zpracována celkem třikrát viz Tabulka 7.

**Tabulka 7 Přehled značení jednotlivých nastavení**

<b>Program</b>	<b>Nastavení</b>	<b>Označení</b>
Agisoft Metashape	Default	Metashape
WebODM	Default	WebODMStd
WebODM	Default + uložené výsledky vnitřní kalibrace	WebOdmEnh

Výstupem těchto zpracování je tedy celkem 54 bodových mračen ve formátu laz.

Bodové mračno z ULS skenování bylo zpracováno ze vstupních dat pořízených UAV VUX-SYS za pomoci vyhlazeného odhadu dráhy letu (SBET) na základě postprocesingu z Trimble VRS Now. Vše zpracováno v rámci prostředí RiProcess s RiPrecision modulem (Riegl 2019). Ve stejném prostředí byla provedena i klasifikace bodového mračna. Skenování ani příprava ULS bodového mračna nebylo předmětem této práce. Detaily postupu byly shodné jako podrobnosti popsané v části 4.2 dizertační práce Martina Slavíka (Slavík 2020).

## 4.2.5 Porovnání bodových mračen

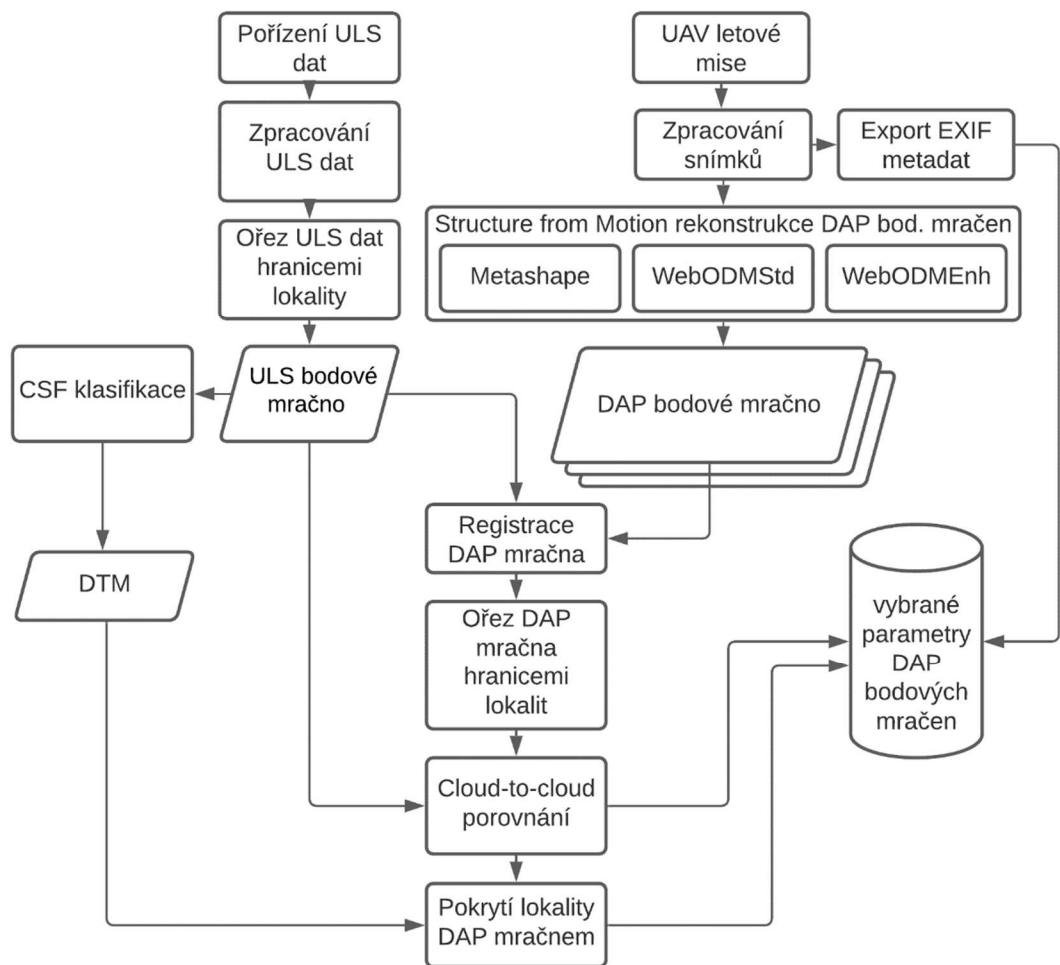
Porovnávání bodových mračen bylo provedeno v programu Cloudcompare (Cloudcompare 2021).

Nejprve byla připravena referenční data. ULS mračno bylo pro obě výzkumné lokality oříznuto hranicemi výzkumné lokality (segmentace pomocí polygonu hranice lokality importovaného v rámci shapefile).

Byl také připraven digitální model terénu (DTM) odvozený z ULS bodového mračna na základě klasifikace pozemních bodů pomocí Cloth Simulation Filter (CSF)(Zhang et al. 2016) pluginu (nastavení General settings: Relief; Slope processing: enabled; Cloth resolution 1.0; Max iterations: 1000; Classification threshold: 0.5) v Cloudcompare.

Porovnání jednotlivých DAP mračen s referenčním ULS mračnem bylo následně provedeno v těchto krocích:

1. Registrace DAP mračna (Tool/Registration/Fine Registration(ICP)) s využitím ULS mračna jako reference.
  2. DAP mračno bylo oříznuto hranicemi výzkumné lokality (segmentace pomocí polygonu importovaného v rámci shapefile)
  3. Bylo provedeno porovnání polohové přesnosti DAP mračna pomocí vzdálenosti jednotlivých bodů obou (DAP a referenční ULS) mračen (Tools/Distances/Cloud distances). Výsledek tohoto porovnání je ukládán do nového skalárního pole DAP mračna.
  4. Export statistik (průměr C2CDistMean a směrodatná odchylka C2CDistStdDev) tohoto nového skalárního pole a také počtu bodů oříznutého DAP mračna do databáze.
  5. Protože hustota DAP mračen byla značně proměnlivá v rámci výzkumné lokality, byla dále ještě provedena identifikace ploch terénu nepokrytých DAP mračnem pomocí nástroje Volume calculations (Tools/Volume/Compute 2.5D volume) mezi DAP mračnem a DTM. Výstupem tohoto procesu využitým dále byla hodnota pro nespárované body/buňky terénu - Non-matching cells Ground (NMGround) z níž bylo odvozeno pokrytí výzkumné lokality DAP bodovým mračnem.
- Přehled postupu prací při pořízení dat a dalšího zpracování DAP bodových mračen je uveden v diagramu Obrázek 15.




Obrázek 15 Postup pořízení a zpracování dat

## 4.3 Vliv vstupních podmínek a kvality bodového mračna na přesnost odvozování vybraných výstupů

### 4.3.1 Referenční data

Pro získání relevantních dat pro ověření úspěšnosti identifikace jednotlivých stromů v bodovém mračnu bylo provedeno pozemní šetření. V rámci lokality Skorkov bylo v průběhu letní sezóny roku 2020 založeno celkem 39 kruhových zkusných ploch Obrázek 16 s proměnlivou velikostí v závislosti na střední výšce porostu viz Tabulka 8.



Obrázek 16 Zkusné plochy na lokalitě Skorkov

Tabulka 8 Zkusné plochy

Typ plochy	Střední výška (m)	Poloměr plochy (m)	Plocha (m <sup>2</sup> )	Min. registr. hranice
1	<3	3,00	28,27	1,5 m výška
2	3-10	5,00	78,54	1,5 m výška
3	>10	12,62	500,00	7cm DBH

Na každé ze zkusných ploch byly změřeny průměry ve výčetní tloušťce 1,3 m (DBH) všech stromů přesahujících minimální registrační hranici. Zároveň bylo provedeno měření výšky pro náhodně vybrané vzorníky v počtu 1 až 5 podle výškové rozrůzněnosti na dané ploše. Rovněž byla změřena šířka koruny pro jeden (náhodně zvolený) z těchto výškových vzorníků na ploše. Pro měření koruny byl zvolen shodný postup jako v Národní inventarizaci lesů (NIL) (Adolt et al. 2013). U jedinců nehroubí, tedy s výčetní tloušťkou menší než 7cm, byla změřena pásmem největší a nejmenší šířka koruny, z nichž byla následně průměrem určena šířka koruny.



V případě jedinců hroubí byla korunová projekce zaměřena pomocí alespoň pěti bodů dobře definujících rozsah koruny pomocí FieldMap technologie. Ze zjištěné plochy polygonu definovaného těmito body (plocha korunové projekce) byla následně odvozena šířka koruny za předpokladu kruhového tvaru koruny.

Zkusné plochy byly podle maximální změřené výšky zařazeny do jedné ze čtyř skupin Tabulka 9.

**Tabulka 9 Rozdělení zkusných ploch podle maximální výšky**

Skupina	Výška (m)	
	od (>)	do(<=)
1	0	5
2	5	10
3	10	20
4	30	30

### 4.3.2 Model šířky koruny

Pro účely nastavení vhodné velikosti plovoucího okna v rámci procedury LMF při identifikaci jednotlivých stromů byl odvozen model závislosti šířky koruny na výšce stromu.

#### 4.3.2.1 Data

Pro odvození modelu byla využita data získaná v rámci NIL pracovníky Ústavu pro hospodářskou úpravu lesů Brandýs nad Labem v období mezi lety 2001 a 2015. Použitá data obsahují měření korunových projekcí a výšek více než 94 tisíc stromů z více než 22 tisíc inventarizačních ploch. Pro účely této práce byla šířka koruny odvozena z plochy korunové projekce za předpokladu jejího kruhového tvaru Tabulka 10.

**Tabulka 10 Přehled datové sady NIL**

<b>Charakteristika</b>	<b>n<sup>1</sup> = 94 066</b>
Inventarizační plocha	n = 22 532
Výška (m)	25 (4 až 54)
Šířka koruny (m)	5,57 (1,35 až 19,33)

Charakteristika	n <sup>1</sup> = 94 066
Skupina dřevin	
Borovice lesní	13 691 (15%)
Břízy	2 382 (2,5%)
Buk lesní	6 475 (6,9%)
Duby	6 728 (7,2%)
Habr obecný	890 (0,9%)
Jasany	1 340 (1,4%)
Javory	1 709 (1,8%)
Jedle bělokorá	1 202 (1,3%)
Modřín opadavý	4 300 (4,6%)
Olše	2 177 (2,3%)
Ostatní jehličnaté	763 (0,8%)
Ostatní listnaté měkké	2 672 (2,8%)
Ostatní listnaté tvrdé	970 (1,0%)
Smrk ztepilý	48 767 (52%)

<sup>1</sup>Průměr (Rozsah); n (%)

### 4.3.2.2 Model

Jednoduchý lineární model se smíšenými efekty byl odvozován opakovaně s různou transformací závislé i nezávislé proměnné pro dosažení optimálních výsledků. Jako nejlepší se osvědčil model ve tvaru Eq 5. využívající inventarizační plochu jako náhodný efekt. Tímto způsobem bylo možné vytvořit model, který bude následně možno kalibrovat pro určitou plochu pomocí několika změřených vzorků.

$$\ln(CW_{ki}) = \beta_0 + \beta_1 H_{ki}/100 + \alpha_{0k} + \alpha_{1k} H_{ki}/100 + e_{ki} \quad \text{Eq 5}$$

Kde  $CW_{ki}$  je šířka koruny stromu(m)  $i$  na ploše  $k$ ,  $H_{ki}$  je výška stromu(m)  $i$  na ploše  $k$ , tato proměnná musela být upravena (dělena 100) jinak nebylo dosaženo konvergence modelu.  $\beta_0$  a  $\beta_1$  odhadované pevné parametry populace,  $\alpha_{0k}$  a  $\alpha_{1k}$  jsou s nulovým očekáváním odhadované náhodné parametry pro plochu  $k$  a  $e_{ki}$  je náhodná reziduální chyba pro strom  $i$  na ploše  $k$ .

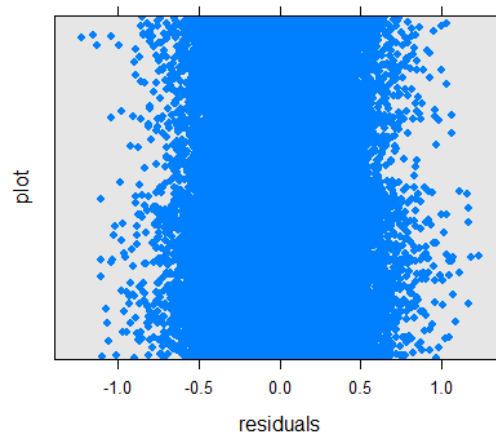

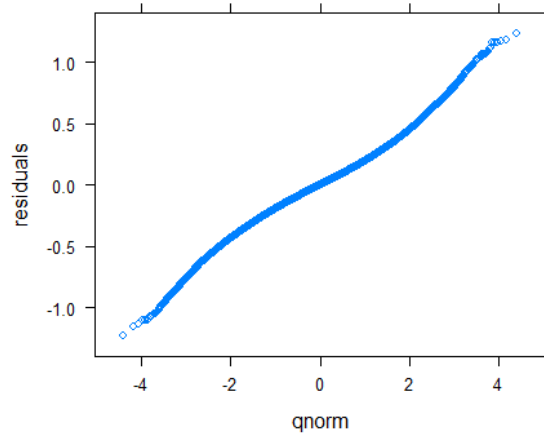

Parametry modelu byly nejprve odhadnuty s použitím celé datové sady. Výsledky tohoto modelu označeného jako model f1 jsou uvedeny v Tabulka 11 a Obrázek 17.

Z šetření na zkusných plochách v lokalitě Skorkov byla zjištěna převažující přítomnost pouze několika vybraných dřevin. Konkrétně Borovice lesní (*Pinus sylvestris*), Dubu letního (*Qercus robur*) a Dubu červeného (*Quercus rubra*). Proto byl následně odvozen stejný model pouze pro podskupinu datové sady obsahující záznamy skupin dřevin Borovice lesní a Duby. Model byl označen jako model f2 viz Tabulka 11 a Obrázek 18.



**Tabulka 11 Model f1 a model f2**


Pevné efekty	Model f1 ln(CW)			Model f2 ln(CW)		
	Odhad	Int. spol.	p	Odhad	Int. spol.	p
(Intercept)	0,9692	0.9552 – 0.9831	<0.001	1,0471	1.0140 – 1.0802	<0.001
H/100	2,9192	2.8671 – 2.9714	<0.001	2,7494	2.6134 – 2.8854	<0.001
Náhodné efekty						
$\sigma^2$		0,0579			0,0588	
$\tau_{0k}$		0,3248			0,3792	
$\tau_{1k}$		3,0351			4,7034	
$Q_{01k}$		-0,8865			-0,8578	
ICC		0,6090			0,6663	
$N_k$		22532			7009	
Pozorování		94066			20419	
Marginální $R^2$ / Podmíněné $R^2$		0,226 / 0,697			0,129 / 0,709	

Marginální a podmíněný koeficient determinace určeny podle (Nakagawa et al. 2017)



Obrázek 17 Model f1 - diagnostické grafy





Obrázek 18 Model f2 - diagnostické grafy

### 4.3.2.3 Kalibrace modelu

Lineární modely se smíšenými efekty umožňují kalibraci (odhad parametrů náhodných efektů) pro konkrétní novou lokalitu, která není zahrnuta ve vstupních datech modelu. Na základě několika měření závislé a nezávislé proměnné, v tomto případě výšky stromu a šířky koruny, provedených na konkrétní lokalitě je možné dosáhnout významného zpřesnění modelu pro tuto konkrétní lokalitu.

Odhad parametrů náhodného efektu byl proveden podle vztahu

$$\hat{a} = (Z' \hat{R}^{-1} Z + \hat{D}^{-1})^{-1} Z' \hat{R}^{-1} (y - \hat{\mu}) \quad \text{Eq 6}$$

Kde:  $\hat{a}$  je matice odhadovaných náhodných parametrů;  $Z$  je projekční matice spojená s náhodnými parametry;  $\hat{D}$  je odhad  $D = \begin{bmatrix} \text{var}(\alpha_{0k}) & \text{cov}(\alpha_{0k}, \alpha_{1k}) \\ \text{cov}(\alpha_{0k}, \alpha_{1k}) & \text{var}(\alpha_{1k}) \end{bmatrix} = \begin{bmatrix} \tau_{0k} & \rho_{01k} \\ \rho_{01k} & \tau_{1k} \end{bmatrix}$  matice variance a kovariance náhodných parametrů;  $\hat{R} = \hat{\sigma}_{e_{ki}}^2 \times I$  je odhad matice variance a kovariance residuálních chyb jednotlivých stromů,  $\hat{\sigma}_{e_{ki}}^2$  je druhá mocnina residuální standardní chyby;  $\hat{\mu}$  je vektor hodnot závislé proměnné odhadovaných na základě pouze pevných parametrů a  $y$  je vektor hodnot pozorování závislé proměnné na konkrétní lokalitě.

Pro ověření této kalibrace byl proveden náhodný výběr jedné inventarizační plochy (splňující podmínku alespoň 15 stromů s daty o koruně a výšce), která byla využita jako kalibrační. Model podle Eq 5 byl odvozen pro celou datovou sadu vyjma

kalibrační plochy. Následně byla provedena kalibrace modelu podle Eq 6 postupně pro 1, 3, 5 a 10 náhodně vybraných stromů z kalibrační plochy.

Odhad šířky koruny pro všechny stromy v rámci kalibrační plochy byl proveden jak podle modelu s pouze pevnými parametry, tak podle modelu s odhadnutými náhodnými parametry. Oba odhady byly porovnány se skutečnou hodnotou šířky koruny s využitím normalizované odmocniny střední kvadratické chyby (normalised Root Mean Square error nRMSE) Eq 7

$$nRMSE = \frac{\sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}}{\bar{y}} \quad \text{Eq 7}$$

Kde  $n$  počet zkusných ploch,  $y$  je pozorovaná hodnota,  $\hat{y}$  je odhadovaná hodnota a  $\bar{y}$  je průměr pozorovaných hodnot  $y$ .

#### 4.3.2.4 Kalibrace modelu pro výzkumnou lokalitu Skorkov

Pro kalibraci modelů popsaných v kapitole 4.3.2.2 bylo využito dat získaných v rámci šetření popsaného v kapitole 4.3.1. Celkem byly k dispozici hodnoty šířky koruny a výšky stromu 39 jedinců. Pro posouzení vlivu počtu kalibračních měření byl proveden odhad náhodných parametrů obou modelů (model f1, model f2) pro 3, 5, 10 a 39 kalibračních měření. Spolu s marginálním modelem využívajícím pouze pevné parametry tak vzniklo celkem 10 rovnic pro odvození šířky koruny z výšky stromu Tabulka 12.

Tabulka 12 Označení rovnic pro odvození šířky koruny z výšky stromu

Model	Počet kalibračních vzorků				
	0	3	5	10	39
Model f1	f1_mar	f1_cal3	f1_cal5	f1_cal10	f1_cal39
Model f2	f2_mar	f2_cal3	f2_cal5	f2_cal10	f2_cal39

#### 4.3.3 Ověření využití modelu pro identifikaci jednotlivých stromů v ULS bodovém mračnu

Pro ověření možnosti využití navrhovaných rovnic, odhadujících šířku koruny z výšky stromu, pro stanovení šířky plovoucího okna v rámci LMF procedury při

identifikaci jednotlivých stromů bylo ULS bodové mračno zpracováno v prostředí R(R Core Team 2020) s balíčky LidR (Roussel a Auty 2021) a ForestTools (Plowright a Roussel 2021) následujícím způsobem:

1. Načtení ULS bodového mračna s klasifikací pozemních bodů provedenou pomocí Cloth Simulation Filter (CSF) viz 4.2.5.
2. Normalizace načteného mračna.

Následně pro každou z deseti rovnic:

3. Spuštění LMF procedury pro identifikaci lokálního maxima v rámci plovoucího okna s šířkou definovanou výsledkem rovnice na základě  $Z$  souřadnice bodu normalizovaného mračna.
4. Průnik identifikovaných bodů v místě lokálních maxim s hranicemi zkusných ploch
5. Porovnání počtu identifikovaných bodů/odhadovaných pozic vrcholků stromů s počtem stromů zjištěných v rámci pozemního šetření (viz 4.3.1). Porovnání je realizováno pomocí relativní chyby Percentage Error (PE) Eq 8 na úrovni jednotlivých zkusných ploch. Dále pomocí průměrné relativní chyby - Mean Percentage Error (MPE) Eq 9 a normalizované odmocniny střední kvadratické chyby nRMSE Eq 7 na úrovni skupin zkusných ploch podle výšky  $i$  pro celý soubor zkusných ploch.
6. Porovnání průměrné a maximální výšky identifikovaných bodů/odhadovaných pozic vrcholků stromů s údaji zjištěnými v rámci pozemního šetření obdobným způsobem jako v bodu 5.

$$PE = \frac{\hat{y}_i - y_i}{y_i} \quad \text{Eq 8}$$

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{\hat{y}_i - y_i}{y_i} \quad \text{Eq 9}$$

Kde  $n$  je počet měření (zkusných ploch),  $y$  je pozorovaná hodnota (počtu stromů na ploše  $i$ ) a  $\hat{y}$  je (LMF procedurou) odhadnutá hodnota (počtu stromů na zkusné ploše  $i$ )

### 4.3.4 Identifikace jednotlivých stromů v rámci fotogrammetrických (DAP) mračen

Obdobným způsobem jako v kapitole 4.3.3 byla provedena identifikace jednotlivých stromů v rámci každého ze 42 DAP mračen lokality Skorkov (připravených podle postupu v 4.2.4) Normalizace DAP mračen byla i zde prováděna s využitím DTM odvozeným z pozemních bodů ULS bodového mračna.

Pro odvození šířky plovoucího okna procedury LMF byla použita funkce, která se v části 4.3.3 osvědčila jako optimální, tedy funkce, u níž přidání dalších kalibračních vzorků již nepřineslo statisticky významné zlepšení.

Kromě počtu stromů byla také vyhodnocena průměrná a maximální výška identifikovaných stromů v rámci zkusné plochy.

Všechny tyto tři zjištěné parametry byly následně posouzeny také v závislosti na vybraných vlastnostech DAP mračen. Konkrétně byla posuzována závislost na výšce letu UAV, rychlosti letu dronu během mise, světelných podmínkách během UAV mise charakterizovaných průměrným expozičním časem snímků a také na software použitým pro rekonstrukci bodového mračna.

## 5 Výsledky

Jak bylo uvedeno na začátku kapitoly 4, práce je rozdělena do tří částí. Tyto části byly také předmětem samostatných publikací (viz přílohy 1 až 3) a v následující kapitole jsou předkládány v obdobném členění.

### 5.1 Prostorové rozlišení snímků v závislosti na různých vstupních podmínkách

**Kubišta J.; Surový P. Spatial resolution of unmanned aerial vehicles acquired imagery as a result of different processing conditions. 2021.**

Článek popisuje výsledky získané v rámci vyhodnocení prostorového rozlišení pomocí GRD ve snímcích kalibračního cíle Siemens star.




Poměr změřeného GRD k vypočtenému GSD se pohyboval v rozmezí od 1,4 do 3,09  
 Tabulka 13.

**Tabulka 13 Zjištěné hodnoty GSD a GRD**


	<b>GSD</b> (cm/px)	<b>GRD</b> (cm)	<b>GRD/GSD</b> ( )
Min	0,221	0,340	1,389
Median	2,250	4,864	2,220
Mean	2,335	5,205	2,189
Max	4,734	12,113	3,087

Vliv letové výšky na oba parametry je patrný z následujícího grafu. Zároveň je zřejmé, že na hodnotu GRD působí i další vlivy Obrázek 19.




**Obrázek 19 Graf závislosti GRD a GSD na letové výšce**

Vliv expozičního času a rychlosti letu UAV na GRD je zachycen v následujících grafech Obrázek 20 resp. Obrázek 21.



Obrázek 20 Graf vztahu mezi GRD a expozičním časem



Obrázek 21 Graf vztahu mezi GRD a rychlostí letu UAV

Pro lepší pochopení závislosti GRD na letové výšce, expozičním časem a rychlosti letu UAV byl odvozen lineární model. Postupnými úpravami byl zvolen jako nejlepší model ve formě podle Eq 10 s těmito výsledky:  $F(3,180) = 855.306$ ,  $p < 0.001$ ,  $R^2 =$

0.934, Adjusted R<sup>2</sup> = 0.933. Všechny nezávislé proměnné jsou standardizovány pomocí průměru a jednonásobku směrodatné odchylky viz Tabulka 14.

$$\sqrt{GRD} = a + b * Al + c * Sp + d * Ex + e \quad \text{Eq 10}$$

Kde *Al* je výška letu, *Sp* rychlost letu, *Ex* expoziční čas, *a*, *b* a *c* jsou odhadované příslušné parametry modelu a *e* je reziduální chyba.

**Tabulka 14 Model závislosti GRD na výšce letu, rychlosti letu a expozičním čase (Všechny nezávislé proměnné jsou standardizovány pomocí průměru a jednonásobku směrodatné odchylky).**

Proměnná	Odhad	Std. Error	t-hodnota	p-hodnota
(Intercept)	2,167	0,014	159,527	< 0,001
Výška letu	0,614	0,015	41,054	< 0,001
Rychlost letu	0,115	0,015	7,474	< 0,001
Expoziční čas	0,066	0,014	4,561	< 0,001

Z modelu je zjevný výrazný vliv výšky letu a omezený, byť stále statisticky významný vliv rychlosti letu a expozičního času.

Z provedené studie lze odvodit, že v praxi často používaná charakteristika prostorového rozlišení GSD může vést k příliš optimistickému očekávání v oblasti detailu pořizovaného snímku. Poměr prostorového rozlišení popisovaného hodnotou GRD k GSD se ve studii pro daný typ UAV pohyboval v průměru ve výši 2,2. Podobné výsledky publikovali i další autoři, s poměrem GRD/GSD v rozmezí nejčastěji od 1,2 (Lee a Sung 2016) po 2,6 (Dabrowski et al. 2015).

Obdobně jako v provedené studii byl i jinými autory (Lim et al. 2018a) (Lim et al. 2018b) potvrzen také vyšší poměr GRD/GSD při horších světelných podmínkách.

Významně větších poměrů GRD/GSD ve výši 10 až 15ti násobku bylo dosahováno s využitím snímače S.O.D.A neseného SenseFly eBee Plus UAV s pevným křídlem (Stöcker et al. 2018). Vzhledem k použitému UAV lze předpokládat významně vyšší horizontální rychlosti než v případě jiných studií využívajících UAV multirotorového typu.

## 5.2 Kvalita fotogrammetrických (DAP) bodových mračen odvozených ze snímků pořízených v různých vstupních podmínkách

Kubišta J.; Surový P. Forest structure from UAV: software type has more influence on Structure from Motion point cloud than flight conditions. 2022.

Bylo provedeno porovnání DAP bodových mračen rekonstruovaných pomocí software Agisoft Metashape a WebODM (ve dvou nastaveních) v celkovém počtu 78 s referenčním ULS bodovým mračnem Tabulka 15.


Tabulka 15 Vlastnosti DAP bodových mračen

Proměnná	Metashape <sup>1</sup>	WebODMeh <sup>1</sup>	WebODMstd <sup>1</sup>
Pokrytí (%)	93.94 (31.00 to 99.80)	81.58 (25.30 to 96.70)	81.67 (24.50 to 96.70)
Hustota bodů (bodů/m <sup>2</sup> )	79.61 (30.43 to 181.23)	52.20 (9.90 to 103.04)	51.45 (9.52 to 101.92)
Polohová přesnost (m)	0.40 (0.26 to 0.60)	0.25 (0.13 to 0.65)	0.31 (0.18 to 0.62)

<sup>1</sup>n (%); Průměr (rozsah)


### 5.2.1 Pokrytí výzkumné lokality

Pokrytí výzkumné lokality DAP mračnem se výrazně lišilo jak podle letové výšky Obrázek 22(a) tak podle výzkumné lokality Obrázek 22(b) **Chyba! Nenalezen zdroj odkazů..**



Obrázek 22 Pokrytí výzkumné lokality bodovým mračnem v členění podle použitého software (a) a výzkumné lokality (b). Zahrnuje všech 78 bodových mračen.

Tento jev lze vysvětlit hypotézou horších výsledků rekonstrukce bodového mračna ze snímků s příliš krátkou vzdáleností od snímaného povrchu (terén, ale zejména koruny stromů), díky níž nedokáže algoritmus SfM spolehlivě detekovat dostatek uzlových bodů v jednotlivých snímcích. Tuto hypotézu potvrzují výsledky mračen rekonstruovaných z letové hladiny 75m v případě lokality Skalice. Vzhledem k tomu, že letová výška byla udržována jako konstantní nad místem startu, je na této lokalitě s vyšším sklonem skutečná vzdálenost UAV a snímaných vrcholů stromů značně proměnlivá, v některých případech zřejmě příliš malá (při výšce letu 75 m byla vzdálenost UAV od vrcholů stromů v nejnvýše položené části lokality pouhých cca 35m). Jak ukazuje Obrázek 23 nízká letová hladina 75 m vedla pouze k částečné úspěšnosti rekonstrukce bodového mračna (a), na rozdíl od letové hladiny 100m (b).



Obrázek 23 Boční pohled na rekonstruované bodové mračno (zeleně) s terénem (šedě) lokality Skorkov při letové hladině 75m(modře) (a) a 100m(červeně)(b)

Pro lepší porovnatelnost výsledků byla v dalším zpracování použita pouze DAP bodová mračna s pokrytím vyšším než 80%. Tuto podmínku splnilo celkem 63 mračen viz Tabulka 16.

Tabulka 16 Vlastnosti vybraných 63 DAP bodových mračen s pokrytím >80%

Proměnná	Metashape <sup>1</sup>	WebODMenh <sup>1</sup>	WebODMstd <sup>1</sup>
Pokrytí (%)	97.24 (81.10 to 99.80)	91.89 (80.80 to 96.70)	92.34 (83.20 to 96.70)
Hustota bodů (bodů/m <sup>2</sup> )	81.35 (35.02 to 181.23)	57.74 (32.15 to 103.04)	57.10 (31.42 to 101.92)
Polohová přesnost (m)	0.41 (0.26 to 0.60)	0.22 (0.14 to 0.30)	0.30 (0.19 to 0.62)

<sup>1</sup>n (%); Průměr (rozsah)

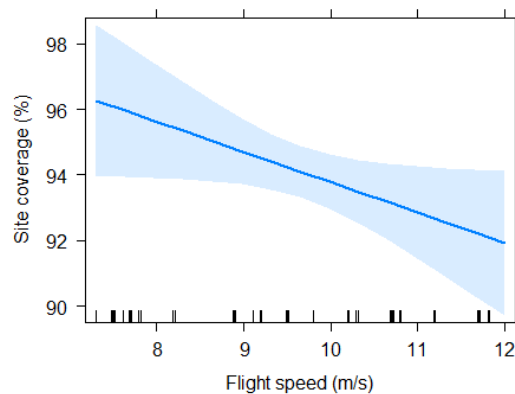
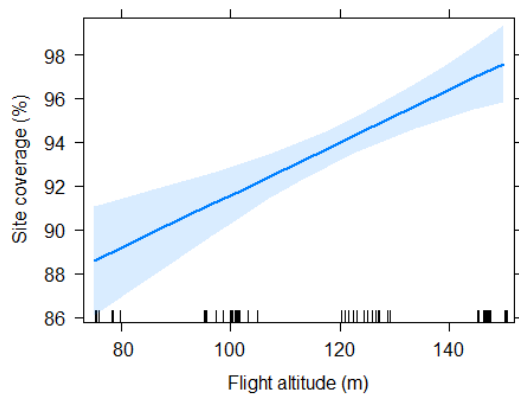
S využitím generalizovaného lineárního modelu (GLM) byl potvrzen významný vliv výšky letu, rychlosti letu, využitého software a výzkumné lokality na pokrytí

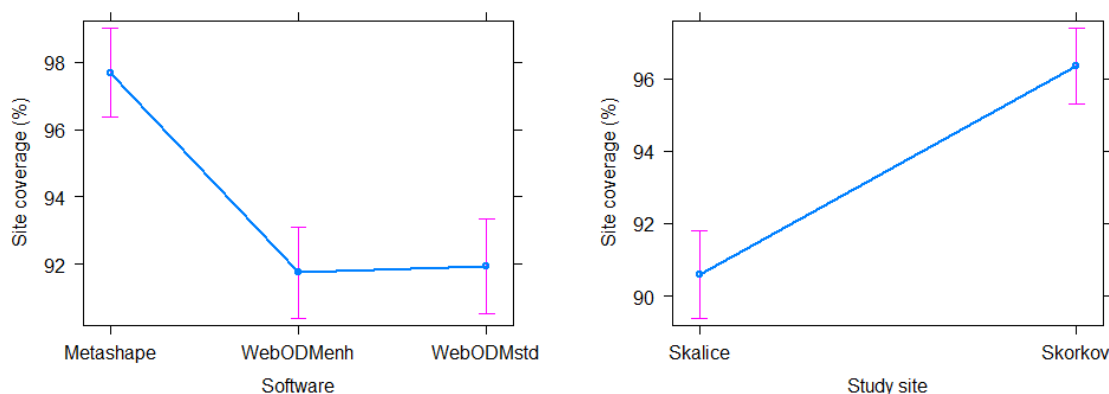
DAP bodového mračna Tabulka 17 a Obrázek 24. Světelné podmínky, popsané pomocí expozičního času snímků, nebyly tímto modelem potvrzeny jako statisticky významné.

**Tabulka 17 GLM závislosti pokrytí výzkumné lokality na výšce letu, software, lokalitě a rychlosti letu**

Proměnná	Odhad	95% CI <sup>1</sup>	p-value
(Intercept)	88,68	83,41, 93,98	<0,001
Výška letu	0,120	0,069, 0,172	<0,001
Software			
Metashape	—	—	
WebODMenh	-5,937	-7,785, -4,087	<0,001
WebODMstd	-5,750	-7,634, -3,863	<0,001
Výzkumná lokalita			
Skalice	—	—	
Skorkov	5,739	4,148, 7,325	<0,001
Rychlost letu	-0,924	-1,804, -0,049	0,043

<sup>1</sup>CI = Interval spolehlivosti



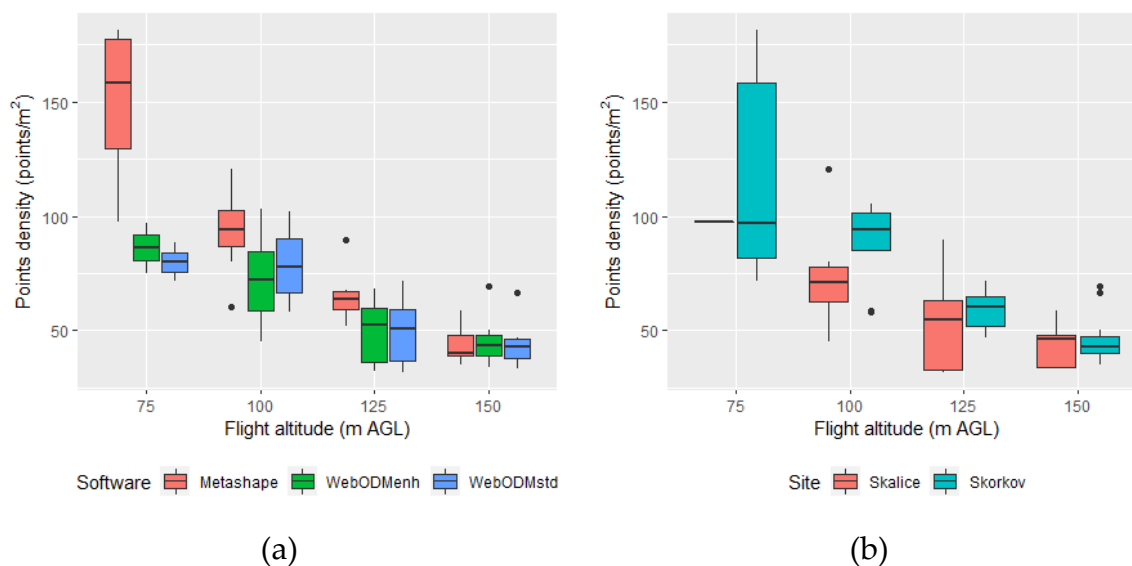


**Obrázek 24** Efekty vybraných proměnných výška letu, rychlost letu, software a výzkumná lokalita na GLM predikované pokrytí výzkumné lokality DAP bodovým mračnem.

## 5.2.2 Hustota bodů

Hustota bodů DAP bodových mračen klesá s rostoucí letovou výškou. Rovněž se lišila mezi mračny rekonstruovanými v rámci Metashape a WebODM (v obou verzích nastavení) s vyššími hodnotami u Metashape Obrázek 25(a). Také se hustota bodů lišila mezi oběma výzkumnými lokalitami, s nižšími hodnotami v případě lokality Skalice viz Obrázek 25(b), což patrně souvisí s jevem vyššího výskytu částí lokality, kde se nepodařilo rekonstruovat bodové mračno, jak je vysvětleno v předchozí části.

Obdobně jako u pokrytí lokality byl i u hustoty bodového mračna potvrzen pomocí GLM vliv výšky letu, rychlosti letu, využitého software a výzkumné lokality na hustotu DAP bodového mračna Tabulka 18, Obrázek 26. Stejně jako v předchozím případě se nepotvrdil vliv světelných podmínek.



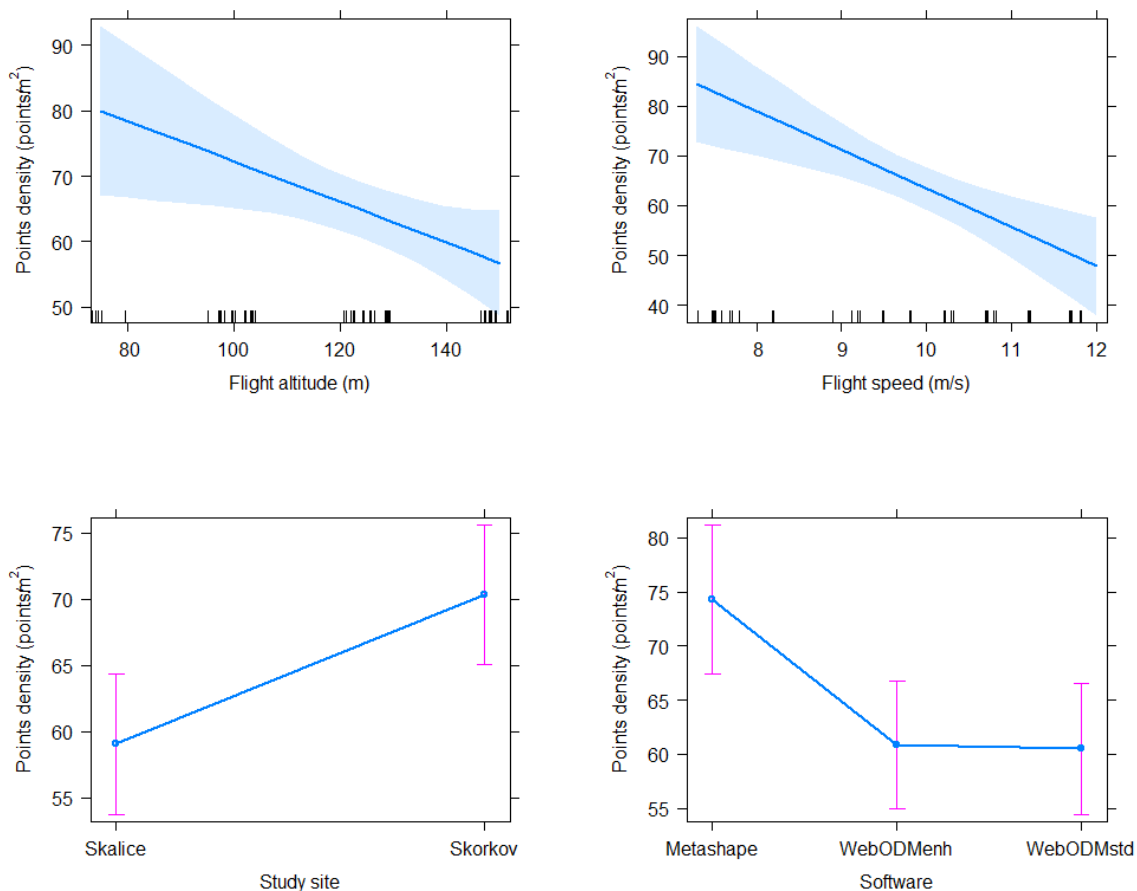
**Obrázek 25** Hustota bodů DAP mračen v členění podle použitého software (a) a výzkumné lokality (b). Zahrnuje pouze vybraných 63 bodových mračen s pokrytím nad 80%.

**Tabulka 18** GLM závislosti hustoty DAP bodového mračna na výšce letu, software, lokalitě a rychlosti letu

Proměnná	Odhad	95% CI <sup>1</sup>	p-value
(Intercept)	180.3	153.7, 208.2	<0.001
Výška letu	-0.311	-0.567, -0.049	0.017
Software			
Metashape	—	—	
WebODMenh	-13.43	-22.55, -4.690	0.003
WebODMstd	-13.79	-22.97, -5.001	0.002
Výzkumná lokalita			
Skalice	—	—	
Skorkov	11.29	4.499, 18.15	0.001
Rychlost letu	-7.782	-12.01, -3.767	<0.001

<sup>1</sup>CI = Interval spolehlivosti



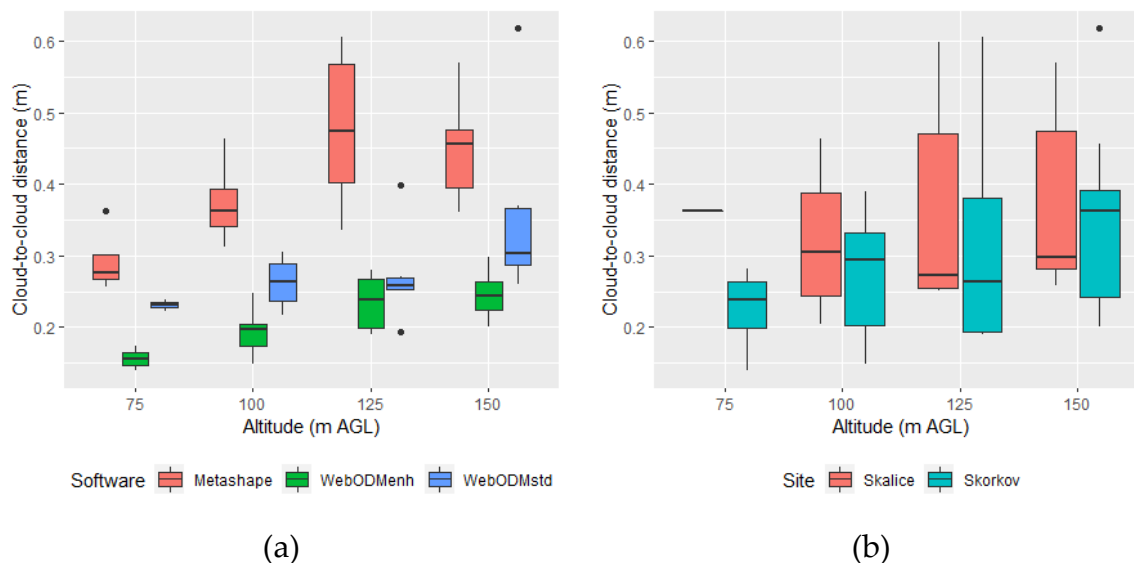


**Obrázek 26** Efekty vybraných proměnných výška letu, rychlost letu, software a výzkumná lokalita na GLM predikovanou hustotu DAP bodového mračna.

### 5.2.3 Polohová přesnost

Polohová přesnost byla hodnocena pomocí průměrné vzdálenosti jednotlivých bodů DAP mračna od referenčního ULS mračna. Tato vzdálenost se u vybraných DAP mračen pohybovala v rozmezí 0,14 až 0,62m viz Tabulka 16.

Nejlepších výsledků dosahovala mračna rekonstruovaná programem WebODM s optimalizovaným nastavením (WebODMenh) v nízkých letových výškách Obrázek 27(a). Vliv výzkumné lokality na polohovou přesnost dokumentuje Obrázek 27(b).



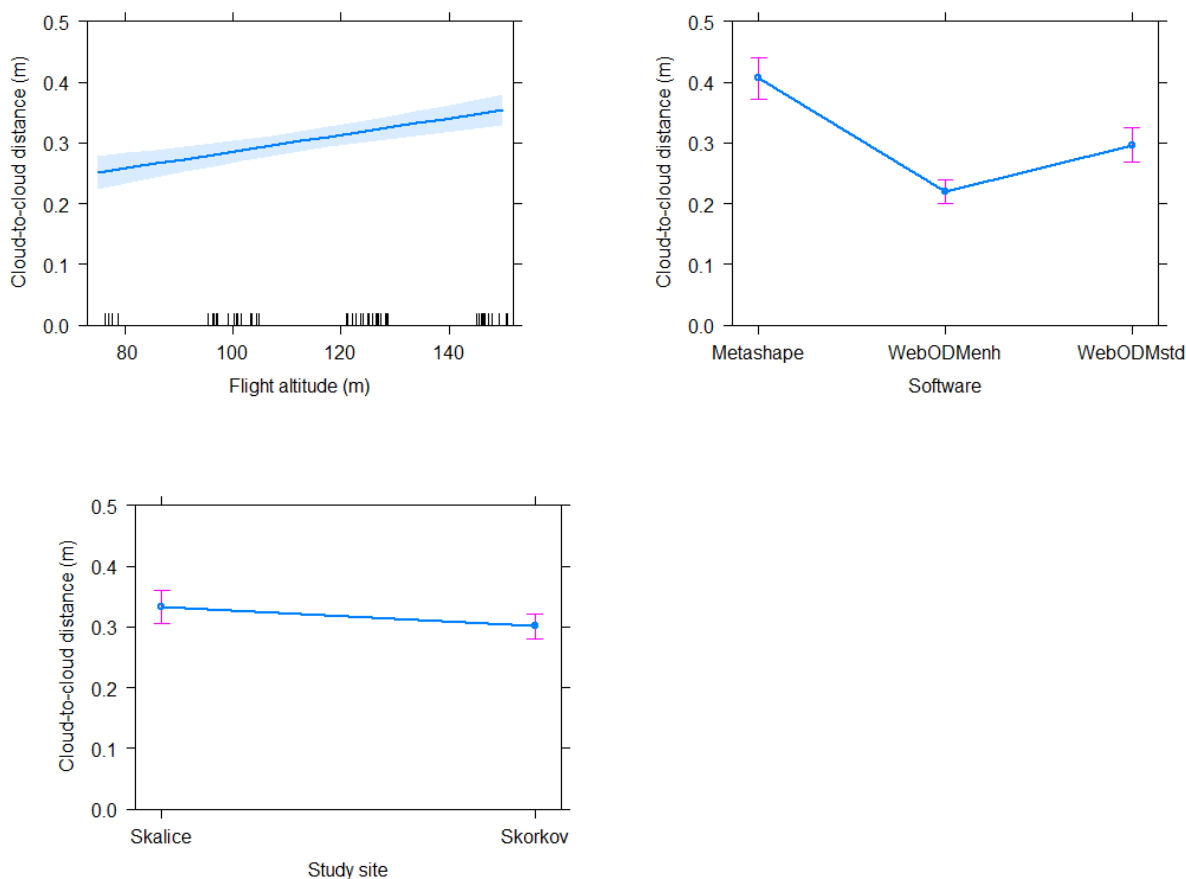
**Obrázek 27** Průměrná vzdálenost bodů DAP mračen od referenčního ULS mračna v členění podle použitého software (a) a výzkumné lokality (b). Zahrnuje DAP mračna s pokrytím lokality nad 80% (63 bodových mračen).

GLM potvrdil významný vliv výšky letu, software a výzkumné lokality na polohovou přesnost DAP bodového mračna Tabulka 19, Obrázek 28. Vliv dalších proměnných (rychlost letu a světelné podmínky) nebyl potvrzen.

**Tabulka 19** GLM závislosti polohové přesnosti DAP bodového mračna na výšce letu, software a lokalitě.

Proměnná	Odhad	95% CI <sup>1</sup>	p-value
(Intercept)	0.260	0.185, 0.337	<0.001
Výška letu	0.001	0.001, 0.002	<0.001
Software			
Metashape	—	—	
WebODMenh	-0.186	-0.225, -0.149	<0.001
WebODMstd	-0.109	-0.153, -0.067	<0.001
Výzkumná lokalita			
Skalice	—	—	
Skorkov	-0.032	-0.065, -0.001	0.050

<sup>1</sup>CI = Interval spolehlivosti



**Obrázek 28** Efekty vybraných proměnných výška letu, software a výzkumná lokalita na GLM predikovanou polohovou přesnost DAP bodového mračna.

Široce využívaný komerční software Agisoft Metashape v defaultním nastavení rekonstruoval bodová mračna s významně vyšší bodovou hustotou v porovnání s open-source alternativou WebODM. Tento jev nelze nijak generalizovat, jedná se patrně pouze o důsledek odlišného výchozího nastavení. Naopak z hlediska polohové přesnosti vykazovala mračna vytvořená v rámci WebODM lepší výsledky než mračna z Metashape. Zároveň byl potvrzen pozitivní vliv optimalizované kalibrace (WebODMenh) na polohovou přesnost výstupů WebODM.

Očekávaný vliv světelných podmínek v průběhu pořizování snímků UAV se nepotvrdil jako statisticky významný pro žádnou z posuzovaných vlastností (hustota bodů, relativní pokrytí, polohová přesnost) výsledného DAP bodového mračna.

Let UAV v příliš nízké letové výšce nad povrchem může přinášet problémy při rekonstrukci bodového mračna. Obzvláště důležité je pamatovat na tento fakt při

snímkování lokality s velmi variabilním terénem, kdy může dojít k velkým rozdílům výšky UAV nad snímaným povrchem. Z tohoto pohledu lze, mimo jiné i na základě zkušeností ze snímání lokality Skalice, jednoznačně doporučit pro plánování letové mise software umožňující udržovat konstantní výšku nad terénem (na základě digitálního modelu terénu). Let v konstantní výšce nad místem startu může ve výškově proměnlivém terénu zřejmě vést k nižší úspěšnosti rekonstrukce bodového mračka díky příliš nízké vzdálenosti UAV od snímaného povrchu ve vyšších částech snímané lokality.

### 5.3 Vliv vstupních podmínek a kvality bodového mračka na přesnost odvozování vybraných výstupů

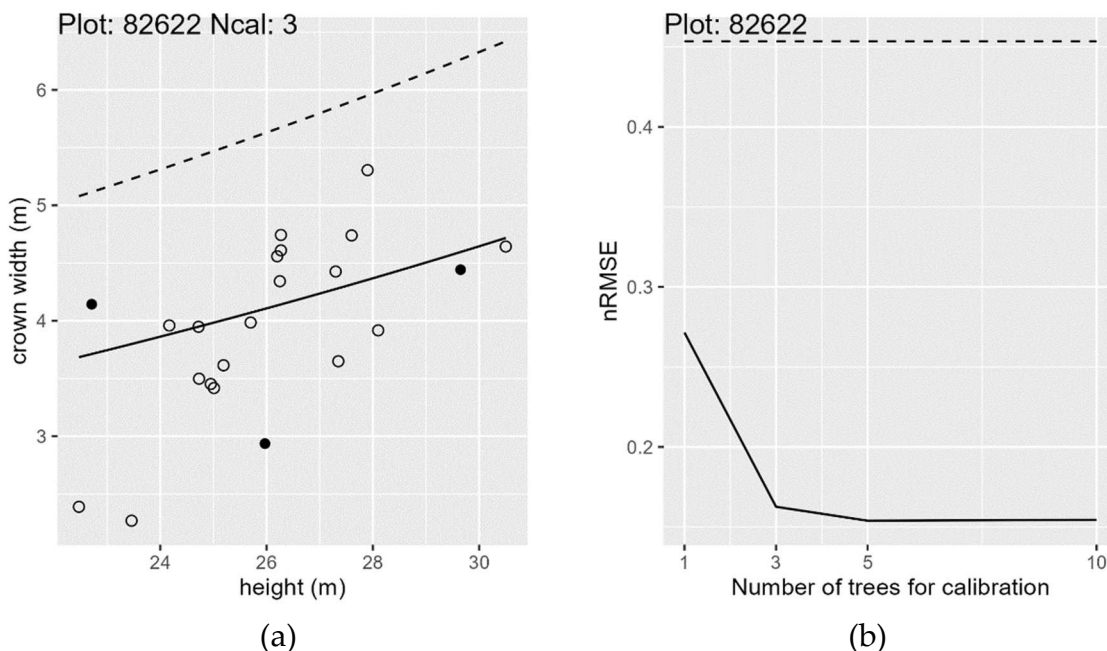
První část tohoto bloku, zahrnující přípravu lineárního modelu se smíšenými efekty pro odvození šířky koruny z výšky stromu, ověření kalibrace tohoto modelu pro konkrétní lokalitu a využití modelu kalibrovaného různým počtem kalibračních vzorků pro identifikaci jednotlivých stromů v ULS bodovém mračku byly zpracovány v rámci článku.

**Kubišta J.; Surový P. Individual tree identification in ULS point cloud using a crown width mixed-effects model based on NFI data. 2022.**


Další část zahrnující využití optimálního kalibrovaného modelu pro identifikaci jednotlivých stromů v rámci DAP mračen připravených v rámci bloku 2 publikována zatím nebyla a její výsledky jsou předkládány v této práci v části 0.

#### 5.3.1 Ověření kalibrace modelu

Kalibrace modelu (odhad náhodných parametrů) pro konkrétní lokalitu, která byla pro ověření provedena opakovaně pro sto postupně náhodně vybíraných inventarizačních ploch Obrázek 29, potvrdila přínos kalibrace ke zpřesnění odhadu šířky koruny Obrázek 30.



Obrázek 29 Příklad kalibrace modelu pro jednu náhodně vybranou inventarizační plochu. (a) náhled kalibrace se třemi kalibračními vzorky, plné body kalibrační vzorky, přerušovaná čára nekalibrovaný model, plná čára kalibrovaný model; (b) porovnání kalibrace, plná čára model s různým počtem kalibračních vzorků a přerušovaná čára nekalibrovaný model.



Obrázek 30 Vliv počtu kalibračních vzorků, 0 znamená nekalibrovaný model pouze s pevnými efekty

Závislost normalizované střední kvadratické chyby (nRMSE) na počtu použitých vzorků byla testována Kruskal-Wallisovým testem jako statisticky významná pro  $\alpha=0,05$  (p-hodnota = 1.219e-13).

Následný Dunnův test potvrdil, že zvýšení počtu kalibračních vzorků nad hodnotu 3 již nepřineslo statisticky významné zlepšení nRMSE odhadu Tabulka 20.

**Tabulka 20 p-hodnoty Dunnova testu pro nRMSE odhadu podle počtu kalibračních vzorků (tučně p-hodnota<0.05)**

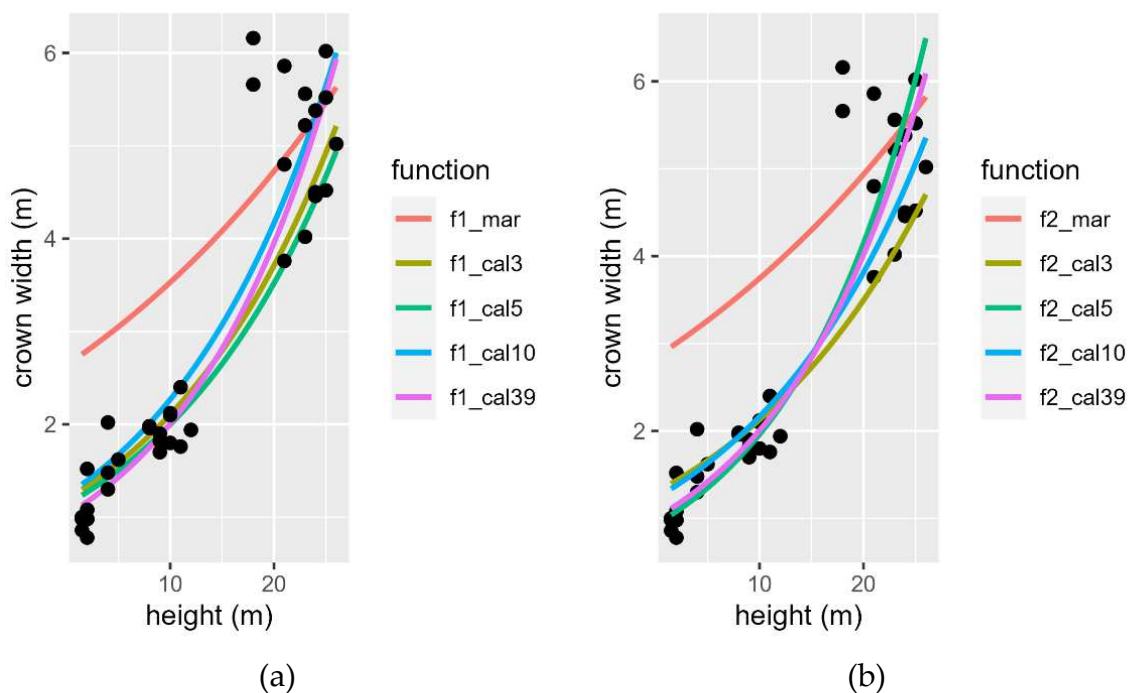
Počet kal.vzorků	0	1	3	5
1	<b>0,001</b>			
3	<b>0,000</b>	<b>0,033</b>		
5	<b>0,000</b>	<b>0,003</b>	0,443	
10	<b>0,000</b>	<b>0,001</b>	0,219	0,608

### 5.3.2 Kalibrace modelu pro výzkumnou lokalitu Skorkov

Na základě dat o šířkách koruny a výškách stromů získaných v rámci terénního šetření na zkusných plochách byla provedena kalibrace obou modelů (model f1 bez rozlišení dřeviny a model f2 odvozený pouze pro NIL skupiny dřevin Borovice lesní a Duby) pro výzkumnou lokalitu Skorkov. Obdobně jako u předchozího bodu byla kalibrace provedena pro různý počet kalibračních vzorků, v tomto případě 3,5,10 a 39 viz Tabulka 21 a Obrázek 31.

**Tabulka 21 Výsledky kalibrace**

Model	# kal. vzorků	Označení	Funkce
Model	-	f1_mar	$CW = \exp((0,969)+(2,919)*x/100)$
f1	3	f1_cal3	$CW = \exp((0,969 - 0,792) + (2,919 + 2,751) * H/100)$
	5	f1_cal5	$CW = \exp((0,969 - 0,843) + (2,919 + 2,742) * H/100)$
	10	f1_cal10	$CW = \exp((0,969 - 0,759) + (2,919 + 3,165) * H/100)$
	39	f1_cal39	$CW = \exp((0,969 - 0,951) + (2,919 + 3,864) * H/100)$
Model	-	f2_mar	$CW = \exp((1,045) + (2,758) * H/100)$
f2	3	f2_cal3	$CW = \exp((1,045 - 0,785) + (2,758 + 2,200) * H/100)$
	5	f2_cal5	$CW = \exp((1,045 - 1,119) + (2,758 + 4,724) * H/100)$
	10	f2_cal10	$CW = \exp((1,045 - 0,838) + (2,758 + 2,902) * H/100)$
	39	f2_cal39	$CW = \exp((1,045 - 1,042) + (2,758 + 4,180) * H/100)$

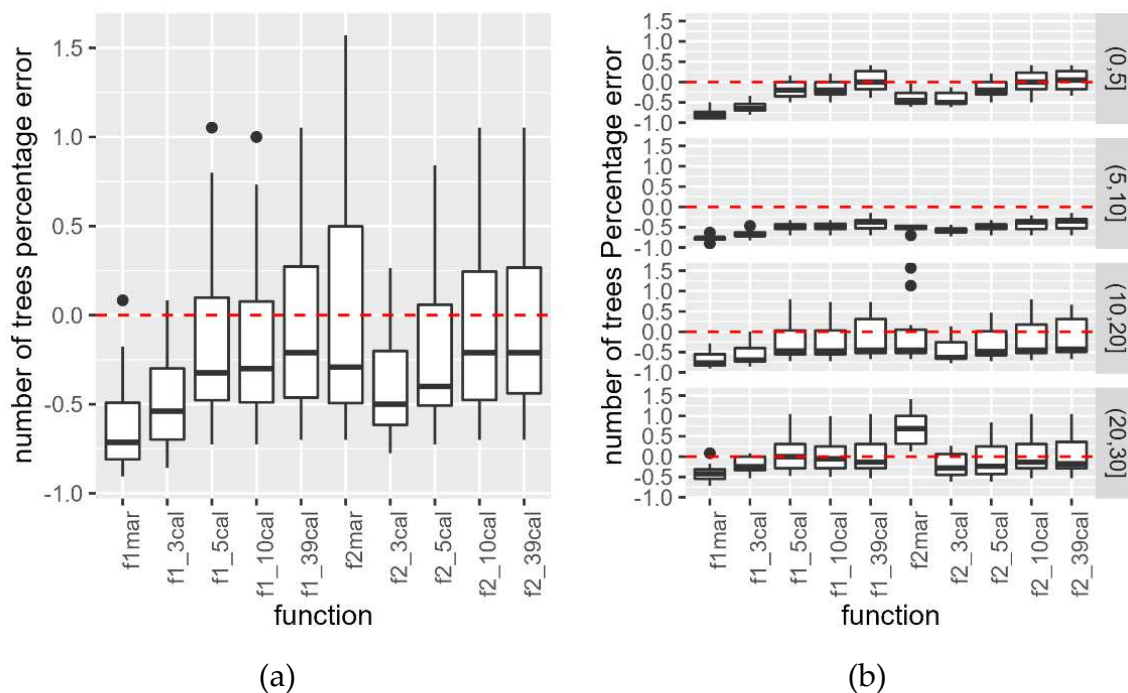


Obrázek 31 Kalibrace modelů pro výzkumnou lokalitu Skorkov (a) model f1 pro všechny skupiny dřevin; (b) model f2 pro skupiny dřevin Borovice lesní a Duby.

### 5.3.3 Identifikace jednotlivých stromů v rámci ULS mračna

Průměrná relativní chyba MPE mezi počtem stromů zjištěným LMF procedurou z ULS bodového mračna a v rámci pozemního šetření na zkusných plochách dosahovala hodnoty -0,23 se směrodatnou odchylkou 0,21.

Obrázek 32 znázorňuje rozdělení této chyby podle funkce využití v rámci LMF a výškové kategorie zkusných ploch. Největší odchylky vznikaly na zkusných plochách výškové kategorie mezi 5 a 10 metry, což lze vysvětlit značnou hustotou porostů ve věkovém stádiu odpovídajícím těmto výškám na výzkumné lokalitě. Naopak nejlepších výsledků bylo dosahováno u nejvyšší kategorie 20 až 30 metrů, odpovídající stadiu dospělé kmenoviny.



**Obrázek 32** relativní chyba mezi počtem stromů určených z ULS mračna a pozemním šetřením v členění podle použité funkce pro LMF(a) a dále podle výškové kategorie zkusných ploch (b)

Kruskal-Wallisův test potvrdil statistickou významnost vlivu vyuzité funkce pro LMF na chybu v určení počtu stromů ( $\alpha=0,05$  p-hodnota =  $9.302e-06$ ). Následný Dunnův test pak určil jako optimální funkci f1\_5cal modelu využívajícího všechny druhy dřevin a 5 vzorků pro kalibraci ( $\alpha=0,05$ ) viz Tabulka 22.

**Tabulka 22** P-hodnoty Dunnova testu vlivu funkce použité pro LMF na chybu určení počtu stromů z ULS oproti pozemnímu šetření (tučně p-hodnota<0,05)

	f1mar	f1_3cal	f1_5cal	f1_10cal	f1_39cal	f2mar	f2_3cal	f2_5cal	f2_10cal
f1_3cal	0.439								
f1_5cal	<b>0.006</b>	0.071							
f1_10cal	<b>0.005</b>	0.067	0.998						
f1_39cal	<b>0.001</b>	<b>0.014</b>	0.665	0.683					
f2mar	<b>0.001</b>	<b>0.009</b>	0.537	0.554	0.905				
f2_3cal	0.175	0.706	0.228	0.218	0.063	<b>0.037</b>			
f2_5cal	<b>0.013</b>	0.167	0.810	0.791	0.451	0.347	0.445		
f2_10cal	<b>0.001</b>	<b>0.018</b>	0.692	0.710	0.961	0.837	0.068	0.511	
f2_39cal	<b>0.001</b>	<b>0.014</b>	0.646	0.665	0.966	0.942	0.056	0.435	0.925

Využití této funkce (f1\_5cal) v LMF vedlo k průměrné relativní chybě počtu stromů oproti pozemnímu šetření ve výši -0,17. Obdobně jako u výsledků použití většiny ostatních funkcí byla průměrná relativní chyba nejnižší (+0,05) v nejvyšší výškové



kategorii (20-30m). Naopak nejvyšší průměrná relativní chyba (-0,49) vznikla ve výškové kategorii 5 až 10 m.

Předběžně očekávané lepší výsledky na základě použití modelu odvozeného pouze pro vybrané druhy dřevin vyskytující se na výzkumné lokalitě (model f2) se nepotvrdily.

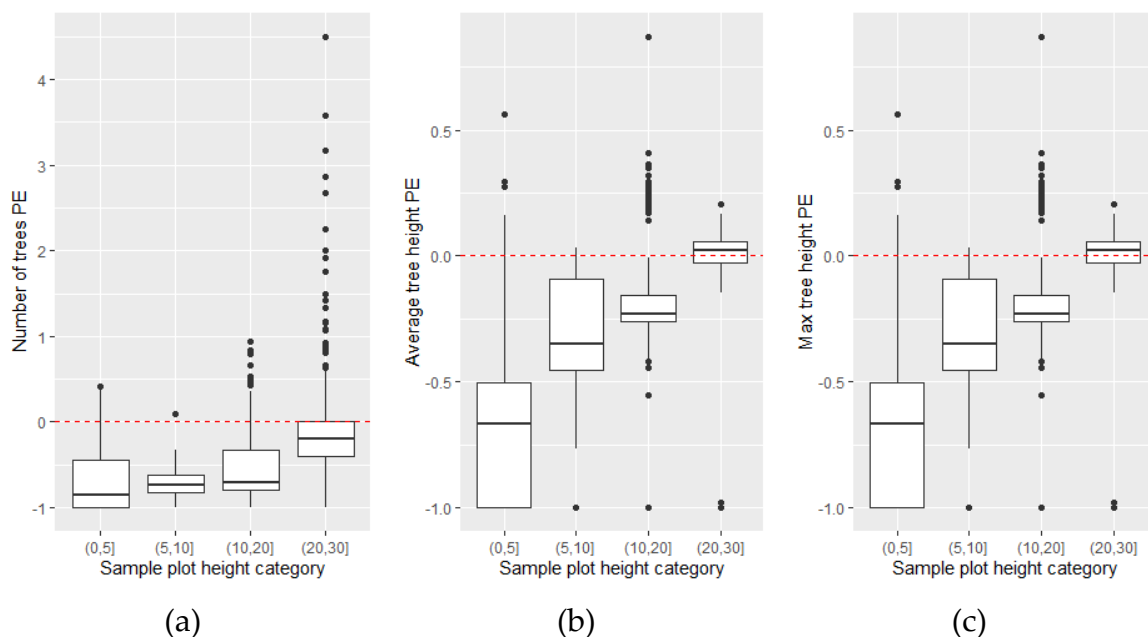
### 5.3.4 Identifikace jednotlivých stromů v rámci fotogrammetrických (DAP) mračen

Identifikace jednotlivých stromů v rámci DAP mračen procedurou LMF s využitím funkce f1\_5cal, která byla v předchozí kapitole ověřena jako optimální pro odvození šířky plovoucího okna, vedlo v porovnání s pozemním měřením k průměrné relativní chybě počtu stromů -0,46. Tato relativní chyba se výrazně lišila v závislosti na výškové kategorii zkusných ploch. Nejlepších výsledků bylo dosaženo u kategorie mezi 20 a 30m výšky, kde relativní chyba počtu stromů byla v průměru -0,10. U nižších kategorií pak byla průměrná relativní chyba vyšší (0,69 a 0,72 u kategorií 0 až 5 metrů respektive 5 až 10 metrů). Obdobných výsledků dosahovala také relativní chyba průměrné a maximální výšky identifikovaných stromů v rámci zkusných ploch Tabulka 23 a Obrázek 33.

**Tabulka 23 Relativní chyba mezi LMF identifikací a pozemním šetřením v rámci zkusných ploch**

Relativní chyba	Výšková kategorie zkusných ploch (od,do] (m)				
	Celkem n = 1 638 <sup>1</sup>	(0,5] n = 378 <sup>1</sup>	(5,10] n = 294 <sup>1</sup>	(10,20] n = 420 <sup>1</sup>	(20,30] n = 546 <sup>1</sup>
Počet stromů	-0,46 (0,50)	-0,69 (0,35)	-0,72 (0,15)	-0,52 (0,40)	-0,10 (0,56)
Průměrná výška	-0,32 (0,32)	-0,69 (0,27)	-0,29 (0,31)	-0,23 (0,12)	-0,15 (0,24)
Maximální výška	-0,25 (0,34)	-0,67 (0,30)	-0,31 (0,25)	-0,15 (0,21)	-0,01 (0,17)


<sup>1</sup>Průměr (Směrodatná odchylka)



**Obrázek 33 Relativní chyba (a) počtu stromů; (b) průměrné výšky; (c) maximální výšky mezi LMF identifikací a pozemním šetřením v rámci zkusných ploch**

Obrázek 33 ukazuje značně odlehlé hodnoty v grafech, zejména u výškové kategorie zkusných ploch 20 až 30 m. Tento jev je patrně výsledkem toho, že byly na těchto plochách v mezerách korun stromů hlavní vrstvy identifikovány rovněž stromky v přízemní vrstvě, které ale vzhledem ke své výšce nepřekročily na těchto plochách minimální registrační hranici a nebyly tak zachyceny v rámci pozemního šetření. Z tohoto důvodu bylo na těchto plochách v rámci LMF identifikováno více stromů, než při pozemním šetření.

Tento jev je dobře patrný například na zkusné ploše 32, ležící v rámci porostní skupiny ve stadiu kmenoviny, která na své severovýchodní straně sousedí s obnovenou plochou. Vlivem bočního svitu zde dochází k přirozenému zmlazení právě ze strany mladší porostní skupiny Obrázek 34.




**Obrázek 34** Náhled zkusné plochy 32 (růžový kruh) s menšími stromky v severovýchodní části identifikovanými pod úrovní hlavního porostu (značky označují polohu vrcholu jednotlivých stromů, barva odpovídá jejich výšce na škále od modré u nejnižších po červenou u nejvyšších)

Pro porovnání významnosti vlivu vybraných parametrů bodového mračka (výška letu UAV, software použitý pro rekonstrukci bodového mračka, světelné podmínky vyjádřené jako průměrný čas expozice snímků a průměrná rychlost letu UAV) na relativní chybu určení počtu stromů, průměrné a maximální výšky stromů na zkusné ploše byl použit neparametrický Kruskal-Wallisův test viz Tabulka 24 p-hodnoty Kruskal-Wallisova testu. Statistická významnost vlivu žádného z vybraných parametrů nebyla na hladině spolehlivosti  $\alpha=0,05$  tímto postupem potvrzena.


**Tabulka 24** p-hodnoty Kruskal-Wallisova testu

	Počet stromů	Prům. výška	Max. výška
Výška letu UAV	0,8235	0,4518	0,6415
Rychlost letu UAV	0,1329	0,3411	0,8059
Expoziční čas	0,4226	0,0814	0,3418
Software	0,6870	0,6807	0,9948


Rovněž grafické znázornění neodkrývá žádný jasný trend viz Obrázek 35.




(a)



(b)



(c)



(d)

Obrázek 35 Relativní chyba určení počtu stromů na jednotlivých zkušních plochách v členění podle výškových tříd zkušních ploch a dále podle výšky letu (a), rychlosti letu (b), expozičního času (c) a použitého software (d)

## 6 Diskuze

Předkládaná práce zkoumá dopad proměnlivých vnějších podmínek na vlastní obrazová data pořízená prostřednictvím UAV. Dále se zabývá vlivem těchto a dalších podmínek na kvalitu bodového mračka rekonstruovaného metodou Structure from Motion a v neposlední řadě také tím, jak jsou na konci řetězce zpracování ovlivněny odhady vybraných dendrometrických veličin odvozovaných z těchto mraček. Výsledky těchto tří částí jsou dále diskutovány nejprve samostatně s krátkým shrnutím na závěr.

### **Prostorové rozlišení snímků v závislosti na různých vstupních podmínkách.**

V otázkách prostorového rozlišení snímků pořizovaných prostřednictvím UAV uvádí většina studií pouze teoretickou hodnotu GSD, která nedostatečně popisuje další faktory ovlivňující prostorové rozlišení kromě vlastní geometrie snímače a vzdálenosti snímaného objektu. Prezentovaný postup odvození prostorového rozlišení snímků pomocí údaje GRD ukazuje, že v případě zde užitého snímače DJI FC300x bylo GRD vždy vyšší než GSD, a to v poměru 1,4 až 3,1 s průměrem 2,2. Obdobných hodnot dosahují i jiní autoři zabývající se touto problematikou. Poměr 1,2 až 1,4 byl dosažen v případě užití snímače Canon IXUS 127 HS (Lee a Sung 2016). (Dabrowski et al. 2015) dosáhl poměru 2,6 s využitím Sony (NEX-5). 1,3 a 1,8 byly poměry GRD/GSD dosažené s DJI Phantom 4 respektive DJI Phantom 4 RTK v (Cramer & Zhang 2020).

Závislost poměru GRD/GSD na výšce letu a světelných podmínkách, která se v této práci potvrdila (vyšší hodnoty GRD/GSD s vyšší výškou letu a s horšími světelnými podmínkami) lze srovnat například s výsledky v (Lim et al. 2018), kde byl poměr GRD/GSD dosažený pomocí Sony A5100 mezi 1,1 a 2,3 (v závislosti na výšce letu) při slunečném počasí a 1,6 až 3,7 při větší oblačnosti.

Rovněž pro závislost GRD/GSD na rychlosti letu, která se zde potvrdila, lze najít příklady v literatuře. Například výsledky poměru GRD/GSD ve výši okolo hodnoty 10 byly dosaženy s využitím S.O.D.A. snímače neseného UAV SenseFly eBEE – tedy UAV s pevným křídlem, jehož rychlost letu je významně vyšší než v případě snímků pořízených v klidu.

## **Kvalita fotogrammetrických (DAP) bodových mračen odvozených ze snímků pořízených v různých vstupních podmínkách.**

Fotogrammetrická (DAP) mračna rekonstruovaná pomocí SfM algoritmu ze snímků pořízených UAV vykazovala v průměru 0,3 m odchylku od referenčního ULS bodového mračna. Obdobné hodnoty jsou uváděny i dalšími autory (Dandois a Ellis 2013)(Wallace et al. 2016)(Mikita et al. 2016).

Rostoucí výška letu UAV měla negativní dopad na hustotu bodů i polohovou přesnost odvozeného DAP mračna. Příliš nízká výška letu naopak způsobovala, že se v některých částech lokality nepodařilo mračno rekonstruovat. Orientačně lze doporučit, aby ani v případech, kdy je prioritou co nejpodrobnější prostorové rozlišení, nepoklesla při využití UAV obdobné kategorie jako zde využitý DJI Phantom 3 Professional, výška letu pod 30 metrů nad nejvyšším bodem snímaného povrchu (včetně např. korun stromů). To platí zejména v případech, kdy je textura snímaného povrchu značně uniformní.

Přesto, že výsledky zkoumaných DAP mračen z nejvyšší letové hladiny 150 m patří z hlediska prostorové přesnosti k těm nejslabším (průměrná odchylka od ULS mračna 0,64 m) jedná se stále o poměrně přijatelnou chybu například pro určení výšky stromu v porovnání s běžnými pozemními metodami měření výšky (pomocí laserového výškoměru), která je uváděna například ve výši -0,27 m v porovnání s měřením pokáceného kmene (Andersen et al. 2006), ovšem při průměrování měření výšky stojícího stromu ze tří záměr, což značně převyšuje běžnou praxi. Obdobně (Luoma et al. 2017) uvádí odchylku cca 0,5 m.

V rámci porovnání dvou příkladů software použitého pro rekonstrukci DAP bodového mračna metodou SfM dosáhl komerční Agisoft Metashape v základním nastavení jednoznačně lepších výsledků co do hustoty bodů i relativního pokrytí výzkumné lokality. Nicméně je třeba připomenout, že oba programy byly používány primárně v defaultním nastavení, takže při vhodném doladění nelze vyloučit, že by i mračna připravená v rámci open-source alternativy WebODM dosahovala obdobných hodnot.

Z porovnání polohové přesnosti naopak vyplývá, že WebODM mračna poskytovala lepší výsledky než Metashape. I s určitou mírou opatrnosti vzhledem k rozdílné hustotě mračen, lze výsledky shrnout tak, že WebODM, jako volně dostupná alternativa, je plně konkurenceschopná na poli tvorby DAP mračen. K podobným

výsledkům došli také například (Groos et al. 2019) srovnávající OpenDroneMap (ODM je příkazovým řádkem ovládané jádro využívané i v WebODM) s komerčním produktem Pix4D (Pix4D SA 2020), nebo (White et al. 2020). Neuspokojivé výsledky uvedené v (Madawalagama et al. 2017) lze přičíst rannému stádiu ODM v době provádění výzkumu.

### **Vliv kvality bodového mračna na přesnost odvozování vybraných výstupů.**

Model se smíšenými efekty pro odhad šířky koruny na základě výšky stromu, využívající inventarizační plochu jako náhodného efektu, odvozený z datové sady šetření Národní inventarizace lesů, vykazoval podmíněný koeficient determinace ve výši 0,70 což je slibnější hodnota než například 0,51 uveřejněná u podobného modelu pouze s pevnými efekty v (Popescu et al. 2003).

Lokální kalibrace modelu predikce šířky koruny na základě výšky stromu vedla k významnému zpřesnění odhadů modelu pro danou lokalitu. Jako optimální se při porovnání modelů s různým počtem kalibračních vzorků, využitých pro stanovení šířky okna procedury LMF při identifikaci jednotlivých stromů v rámci ULS bodového mračna, osvědčil model založený na všech druzích dřevin, kalibrovaný s využitím 5 kalibračních měření. Relativní chyba počtu stromů na zkusných lokalitách byla v případě využití tohoto modelu ve výši -0,17. Hodnoty v podobných rozsazích 50 až 140% s použitím různých metod ITD publikoval například (Wang et al. 2016). Úspěšnost detekce 95% u jehličnatých a 71% u listnatých dřevin byla publikována v (Grznárová et al. 2019). Hodnot 64 až 97% úspěšnosti ITD bylo dosaženo v (Nevalainen et al. 2017).

Úspěšnost identifikace jednotlivých stromů se lišila podle výšky porostu, nejlepších hodnot dosahovala u nejvyšších porostů (20 až 30m) s relativní chybou +0,05 a naopak nejhorší byla u porostů s výškou 5 až 10m kde dosáhla relativní chyby -0,49. Podobného trendu výsledků s úspěšností detekce 38 až 85% podle výšky stromů dosahoval (Jeronimo et al. 2018).

Identifikace jednotlivých stromů v DAP bodových mračcích, s využitím šířky plovoucího okna LMF procedury odvozené pomocí lokálně kalibrovaného modelu šířky koruny, vedla v průměru k výsledné relativní chybě počtu stromů -0,46. U nižších stromů byla tato chyba vyšší, což lze částečně vysvětlit obtížnějším rozlišením jednotlivých stromů v hustých porostech mladších růstových fází

odpovídajících těmto výškám a částečně také vlivem druhů dřevin vyskytujícím se na výzkumné lokalitě v této růstové fázi.

Slabší úspěšnost identifikace jednotlivých stromů pravděpodobně významně ovlivňuje i úspěšnost odvození dalších parametrů. Za předpokladu, že ITD nebyla schopna identifikovat zejména nižší stromy v rámci zkusné plochy lze očekávat větší vliv na průměrnou výšku než na maximální výšku. Tomu do značné míry odpovídají i výsledky, kdy relativní chyba průměrné výšky byla -0,32, zatímco u maximální výšky to bylo -0,25. Řada studovaných zdrojů v tomto směru dosahovala podstatně lepších výsledků, ovšem je třeba připomenout, že často se studie zabývala porovnáním výšek stromů v omezeném výškovém rozsahu a v poměrně jednoduše strukturovaných porostech. V řadě případů navíc bylo také zapojeno manuální zpřesnění identifikace jednotlivých stromů, jako třeba v (Lisein et al. 2013). Negativní vliv komplexnější struktury porostu na úspěšnost identifikace jednotlivých stromů byl názorně demonstrován v (Jeronimo et al. 2018).

I když bylo v kapitole 5.2 prokázáno, že vybrané parametry (výška letu UAV a software použitý pro rekonstrukci bodového mračka) mají významný vliv na prostorovou přesnost DAP mračen, při identifikaci jednotlivých stromů v rámci těchto mračen pomocí LMF postupu se tento vliv neprojevil. Nebyl potvrzen statisticky významný vliv žádného ze sledovaných parametrů souvisejících s tvorbou DAP bodového mračka (výška letu, rychlost letu, světelné podmínky, software) na chybu stanovení počtu stromů, průměrnou a maximální výšku na zkusné ploše na základě identifikace jednotlivých stromů s využitím LMF. K podobným výsledkům, kdy vliv světelných podmínek na odhad výšky stromů z DAP bodového mračka nebyl prokázán, dochází (Dandois et al. 2015).

### **Shrnutí diskuze**

Přesto, že byl prokázán významný vliv vnějších podmínek (výška letu, rychlost letu, světelné podmínky) na prostorové rozlišení jednotlivých snímků, u DAP bodových mračen se tento vliv již projevil pouze částečně, když pouze výška letu ovlivňovala všechny tři kvalitativní parametry DAP bodového mračka (hustota bodů, stupeň pokrytí lokality a polohová přesnost). Výstupy identifikace jednotlivých stromů v rámci DAP bodových mračen pak již nebyly vnějšími podmínkami panujícími během letové mise významně ovlivněny. Tyto závěry jsou v souladu se zjištěními jiných studií, které například neprokázaly další zlepšení výsledků identifikace



jednotlivých stromů v rámci ALS bodových mračen při zvyšování hustoty mračna nad určitou úroveň (Kandare et al. 2016)(Magnussen et al. 2010)

## 7 Závěr

Vnější podmínky (výška letu, rychlost letu a světelné podmínky) při pořízení snímků prostřednictvím UAV významně ovlivňují prostorové rozlišení jednotlivých snímků. Skutečné prostorové rozlišení GRD bylo v případě zde využitého UAV v průměru dvakrát horší než teoreticky vypočtená hodnota GSD.

Kvalita DAP bodového mračna (pokrytí, hustota bodů a polohová přesnost) je z výše uvedených vnějších podmínek ovlivňována zejména výškou letu a částečně také rychlostí letu. Naopak u světelných podmínek nebyl potvrzen významný vliv ani na jeden z uvedených kvalitativních parametrů DAP mračna, což lze také interpretovat tak, že i za ne zcela ideálních světelných podmínek lze pořídit obrazová data vhodná pro využití při monitoringu lesních porostů.

Výsledky identifikace jednotlivých stromů v DAP bodovém mračnu pak nebyly významně ovlivněny ani jednou z uvedených tří vnějších podmínek při pořízení snímků UAV, z čehož lze vyvodit, že hustota DAP bodových mračen se v případě zde využitého fotoaparátu i v letové výšce 150 metrů pohybuje v takových hodnotách, že její další zvyšování při nižších letových výškách nevede k významnému zpřesnění výsledků identifikace jednotlivých stromů.

Vliv letové výšky byl patrný při analýze kvalitativních parametrů DAP bodového mračna, nicméně při následné identifikaci jednotlivých stromů v rámci bodového mračna se již nepotvrdil jako významný. Z tohoto pohledu, i s ohledem na hodnoty polohové přesnosti bodových mračen dosahované u nejvyšší letové hladiny, lze učinit závěr, že při využití DAP bodového mračna pro popis lesních porostů pomocí individuálního přístupu je možné preferovat vyšší letové výšky, které poskytují v zásadě srovnatelné výstupy a zároveň umožňují pořídit v rámci jednoho letu snímky většího území. Vzhledem k tomu, že pro řadu potenciálních uživatelů (v otevřené kategorii) je nově maximální výška letu omezena na 120 metrů nad terénem (Evropská Komise 2019), je možné doporučit právě tuto hodnotu.

Vzhledem k tomu, že příliš malá vzdálenost UAV od povrchu vedla k problémům při rekonstrukci fotogrammetrického mračna, lze pro plánování a provedení letové

mise silně doporučit využití takového programu, který umožňuje udržovat konstantní výšku nad terénem zohledňující reliéf na základě DTM, nikoliv konstantní výšku pouze nad bodem startu, což platí zejména při snímkování terénu s proměnlivou výškou. V případě, že není možné využít software zohledňující průběh terénu, lze silně doporučit, aby letová hladina byla volena vzhledem k nejvyššímu bodu snímaného povrchu.

Využití modelu odhadu šířky koruny z výšky stromu pro stanovení variabilní šířky plovoucího okna při LMF identifikaci jednotlivých stromů představuje poměrně univerzální základní východisko pro další zpřesňování s ohledem na konkrétní situaci v šetřené oblasti. Postup kalibrace modelu na základě místního šetření pak umožňuje využití představeného modelu pro lokality, kde se dřevinné složení významně neodchyluje od dřevinné skladby ČR.

Za pomoci široce dostupných UAV, jako je zde používaný, dnes již překonaný, DJI Phantom 3 Professional, lze, ve spojení s open-source software WebODM a LidR balíčkem v rámci R, provádět finančně dostupný monitoring lesních porostů ve velkém detailu s přijatelnou přesností.

## 8 Seznam literatury a použitých zdrojů

ADOLT, Radim, Miloš KUČERA, Jiří ZAPADLO, Milan ANDRLÍK, Zbyněk ČECH a Jaroslav COUFAL, 2013. *Pracovní postupy pozemního šetření NIL2* [online]. B.m.: Ústav pro hospodářskou úpravu lesů Brandýs nad Labem. ISBN 9788090542327. Dostupné z: [https://nil.uhul.cz/downloads/pp\\_nil2/2013\\_09\\_13\\_0\\_pp\\_nil2.pdf](https://nil.uhul.cz/downloads/pp_nil2/2013_09_13_0_pp_nil2.pdf)

AGISOFT-LLC, 2019. *Agisoft Metashape Professional Edition, Version 1.55*. 2019.

ANDERSEN, Hans Erik, Stephen E. REUTEBUCH a Robert J. MCGAUGHEY, 2006. A rigorous assessment of tree height measurements obtained using airborne lidar and conventional field methods. *Canadian Journal of Remote Sensing* [online]. **32**(5), 355–366. ISSN 17127971. Dostupné z: doi:10.5589/m06-030

ANDERSON, Karen a Kevin J. GASTON, 2013. Lightweight unmanned aerial vehicles will revolutionize spatial ecology. *Frontiers in Ecology and the Environment* [online]. **11**(3), 138–146. ISSN 15409295. Dostupné z: doi:10.1890/120150

BECHTOLD, William A., 2003. Crown-Diameter Prediction Models for 87 Species of Stand-Grown Trees in the Eastern United States. *Southern Journal of Applied Forestry* [online]. **27**(4), 269–278. ISSN 01484419. Dostupné z: doi:10.1093/sjaf/27.4.269

BÖHM, Jozef (Vysoká škola báňská – technická univerzita Ostrava.), 2002. *Fotogrammetrie* [online] [vid. 2017-06-26]. Dostupné z: <http://igdm.vsb.cz/igdm/materialy/Fotogrammetrie.pdf>

CALAMA, R. a G. MONTERO, 2006. Stand and tree-level variability on stem form and tree volume in *Pinus pinea* L.: A multilevel random components approach. *Investigación Agraria: Sistemas y Recursos Forestales* [online]. **15**(1), 24. ISSN 1131-7965. Dostupné z: doi:10.5424/srf/2006151-00951

ČESKO, 2014. *Předpis L2 Doplněk X zákona č. 49/1997 Sb. z roku 2014*. 2014. B.m.: Česká republika.

CLOUDCOMPARE, 2021. *Cloudcompare 2.11.1* [online]. 2021. Dostupné z: <http://www.cloudcompare.org/>

COLOMINA, I. a P. MOLINA, 2014. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing* [online]. **92**, 79–97. ISSN 09242716. Dostupné z: doi:10.1016/j.isprsjprs.2014.02.013

CRAMER, Michael a Shuhang ZHANG, 2020. Quality assessment of high-resolution UAV imagery and products. In: *40. Wissenschaftlich-Technische Jahrestagung der DGPF in Stuttgart*.

CULVENOR, Darius S., 2002. TIDA: An algorithm for the delineation of tree crowns in high spatial resolution remotely sensed imagery. *Computers and Geosciences* [online]. **28**(1), 33–44. ISSN 00983004. Dostupné z: doi:10.1016/S0098-3004(00)00110-2

DABROWSKI, R., A. ORYCH, A. JENEROWICZ a P. WALCZYKOWSKI, 2015. Preliminary results from the Portable Imagery Quality Assessment Test Field (PIQuAT) of UAV imagery for imagery reconnaissance purposes. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* [online]. **40**(1W4), 111–115. ISSN 16821750. Dostupné z: doi:10.5194/isprsarchives-XL-1-W4-111-2015

DANDOIS, Jonathan P. a Erle C. ELLIS, 2013. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. *Remote Sensing of Environment* [online]. **136**, 259–276 [vid. 2017-07-03]. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2013.04.005

DANDOIS, Jonathan P., Marc OLANO a Erle C. ELLIS, 2015. Optimal altitude, overlap, and weather conditions for computer vision uav estimates of forest structure. *Remote Sensing* [online]. ISSN 20724292. Dostupné z: doi:10.3390/rs71013895

DEMPEWOLF, Jan, Jyoteshwar NAGOL, Sebastian HEIN, Carsten THIEL a Reiner ZIMMERMANN, 2017. Measurement of Within-Season Tree Height Growth in a Mixed Forest Stand Using UAV Imagery. *Forests* [online]. **8**(7), 231 [vid. 2017-08-01]. ISSN 1999-4907. Dostupné z: doi:10.3390/f8070231

DJI, 2017. *Phantom 3 Professional User manual* [online]. 2017. B.m.: DJI. [vid. 2021-01-15]. Dostupné z: [https://dl.djicdn.com/downloads/phantom\\_3/UserManual/Phantom\\_3\\_Professional\\_User\\_Manual\\_v1.8\\_en.pdf](https://dl.djicdn.com/downloads/phantom_3/UserManual/Phantom_3_Professional_User_Manual_v1.8_en.pdf)

DOLANSKÝ, Tomáš, 2004. *Lidary a letecké laserové skenování*. B.m.: Studia Geoinformatica. ISBN 8070445750.

DRONEDEPLOY, Inc., 2020. *DroneDeploy Drone mapping software* [online]. Dostupné z: [dronedeploy.com](https://www.dronedeploy.com)

ELTNER, Anette, Andreas KAISER, Carlos CASTILLO, Gilles ROCK, Fabian NEUGIRG a Antonio ABELLÁN, 2016. Image-based surface reconstruction in geomorphometry-merits, limits and developments. *Earth Surface Dynamics* [online]. **4**(2), 359–389. ISSN 2196632X. Dostupné z: doi:10.5194/esurf-4-359-2016

EU, 2018. *Nářízení Evropského parlamentu a Rady (EU) 2018/1139 ze dne 4. července 2018 o společných pravidlech v oblasti civilního letectví a o zřízení Agentury Evropské unie pro bezpečnost letectví, kterým se mění nařízení (ES) č. 2111/2005, (ES) č. 1008/2008, (EU.*

2018.

EVROPSKÁ KOMISE, 2019. Prováděcí Nařízení Komise (EU) 2019/947. *Úřední věstník Evropské unie*. **2019**(6), 1–27.

FRASER, Clive, 2018. Camera Calibration Considerations for UAV Photogrammetry. In: [online]. [vid. 2021-02-03]. Dostupné z: <https://www.isprs.org/tc2-symposium2018/images/ISPRS-Invited-Fraser.pdf>

FU, Liyong, Hua SUN, Ram P. SHARMA, Yuancai LEI, Huiru ZHANG a Shouzheng TANG, 2013. Nonlinear mixed-effects crown width models for individual trees of Chinese fir (*Cunninghamia lanceolata*) in south-central China. *Forest Ecology and Management*. **302**, 210–220.

GIANNETTI, Francesca, Gherardo CHIRICI, Terje GOBAKKEN, Erik NÆSSET, Davide TRAVAGLINI a Stefano PULITI, 2018. A new approach with DTM-independent metrics for forest growing stock prediction using UAV photogrammetric data. *Remote Sensing of Environment* [online]. **213**(June 2017), 195–205. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2018.05.016

GILL, Samantha J., Gregory S. BIGING a Edward C. MURPHY, 2000. Modeling conifer tree crown radius and estimating canopy cover. *Forest Ecology and Management* [online]. **126**(3), 405–416. ISSN 03781127. Dostupné z: doi:10.1016/S0378-1127(99)00113-9

GOODBODY, Tristan R.H., Nicholas C. COOPS, Peter L. MARSHALL, Piotr TOMPALSKI a Patrick CRAWFORD, 2017. Unmanned aerial systems for precision forest inventory purposes: A review and case study. *Forestry Chronicle* [online]. **93**(1). ISSN 00157546. Dostupné z: doi:10.5558/tfc2017-012

GROOS, Alexander R., Thalia J. BERTSCHINGER, Céline M. KUMMER, Sabrina ERLWEIN, Lukas MUNZ a Andreas PHILIPP, 2019. The potential of low-cost UAVs and open-source photogrammetry software for high-resolution monitoring of alpine glaciers: A case study from the Kanderfirn (Swiss Alps). *Geosciences (Switzerland)* [online]. **9**(8). ISSN 20763263. Dostupné z: doi:10.3390/geosciences9080356

GRZNÁROVÁ, A., M. MOKROŠ, P. SUROVÝ, M. SLAVÍK, M. PONDELÍK a J. MERGANIČ, 2019. THE CROWN DIAMETER ESTIMATION FROM FIXED WING TYPE OF UAV IMAGERY [online]. [vid. 2020-08-14]. Dostupné z: doi:10.5194/isprs-archives-XLII-2-W13-337-2019

GUERRA-HERNÁNDEZ, Juan, Diogo N. COSENZA, Luiz Carlos Estraviz RODRIGUEZ, Margarida SILVA, Margarida TOMÉ, Ramón A. DÍAZ-VARELA a Eduardo GONZÁLEZ-FERREIRO, 2018. Comparison of ALS- and UAV(SfM)-derived high-density point clouds for individual tree detection in Eucalyptus

plantations. *International Journal of Remote Sensing* [online]. **39**(15–16), 5211–5235. ISSN 13665901. Dostupné z: doi:10.1080/01431161.2018.1486519

HARVEY, Phil, 2016. *ExifTool* [online]. 2016. Dostupné z: <https://exiftool.org/>

HONKAVAARA, E., J. JAAKKOLA, L. MARKELIN a S. BECKER, 2006. Evaluation of resolving power and MTF of DMC. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. **36**. ISSN 17689791.

IGLHAUT, Jakob, Carlos CABO, Stefano PULITI, Livia PIERMATTEI, James O'CONNOR, Jacqueline ROSETTE, A Ac UK a Gonzalo GUTIÉRREZ QUIRÓS, 2019. Structure from Motion Photogrammetry in Forestry: a Review [online]. [vid. 2020-01-03]. Dostupné z: doi:10.1007/s40725-019-00094-3

JAAKKOLA, Anttoni, Juha HYYPPÄ, Xiaowei YU, Antero KUKKO, Harri KAARTINEN, Xinlian LIANG, Hannu HYYPPÄ a Yunsheng WANG, 2017. Autonomous Collection of Forest Field Reference—The Outlook and a First Step with UAV Laser Scanning. *Remote Sensing* [online]. **9**(8), 785 [vid. 2017-08-01]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs9080785

JERONIMO, Sean M.A., Van R. KANE, Derek J. CHURCHILL, Robert J. MCGAUGHEY a Jerry F. FRANKLIN, 2018. Applying LiDAR individual tree detection to management of structurally diverse forest landscapes. *Journal of Forestry* [online]. **116**(4), 336–346. ISSN 19383746. Dostupné z: doi:10.1093/jofore/fvy023

KANDARE, Kaja, Hans Ole ØRKA, Jonathan Cheung Wai CHAN a Michele DALPONTE, 2016. Effects of forest structure and airborne laser scanning point cloud density on 3D delineation of individual tree crowns. *European Journal of Remote Sensing* [online]. **49**, 337–359. ISSN 22797254. Dostupné z: doi:10.5721/EuJRS20164919

KATOH, Masato a Francois A. GOUGEON, 2012. Improving the Precision of Tree Counting by Combining Tree Detection with Crown Delineation and Classification on Homogeneity Guided Smoothed High Resolution (50 cm) Multispectral Airborne Digital Data. *Remote Sensing* [online]. **4**(12), 1411–1424 [vid. 2017-07-03]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs4051411

KE, Yinghai a Lindi J. QUACKENBUSH, 2011. A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. <http://dx.doi.org/infozdroje.czu.cz/10.1080/01431161.2010.494184> [online]. **32**(17), 4725–4747 [vid. 2021-11-23]. ISSN 13665901. Dostupné z: doi:10.1080/01431161.2010.494184

KUČERA, Miloš a Radim ADOLT, ed., 2019. *Národní inventarizace lesů v České republice - výsledky druhého cyklu 2011-2015* [online]. Brandýs nad Labem: Ústav pro

hospodářskou úpravu lesů Brandýs nad Labem. ISBN 978-80-88184-23-2. Dostupné z: [https://nil.uhul.cz/downloads/2019\\_kniha\\_nil2\\_web.pdf](https://nil.uhul.cz/downloads/2019_kniha_nil2_web.pdf)

KUŽELKA, Karel a Peter SUROVÝ, 2017. *Systém operativního leteckého snímkování pro doplňování ortofotografií po hospodářských zásazích nebo po kalamitách*. Praha: Česká zemědělská univerzita v Praze. ISBN 9788021328.

LAPPI, J, 1991. Calibration of Height and Volume Equations with Random Parameters. *Forest Science*. **37**(3), 781–801.

LEE, Jaeone a Sangmin SUNG, 2016. Evaluating spatial resolution for quality assurance of UAV images. *Spatial Information Research* [online]. **24**(2), 141–154 [vid. 2021-01-02]. ISSN 23663294. Dostupné z: doi:10.1007/s41324-016-0015-0

LIM, Pyung Chae, Taejung KIM, Sang Il NA, Kyung Do LEE, Ho Yong AHN a Jaeyoung HONG, 2018a. Analysis of uav image quality using edge analysis. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* [online]. **42**(4), 359–364. ISSN 16821750. Dostupné z: doi:10.5194/isprs-archives-XLII-4-359-2018

LIM, Pyung Chae, Junghoon SEO a Taejung KIM, 2018b. Extraction of UAV Image Sharpness Index Using Edge Target Analysis. *Korean Journal of Remote Sensing*. **34**(6), 905–923. ISSN 1225-6161.

LISEIN, Jonathan, Marc PIERROT-DESEILLIGNY, Stephanie BONNET a Philippe LEJEUNE, 2013. A Photogrammetric Workflow for the Creation of a Forest Canopy Height Model from Small Unmanned Aerial System Imagery. *Forests* [online]. **4**(4), 922–944 [vid. 2017-07-03]. ISSN 1999-4907. Dostupné z: doi:10.3390/f4040922

LONG, Jacob A, 2020. *jtools: Analysis and Presentation of Social Scientific Data* [online]. 2020. Dostupné z: <https://cran.r-project.org/package=jtools>

LOWE, David G., 2004. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision* [online]. **60**(2), 91–110. ISSN 09205691. Dostupné z: doi:10.1023/B:VISI.0000029664.99615.94

LÜDECKE, Daniel, 2021. *sjPlot: Data Visualization for Statistics in Social Science* [online]. 2021. Dostupné z: <https://cran.r-project.org/package=sjPlot>

LUOMA, Ville, Ninni SAARINEN, Michael A. WULDER, Joanne C. WHITE, Mikko VASTARANTA, Markus HOLOPAINEN a Juha HYYPPÄ, 2017. Assessing precision in conventional field measurements of individual tree attributes. *Forests* [online]. **8**(2), 1–16. ISSN 19994907. Dostupné z: doi:10.3390/f8020038

LYNCH, Thomas B., A. Gordon HOLLEY a Douglas J. STEVENSON, 2005. A

random-parameter height-dbh model for cherrybark oak. *Southern Journal of Applied Forestry* [online]. **29**(1), 22–26. ISSN 01484419. Dostupné z: doi:10.1093/sjaf/29.1.22

MADAWALAGAMA, S. L., D. R.M. ATHUKORALA, K. C. JAYAMAL, S. OCHI a L. SAMARAKOON, 2017. Assessment of UAV based low cost photogrammetric system for aerial mapping. *38th Asian Conference on Remote Sensing - Space Applications: Touching Human Lives, ACRS 2017*. **2017-Octob**(March), 1V.

MAGNUSSEN, S., E. NÆSSET a T. GOBAKKEN, 2010. Reliability of LiDAR derived predictors of forest inventory attributes: A case study with Norway spruce. *Remote Sensing of Environment* [online]. **114**(4), 700–712. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2009.11.007

MEISSNER, H., M. CRAMER a R. REULKE, 2018. Towards standardized evaluation of image quality for airborne camera systems. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* [online]. **42**(1), 295–300. ISSN 16821750. Dostupné z: doi:10.5194/isprs-archives-XLII-1-295-2018

MESSINGER, Max, Gregory ASNER a Miles SILMAN, 2016. Rapid Assessments of Amazon Forest Structure and Biomass Using Small Unmanned Aerial Systems. *Remote Sensing* [online]. **8**(8), 615 [vid. 2017-06-26]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs8080615

MIKITA, Tomáš, Přemysl JANATA a Peter SUROVÝ, 2016. Forest Stand Inventory Based on Combined Aerial and Terrestrial Close-Range Photogrammetry. *Forests* [online]. **7**(8), 165 [vid. 2016-11-24]. ISSN 1999-4907. Dostupné z: doi:10.3390/f7080165

MLAMBO, Reason, Iain WOODHOUSE, France GERARD a Karen ANDERSON, 2017. Structure from Motion (SfM) Photogrammetry with Drone Data: A Low Cost Method for Monitoring Greenhouse Gas Emissions from Forests in Developing Countries. *Forests* [online]. **8**(3), 68 [vid. 2017-06-26]. ISSN 1999-4907. Dostupné z: doi:10.3390/f8030068

NAKAGAWA, Shinichi, Paul C.D. JOHNSON a Holger SCHIELZETH, 2017. The coefficient of determination  $R^2$  and intra-class correlation coefficient from generalized linear mixed-effects models revisited and expanded. *Journal of the Royal Society Interface* [online]. **14**(134). ISSN 17425662. Dostupné z: doi:10.1098/rsif.2017.0213

NEVALAINEN, Olli, Eija HONKAVAARA, Sakari TUOMINEN, Niko VILJANEN, Teemu HAKALA, Xiaowei YU, Juha HYYPPÄ, Heikki SAARI, Ilkka PÖLÖNEN, Nilton N. IMAI a Antonio M.G. TOMMASELLI, 2017. Individual tree detection and



classification with UAV-Based photogrammetric point clouds and hyperspectral imaging. *Remote Sensing* [online]. 9(3). ISSN 20724292. Dostupné z: doi:10.3390/rs9030185

NOŽIČKA, Josef, 1957. *Přehled vývoje našich lesů* [online]. Praha: Státní zemědělské nakladatelství. Dostupné z: <https://www.digitalniknihovna.cz/mzk/view/uuid:b74fe910-bac5-11e6-83d2-005056827e52?page=uuid:ae7ba030-c7be-11e6-b22f-5ef3fc9ae867>

O'CONNOR, James, Mike J. SMITH a Mike R. JAMES, 2017. Cameras and settings for aerial surveys in the geosciences: Optimising image data. *Progress in Physical Geography* [online]. 41(3), 325–344. ISSN 03091333. Dostupné z: doi:10.1177/0309133317703092

ORYCH, A, 2015. Review of methods for determining the spatial resolution of UAV sensors. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* [online]. s. 391–395 [vid. 2019-05-07]. ISSN 16821750. Dostupné z: doi:10.5194/isprsarchives-XL-1-W4-391-2015

PAJARES, Gonzalo, 2015. Overview and current status of remote sensing applications based on unmanned aerial vehicles (UAVs). *Photogrammetric Engineering and Remote Sensing* [online]. 81(4). ISSN 00991112. Dostupné z: doi:10.14358/PERS.81.4.281

PANAGIOTIDIS, Dimitrios, Azadeh ABDOLLAHNEJAD, Peter SUROVÝ a Vasco CHITECULO, 2016. Determining tree height and crown diameter from high-resolution UAV imagery. *International Journal of Remote Sensing* [online]. 38(8–10), 1–19 [vid. 2017-07-12]. ISSN 0143-1161. Dostupné z: doi:10.1080/01431161.2016.1264028

PAVELKA, Karel, 2003. *Fotogrammetrie*. Praha: České vysoké učení technické v Praze – fakulta stavební.

PIX4D SA, 2020. *Pix4D* [online]. 2020. Dostupné z: [pix4d.com](http://pix4d.com)

PLOWRIGHT, Andrew a Jean-Romain ROUSSEL, 2021. *ForestTools: Analyzing Remotely Sensed Forest Data* [online]. 2021. Dostupné z: <https://cran.r-project.org/package=ForestTools>

POPESCU, Sorin C., Randolph H. WYNNE a Ross F. NELSON, 2003. Estimating plot-level tree heights with lidar: Local filtering with a canopy-height based variable window size. *Computers and Electronics in Agriculture* [online]. 37(1–3), 71–95. ISSN 01681699. Dostupné z: doi:10.1016/S0168-1699(02)00121-7

POULIOT, D. A., D. J. KING, F. W. BELL a D. G. PITT, 2002. Automated tree crown

detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration. *Remote Sensing of Environment* [online]. **82**(2–3), 322–334. ISSN 00344257. Dostupné z: doi:10.1016/S0034-4257(02)00050-0

PULITI, Stefano, Hans OLERKA, Terje GOBAKKEN a Erik NÆSSET, 2015. Inventory of Small Forest Areas Using an Unmanned Aerial System. *Remote Sensing* [online]. **7**(8), 9632–9654 [vid. 2017-07-03]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs70809632

R CORE TEAM, 2020. *R: A Language and Environment for Statistical Computing* [online]. 2020. Dostupné z: <https://www.r-project.org/>

RIEGL, 2019. RIEGL RIEGL VUX-SYS VUX-SYS Complete Sensor System for Kinematic Laser Scanning [online]. [vid. 2021-08-06]. Dostupné z: [http://www.riegl.com/uploads/tx\\_pxriegl/downloads/RIEGL\\_VUX-SYS\\_Datasheet\\_2020-10-02\\_01.pdf](http://www.riegl.com/uploads/tx_pxriegl/downloads/RIEGL_VUX-SYS_Datasheet_2020-10-02_01.pdf)

ROUSSEL, Jean-Romain a David AUTY, 2021. *Airborne LiDAR Data Manipulation and Visualization for Forestry Applications* [online]. 2021. Dostupné z: <https://cran.r-project.org/package=lidR>

RSTUDIO TEAM, 2019. *RStudio: Integrated Development Environment for R* [online]. 2019. Dostupné z: <http://www.rstudio.com/>

SCHNEIDER, Caroline A, Wayne S RASBAND a Kevin W ELICEIRI, 2012. NIH Image to ImageJ: 25 years of image analysis. *Nature Methods* [online]. **9**(7), 671–675. ISSN 1548-7105. Dostupné z: doi:10.1038/nmeth.2089

SHUM, Heung Yeung, Qifa KE a Zhengyou ZHANG, 1999. *Efficient bundle adjustment with virtual key frames: A hierarchical approach to multi-frame structure from motion* [online]. 1999. ISSN 10636919. Dostupné z: doi:10.1109/cvpr.1999.784733

SJOBERG, Daniel D, Karissa WHITING, Michael CURRY, Jessica A LAVERY a Joseph LARMARANGE, 2021. Reproducible Summary Tables with the gtsummary Package. *The R Journal* [online]. **13**(1), 570–580. Dostupné z: doi:10.32614/RJ-2021-053

SLAVÍK, Martin, 2020. *Využití moderních technik laserového skenování pro sběr dat o lesních ekosystémech*. B.m. Česká zemědělská univerzita v Praze.

SPERLICH, Maximilian, Teja KATTENBORN, Barbara KOCH a Dr Gilbert KATTENBORN, 2008. Potential of Unmanned Aerial Vehicle Based Photogrammetric Point Clouds for Automatic Single Tree Detection [online]. [vid. 2017-07-03]. Dostupné z: <http://www.dgpf.de/neu/Proc2014/proceedings/papers/Beitrag270.pdf>

STÖCKER, Claudia, Mila KOEVA a Francesco NEX, 2018. Deliverable 4.2 Data quality assessment of UAV-based products for land tenure recording [online]. (2003), 3–55. Dostupné z: [www.its4land.com](http://www.its4land.com)

TOFFANIN, Piero, 2019. *OpenDroneMap: The Missing Guide* [online]. first. B.m.: UAV4GEO. Dostupné z: <https://odmbook.com/>

TOFFANIN, Piero, Nicolas CHAMO, Brandon BARKER, Pyup.io BOT, Abdelkoddouss IZEM, Dan JOSEPH, Anand MAHESH, Sylvain POULAIN, Nikos VES, Paul MUMBY, Patrick José PEREIRA, İbrahim SARIÇIÇEK, Islam HEGGY, Seth FITZSIMMONS, W-TOGUUCHI83, Gabriel GADELHA, JP STOERMER, Stephen MATHER, Andy LYONS, Chris DENNISTON, Fabian HORST, FALU, FLORIANMICKLER, Giovanni Cimolin da SILVA, HARDIK CHUGH, James LÉON-DUFOUR, DAEDROZA, Paul PICAZO a WASI, 2020. *OpenDroneMap/WebODM: 1.7.0*. 2020.

TOMPALSKI, Piotr, Nicholas COOPS, Joanne WHITE a Michael WULDER, 2015. Enriching ALS-Derived Area-Based Estimates of Volume through Tree-Level Downscaling. *Forests* [online]. 6(8), 2608–2630 [vid. 2017-10-05]. ISSN 1999-4907. Dostupné z: [doi:10.3390/f6082608](https://doi.org/10.3390/f6082608)

TRINCADO, Guillermo a Harold E. BURKHART, 2006. A generalized approach for modeling and localizing stem profile curves. *Forest Science* [online]. 52(6), 670–682. ISSN 0015749X. Dostupné z: [doi:10.1093/forestscience/52.6.670](https://doi.org/10.1093/forestscience/52.6.670)

TRINCADO, Guillermo, Curtis L. VANDERSCHAAF a Harold E. BURKHART, 2007. Regional mixed-effects height-diameter models for loblolly pine (*Pinus taeda* L.) plantations. *European Journal of Forest Research* [online]. 126(2), 253–262. ISSN 16124669. Dostupné z: [doi:10.1007/s10342-006-0141-7](https://doi.org/10.1007/s10342-006-0141-7)

UDIN, W S a A AHMAD, 2014. Assessment of Photogrammetric Mapping Accuracy Based on Variation Flying Altitude Using Unmanned Aerial Vehicle. *IOP Conference Series: Earth and Environmental Science* [online]. 18(1), 7 [vid. 2017-12-19]. ISSN 1755-1315. Dostupné z: [doi:10.1088/1755-1315/18/1/012027](https://doi.org/10.1088/1755-1315/18/1/012027)

VAŠÍČEK, Jaromír et al., 2007. *Národní inventarizace lesů v České republice: 2001-2004: Úvod, metody, výsledky*. Brandýs nad Labem: Ústav pro hospodářskou úpravu lesů Brandýs nad Labem. ISBN 978-80-7084-587-5.

WALLACE, Luke, Arko LUCIEER, Zbyněk MALENOVSKÝ, Darren TURNER a Petr VOPĚNKA, 2016. Assessment of Forest Structure Using Two UAV Techniques: A Comparison of Airborne Laser Scanning and Structure from Motion (SfM) Point Clouds. *Forests* [online]. 7(3), 62 [vid. 2016-08-17]. ISSN 1999-4907. Dostupné z: [doi:10.3390/f7030062](https://doi.org/10.3390/f7030062)

WANG, Yunsheng, Juha HYYPPA, Xinlian LIANG, Harri KAARTINEN, Xiaowei YU, Eva LINDBERG, Johan HOLMGREN, Yuchu QIN, Clement MALLET, Antonio FERRAZ, Hossein TORABZADEH, Felix MORSDORF, Lingli ZHU, Jingbin LIU a Petteri ALHO, 2016. International Benchmarking of the Individual Tree Detection Methods for Modeling 3-D Canopy Structure for Silviculture and Forest Ecology Using Airborne Laser Scanning. *IEEE Transactions on Geoscience and Remote Sensing* [online]. 54(9), 5011–5027. ISSN 01962892. Dostupné z: doi:10.1109/TGRS.2016.2543225

WESTOBY, M.J. J., J. BRASINGTON, N.F. F. GLASSER, M.J. J. HAMBREY a J.M. M. REYNOLDS, 2012. Structure-from-Motion photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology* [online]. 179, 300–314 [vid. 2017-06-26]. ISSN 0169555X. Dostupné z: doi:10.1016/j.geomorph.2012.08.021

WHITE, C, A PETRASOVA, W RECKLING a H MITASOVA, 2020. Automated Land Cover Change detection through rapid UAS updates of Digital Surface Models. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* [online]. XLII-3/W11 [vid. 2020-11-26]. Dostupné z: doi:10.5194/isprs-archives-XLII-3-W11-155-2020

WICKHAM, Hadley, 2016. *ggplot2: Elegant Graphics for Data Analysis* [online]. 1. vyd. B.m.: Springer-Verlag New York. ISBN 978-3-319-24277-4. Dostupné z: <https://ggplot2.tidyverse.org>

WICKHAM, Hadley a Jim HESTER, 2020. *readr: Read Rectangular Text Data* [online]. 2020. Dostupné z: <https://cran.r-project.org/package=readr>

WULDER, Mike, K. Olaf NIEMANN a David G. GOODENOUGH, 2000. Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. *Remote Sensing of Environment* [online]. 73(1), 103–114. ISSN 00344257. Dostupné z: doi:10.1016/S0034-4257(00)00101-2

YAO, Wei, Jan KRULL, Peter KRZYSTEK a Marco HEURICH, 2014. Sensitivity analysis of 3D individual tree detection from LiDAR point clouds of temperate forests. *Forests* [online]. 5(6), 1122–1142. ISSN 19994907. Dostupné z: doi:10.3390/f5061122

ZARCO-TEJADA, P. J., R. DIAZ-VARELA, V. ANGILERI a P. LOUDJANI, 2014. Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. *European Journal of Agronomy* [online]. 55. ISSN 11610301. Dostupné z: doi:10.1016/j.eja.2014.01.004

ZHANG, Wuming, Jianbo QI, Peng WAN, Hongtao WANG, Donghui XIE, Xiaoyan

WANG a Guangjian YAN, 2016. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing* [online]. **8**(6), 1–22 [vid. 2021-02-01]. ISSN 20724292. Dostupné z: [doi:10.3390/rs8060501](https://doi.org/10.3390/rs8060501)

## 9 Přílohy

**Příloha 1.** Kubišta J.; Surový P. Spatial resolution of unmanned aerial vehicles acquired imagery as a result of different processing conditions. 2021.

**Příloha 2.** Kubišta J.; Surový P Forest structure from UAV: software type has more influence on Structure from Motion point cloud than flight conditions. 2022.

**Příloha 3.** Kubišta J.; Surový P. Individual tree identification in ULS point clouds using a crown width mixed-effects model based on NFI data. 2022.

**Příloha 1. Kubišta J.; Surový P. Spatial resolution of unmanned aerial vehicles acquired imagery as a result of different processing conditions. 2021.**



# Spatial resolution of unmanned aerial vehicles acquired imagery as a result of different processing conditions

Jaroslav Kubišta<sup>1,2\*</sup>, Peter Surový<sup>1</sup>

<sup>1</sup> Czech University of Life Sciences, Faculty of Forestry and Wood Sciences, Prague, Kamýcká 129, CZ–165 00 Praha, Czech Republic

<sup>2</sup> Forest Management Institute, Nábřeží 1326, CZ – 250 01 Brandýs nad Labem, Czech Republic

## Abstract

Increasing availability of Unmanned aerial vehicles (UAV) and different software for processing of UAV imagery data brings new possibilities for on-demand monitoring of environment, making it accessible to broader spectra of professionals with variable expertise in image processing and analysis. This brings also new questions related to imagery quality standards. One of important characteristics of imagery is its spatial resolution as it directly impacts the results of object recognition and further imagery processing. This study aims at identifying relationship between spatial resolution of UAV acquired imagery and variables of imagery acquiring conditions, especially UAV flight height, flight speed and lighting conditions. All of these characteristics has been proved as significantly influencing spatial resolution quality and all subsequent data based on this imagery. Higher flight height as well as flight speed brings lower spatial resolution, whereas better lighting conditions lead to better spatial resolution of imagery. In this article we conducted a study testing various heights, flight speeds and light conditions and tested the impact of these parameters on Ground Resolved Distance (GRD). We proved that from among the variables, height is the most significant factor, second position is speed and finally the light condition. All of these factors could be relevant for instance in implementation of UAV in forestry sector, where imagery data must be often collected in diverse terrain conditions and/or complex stand (especially vertical) structure, as well as different weather conditions.

**Key words:** spatial resolution; ground resolved distance; light conditions; object identification; forestry sector

Editor: Bohdan Konôpka

## 1. Introduction

Unmanned aerial vehicles (UAV) or Unmanned aerial systems (UAS) have recently become increasingly available and thus ceased to be the prerogative of the army, and few scientific institutes. At present, inexpensive, user-friendly UAVs, with sufficient potential for aerial imaging can be easily purchased. Together with recent development in processing of digital imagery this brings new opportunities for on-demand monitoring available even for non-specialized practitioners (Pricope et al. 2019).

Consequently, new questions related to UAV imagery do emerge, such as what is the smallest object that can be identified on the image acquired on certain flight height, or what are the minimum required lighting conditions to perform imagery obtaining mission suitable for measurement of selected forest or tree parameters.

In other words, UAV imagery is facing new challenges in terms of describing requirements necessary

to meet expected quality (Lee & Sung, 2016) or quality standardization (Meißner et al. 2018). These challenges would be managed with regard to specific natural conditions. That is very relevant in forestry, a sector which is typical with very complex and variable conditions as for topography and forest stand traits. Spatial resolution is one of the basic characteristics of digital imagery with significant impact on object recognition results, therefore influencing any output derived from original UAV imagery. The smallest detectable object is related to this resolution and for the user interested in mensuration of particular variable or object (crown, individual tree), the information about the spatial resolution is crucial. Spatial resolution is often described by Ground Sampling Distance (GSD) (Orych 2015) which is a measure, that builds on known geometric parameters of camera and distance between camera and target.

Few studies examine further concepts such as Resolution, Resolution power (Lee & Sung 2016), Ground resolved distance (GRD) (Orych 2015) or True Ground

\*Corresponding author. Jaroslav Kubišta, e-mail: [kubista.jaroslav@uhul.cz](mailto:kubista.jaroslav@uhul.cz)



sample distance (tGSD) (Meißner et al. 2020) which takes into account whole complex of characteristics influencing the result image quality, including such variables as optical error of camera, atmospheric conditions etc. These approaches are based on visual analyses of different calibration targets, such as Bar target, Slanted edge test or Siemens star test to name few (Orych 2015).

Trends of spatial resolution related studies are described by Lee and Sung (Lee & Sung 2016). Siemens star calibration target is one of the methods, which is repeatedly reported to be used, to evaluate GRD (Cramer 2013; Dabrowski & Jenerowicz 2015; Dabrowski et al. 2015; Orych 2015). This test does not need any special equipment in terms of calibration target designing. Evaluation can be done based on visual analyses, without any special software. This target is also flexible in terms of flight direction and allows for defining resolution in a continuous way (Orych 2015).

This article is a first stage of study aimed at exploring the spatial resolution of images obtained by UAV DJI Phantom 3 Professional in different conditions. Following stage will explore how this spatial resolution influences the outcomes of typical Structure From Motion SFM processing pipeline resulting in surface point cloud of mixed forest stand.

Basic hypothesis assuming, that spatial resolution depends inter-alia on the flight altitude, flight speed and lighting conditions is examined in this first stage. The main aim of this work is to analyse which flight parameter, and with what impact is influencing the final GRD.

## 2. Material and methods

### 2.1. Explanation of basic terms

First of all, it is necessary to explain basic terms, which relates to the merit of our study. The terms are specifically Ground sampling distance, Ground resolved distance and Siemens star.

Ground sampling distance (GSD) in digital imagery represents the size of surface represented by single pixel of image. It is a theoretical measure that takes into account only geometry of camera (resolution of the sensor and lens focal distance) and distance to imaged surface or object. Other factors, such as system optics, interior noise, etc. are not considered (Orych 2015).

GSD can be calculated based on the real size of a single pixel on the sensor  $x$ , focal length of camera  $f$  and distance between camera and target  $h$  through formula:

$$GSD = x * h / f \quad [1]$$

Ground resolved distance (GRD) represents the smallest recognizable element on image. It can be determined by visual analysis on the basis of specific calibration targets, such as Siemens star (Orych 2015). Contrary to GSD, GRD is evaluated as a result of all factors influencing spatial resolution of imagery.

Siemens star represents the calibration target suitable for determination of GRD without any specific equipment other than target. Two types of Siemens star are used. Sinusoidal type for laboratory uses and Binary for outdoor testing. Binary Siemens star is formed by radial sectors alternating black and white color (Fig. 1a).

GRD determination using Siemens star with  $n$  sectors and diameter  $D$  is based on measuring the diameter  $d$  of blurred center up to the point where black and white sectors can be easily recognized (see Fig. 1b).

GRD can be then calculated based on formula:

$$GRD = \pi * d / n \quad [2]$$

GRD is key factor in subsequent analysis and data extraction from the imagery. And worse GRD definitely leads to lower success in studies dependent on pixel quality. For example, when detecting the tree position in small trees and regeneration of forest stands, or when trying to evaluate spectral reflectance on studies of tree health and physiology status (Klouček et al. 2019).

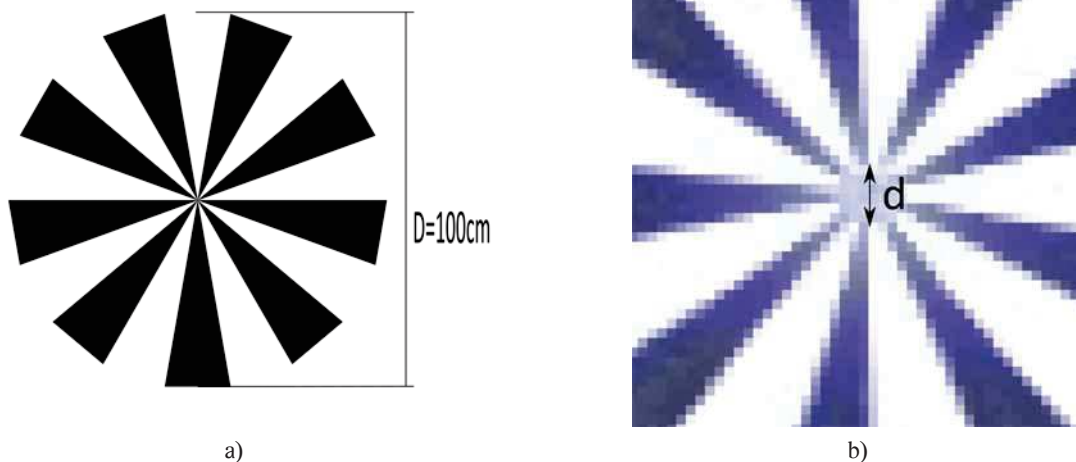


Fig. 1. Siemens star calibration target used in study (a). Blurred center (with diameter  $d$ ) of Siemens star calibration target (b).

## 2.2. Calibration target and study site

Binary Siemens star with 18 sectors of 100 cm diameter (Fig. 1a) printed on paper and laminated to prevent damage, served as a calibration target. Such target in theory allows measuring GRD from 0 to 17.453 cm. This should be sufficient, as the maximum planned flight height was 100 m with GSD 4.375 cm.

Target was placed in a paved, level area allowing for undisturbed UAV flying in vicinity of Forest Management Institute in Brandýs nad Labem, Middle Bohemia region (WGS 84: 50.1876N, 14.6702E).

## 2.3. Images acquisition

DJI Phantom 3 Professional as an example of low-cost, user friendly, widely available UAV was used to acquire images. Parameters of camera DJI FC300X carried by this UAV are specified in Table 1 (DJI 2017).

**Table 1.** DJI FC300X Camera specification.

Sensor	Sony EXMOR 1/2.3" CMOS Effective pixels: 12.4 M
Lens	20 mm (35 mm format equivalent) f/2.8 focus at ∞
ISO Range	100–1600 (photo)
Electronic Shutter Speed	8–1/8000 s
Image Size	4000×3000


Overall, four flight missions were performed to cover different light conditions, acquiring images in different altitudes roughly in 5-meter steps and different horizontal speed of flight. Camera pitch was set to 90 degrees and according to EXIF data originating from UAV Inertial Measurement Unit (IMU) this value was kept in all images with maximum deviance 0.1 degree, therefore all images are considered as nadir images.

## 2.4. Images processing

Non nadir exclusion: The distance between Siemens star target and image center is expected to influence GRD (Honkavaara et al. 2006a). As this study is primarily targeted on other influential conditions, images where Siemens star was out of the middle area of image defined according to grey area (see Fig. 2) were discarded, to eliminate influence of this variable.

EXIF metadata of relative altitude, x, y, z axis speed, aperture, exposure time and ISO, were extracted from all images using Exiftool utility (Harvey 2016). Images where z axis speed was higher than 0.1 m/s as well as

images with ISO value other than 100 were discarded. Speed was calculated based on x, y, z axis speed vectors. Aperture was set to constant value (maximum aperture was used that equals to 2.0 in case of this camera) in camera settings prior to each flight. Still EXIF metadata were used to confirm (successfully), that all images are of the same aperture value.



**Fig. 2.** Middle area (gray rectangles) of picture.

Using only images with same ISO and aperture allows to use exposure time as a descriptor of lighting conditions. Characteristics of resulting images set are summarized in Table 2.

## 2.5. GRD determination

In each image of resulting dataset, perimeter of blurred center area of Siemens star calibration target was measured using ImageJ software (Schneider et al. 2012).

Original RGB image was first transformed to 8-bit grayscale type using the ImageJ function Type/8-bit which uses the formula  $gray = (red + green + blue) / 3$ . In such image value of each pixel varies from 0 to 255. Using threshold function, area with pixel values from 0 to certain value, well corresponding with blurred center area, was highlighted. In each of nine dark (highlighted) sectors the closest-to-the-center point was identified as a border of blurred center area.

As this area is rarely of regular circular shape, rather than measuring the diameter of this area, segmented line tool was used to connect all sectors and measure the perimeter  $p$  of blurred area as in example Fig. 3a. Same area without applied threshold highlighting is in Fig. 3b.

**Table 2.** Flight missions characteristics.

Date	Weather	Images	Altitude [m AGL]		Speed [m/s]		Exposure [s]	
			min	max	min	max	min	max
2019-07-26	Sunny, very light wind	21	4.9	105.2	0.0	0.1	1/1750	1/811
2020-01-17	Sunny, very light wind	60	30.3	100.8	0.0	14.4	1/514	1/252
2020-10-08	Partly cloudy, light wind	64	6.2	70.3	0.0	12.6	1/736	1/176
2020-10-24	Mostly sunny, light wind	39	10.0	70.0	0.0	9.5	1/561	1/336
Total		184	4.9	105.2	0.0	14.4	1/1750	1/176

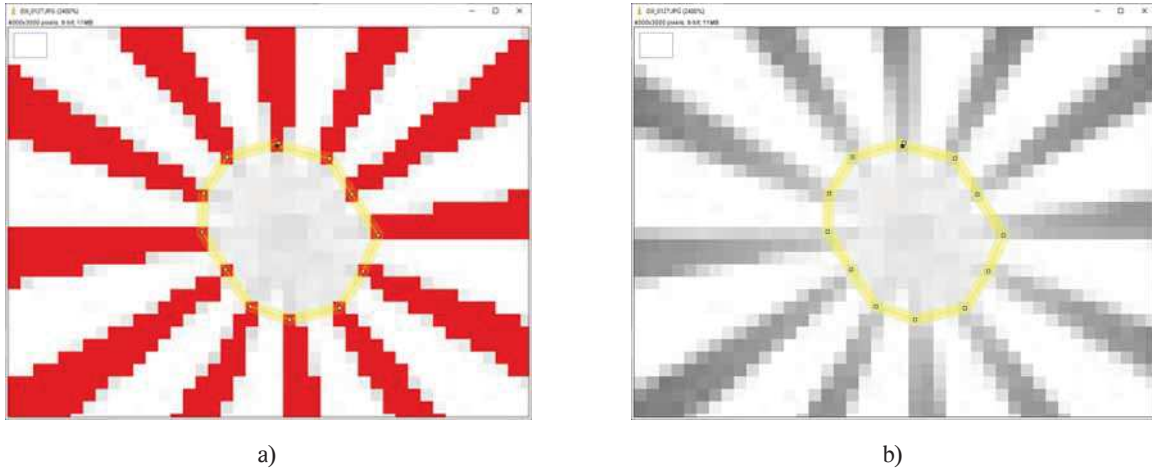


Fig. 3. Identification of blurred center area with (a) and without threshold highlight (b).

Using this method, formula to determinate GRD can be adjusted accordingly with perimeter  $p$  and number of segments  $n$ .

$$GRD = p/n \quad [3]$$

GSD was derived from altitude and known parameters of camera according to formula 1.

All statistical analyses were carried out in R-Studio version 1.4.1103 (RStudio Team 2019) with R version 4.0.3 (R Core Team 2020) using following libraries: JTools(Long 2020), Readr (Wickham & Hester 2020), GGplot2(Wickham 2016).

### 3. Results

In total 184 images from 4 flight missions were used for GRD evaluation (results overview is in Table 3).

Table 3. Basic statistics of GSD and GRD parameters of each of 184 images.

	GSD	GRD	GRD/GSD
	[cm]		[unitless]
Min	0.221	0.340	1.389
Median	2.250	4.864	2.220
Mean	2.335	5.205	2.189
Max	4.734	12.113	3.087

Impact of altitude on GRD is clearly visible in Fig. 4 with higher values of GRD in higher altitudes, though it is obvious that in higher altitudes additional factor influences the resulting GRD.

Inspecting the relationship between GRD and exposure time shows certain positive trend (Fig. 5). This can be translated as a better spatial resolution (lower GRD) is reached in better lighting conditions (shorter exposure time).

Also, relation between GRD and flight speed shows expected trend describing that with increasing speed the GRD is increasing (Fig. 6). In other words, spatial resolution gets worse with increasing speed.




Fig. 4. Plot of GSD and GRD related to altitude.




Fig. 5. Scatterplot of relation between GRD and exposure.


To describe GRD dependence on predictor variables (exposure, altitude and speed), linear regression methods were used.

First attempts led to models violating the basic linear model assumptions, namely the assumption of normally distributed residuals.

Therefore, different transformations of GRD variable were applied with the best results of square root transformation. This transformation used in stepwise modelling approach led to final linear model described in Table 4.


**Table 4.** Results of linear model describing the relationship of square root of GRD as a dependent variable of predictors: Altitude, Speed and Exposure.  $F(3,180) = 855.306$ ,  $p = < 0.001$ ,  $R^2 = 0.934$ , Adjusted  $R^2 = 0.933$ . All predictors are mean-centered and scaled by 1 s.d.

Variable	Estimate	Std. Error	t value	p value
(Intercept)	2.167	0.014	159.527	<0.001
Altitude	0.614	0.015	41.054	<0.001
Speed	0.115	0.015	7.474	<0.001
Exposure	0.066	0.014	4.561	<0.001




**Fig. 6.** Scatterplot of relation between GRD and speed.


Using Shapiro-Wilk normality test on residuals of this model resulted in  $p$ -value of 0.7285, therefore normal distribution of residuals could not be denied. Linear model is described in Fig. 7, 8 and 9. Histogram of residuals and other results indicate good fit of the model.



**Fig. 7.** Linear model – histogram of residuals.



**Fig. 8.** Linear model – Q–Q plot.



**Fig. 9.** Linear model – Scale – Location plot.

Further attempts on creating linear model with interactions between predictors led to only slightly better results in Adjusted  $R^2$  with high trade-offs in terms of increased complexity and lower explanatory value of the model.

#### 4. Discussion

Recently mensuration of various variables by means of UAS become more and more available to broad audience, interested in the output. Though they don't need any more to study principles of UAV flying (propellers, flying mechanisms etc.) which are sufficiently handled by computers, they still face challenges how and when acquire the imagery to get the best results. Influence of different conditions (lighting conditions, flight height and flight speed) on resulting spatial resolution was examined in this study.

Existing studies targeted on UAV imagery acquiring mission options deal usually with GSD in terms of spatial resolution. This study goes further and demonstrates easy procedure to estimate more realistic spatial resolution in form of GRD for particular UAV setup, thus increasing the predictability of acquired image quality and also increasing the accuracy and precision of the results. Our main question was to provide readers with information: which of the selectable flight parameters height, speed, light has the highest influence on final quality and which is lowest (potentially could be sacrificed in favor of the most important one).

Evaluation of presented linear model, apart from expected negative influence of altitude on spatial resolution, proved also negative influence of speed and positive influence of better lighting conditions. In other, more general words, results of this study confirm, that best spatial resolution of UAV imagery can be reached by performing flight missions in lower flight height, with lower flight speed and better conditions in terms of available light. These results are in line with expected outcomes, although the influence of lighting conditions seems to be rather minor.

Results show, that GRD was always higher than GSD as GRD/GSD ratio takes on values from 1.4 to 3.1 with mean value 2.2. Similar trend with higher GRD compared to GSD was published by Lee (Lee & Sung 2016) although the difference was much lower with GRD/GSD ratio between 1.2 and 1.4. Cameras used in quoted study (Lee & Sung 2016) were Canon (IXUS 127 HS) and Sony (NEX-5 N), both of them of better specification than camera used in this study.

Similar results were achieved by Dabrowski (Dabrowski et al. 2015). In this case GRD was examined as a linear function of altitude with GRD/GSD ratio approximately 2.6 and 2.5 for Sony (NEX-5) and miniMCA camera respectively.

GRD to GSD ratio of 1.3, 1.8 and 1.3 was reported in (Cramer & Zhang 2020), using images of Siemens star captured by DJI Phantom 4, DJI Phantom 4 RTK and Phase One iXM100-RS camera in flight altitudes 28, 25 and 47 respectively.

Resolving power derived by the means of Siemens star target on imagery obtained by Intergraph DMC digital large-format photogrammetric sensor carried on airplane led to 1.2 to 1.5 times higher results than GSD as concluded Honkavaara (Honkavaara et al. 2006a, b).

Worse spatial resolution was observed on images taken at higher horizontal flight speed. These results can be compared to much higher GRD to GSD ratio (10 to 15 times higher) of images obtained by S.O.D.A camera on SenseFly eBee Plus fixed wing UAV in (Stöcker et al. 2018). Quoted study does not state the values of UAV horizontal flying speed, but considering the fixed wing design of UAV in this case, higher speed might be one of the reasons for worse results of spatial resolution, same way as our study suggests. Results also indicate positive relation of spatial resolution to better lighting conditions. This is in line with Lim (Lim et al. 2018a), who reported different results of GRD based on lighting conditions. Using Sony A5100 camera carried on octocopter UAV, GRD was 1.1 to 2.3 (depending on the flight altitude) times higher than GSD in images taken on sunny conditions, whereas 1.6 to 3.7 times higher than GSD in images obtained at cloudy day.

Similar relationship to lighting conditions were reported in (Lim et al. 2018b). Images of Siemens star, captured by octocopter carried Sony A5100 in altitudes 20 to 80 meters, resulted in GRD 3–12 times higher than GSD in very cloudy day comparing to 1.2 to 3 times higher GRD than GSD in sunny or little cloudy day.

## 5. Conclusions

Our work focused on description of the first stage of exploring processes for the optimal ways to quantify characteristics of remote sensing data obtained by

common commercial UAV (in our case DJI Phantom 3 Professional UAV) in forestry. The main motivation was to provide the reader and potential practitioner of forest mensuration by the means of remote sensed data with information about the impact of different height, speed and possible light condition on the image quality. In general, the image quality is clearly linked to quality and accuracy of information obtained from such image by means of photogrammetry.

Spatial resolution of imagery is considered as one of the most important preconditions influential to any result of remote sensing application. Therefore, special care was given in this first stage to Ground resolved distance as an objective means to describe spatial resolution. Influence of different conditions in form of flight altitude, flight speed and lighting conditions on resulting spatial resolution was examined. Study proved, that spatial resolution is highly dependent on flight altitude with better resolution resulting from lower flight altitudes, less influential, but still highly significant proved flight speed. Comparing to previous two factors, lighting conditions, although still significant, are of the least influence. This can be translated as a positive message for the flexibility of use of UAV in forestry, as the most unpredictable characteristics of flight mission, lighting conditions as a result of the weather conditions, seems to be of rather low impact on resulting spatial resolution. Concluding knowledge both from previous studies and this work, UAVs can be recommended for forestry sector as a reliable device in terms of imagery data acquisition in forest stands and open areas.

## Acknowledgments

*This research was funded by Faculty of Forestry and Wood Sciences Prague. The authors would like to thank Radim Adolt (Forest Management Institute, Brandýs nad Labem) for his support in performing the statistical analyses.*

## References

- Cramer, M., 2013: The UAV@LGL BW Project – A NMCA Case Study. In: Fritsch, D. (ed.): Photogrammetric Week 2013. Wichmann/VDE Verlag, Belin & Offenbach, p. 165–179.
- Cramer, M., Zhang, S., 2020: Quality Assessment of High-Resolution UAV Imagery and Products. In: 40. Wissenschaftlich-Technische Jahrestagung der DGPF in Stuttgart, p. 33–46.
- Dabrowski, R., Jenerowicz, A., 2015: Portable Imagery Quality Assessment Test Field for UAV Sensors. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 40:117–122.

- Dabrowski, R., Orych, A., Jenerowicz, A., Walczykowski, P., 2015: Preliminary Results from the Portable Imagery Quality Assessment Test Field (PIQuAT) of UAV Imagery for Imagery Reconnaissance Purposes. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences – ISPRS Archives, 40:111–115.
- Harvey, P., 2016: ExifTool. Available in: <http://exiftool.org>.
- Honkavaara, E., Jaakkola, J., Markelin, L., Becker, S., 2006a: Evaluation of Resolving Power and MTF of DMC. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences – ISPRS Archives, 36:1–6.
- Honkavaara, E., Jaakkola, J., Markelin, L., Peltoniemi, J., Ahokas, E., Becker, S., 2006b: Complete Photogrammetric System Calibration and Evaluation in the Sjöckulla Test Field – Case Study With Dmc Abstract. In: Proceedings of EuroSDR Commission I and ISPRS Working Group 1/3 Workshop EuroCOW 2006, 6 p.
- Klouček, T., Komárek, J., Surový, P., Hrach, K., Janata, P., Vašíček, B., 2019: The Use of UAV Mounted Sensors for Precise Detection of Bark Beetle Infestation. *Remote Sensing*, 11:1–17.
- Lee, J., Sung, S., 2016: Evaluating Spatial Resolution for Quality Assurance of UAV Images. *Spatial Information Research*, 24:141–154.
- Lim, P. C., Kim, T., Na, S. Il, Lee, K. Do, Ahn, H. Y., et al., 2018a: Analysis of Uav Image Quality Using Edge Analysis. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences – ISPRS Archives, 42:425–32.
- Lim, P. C., Seo, J., Kim, T., 2018b: Extraction of UAV Image Sharpness Index Using Edge Target Analysis. *Korean Journal of Remote Sensing*, 34:905–23.
- Long, J. A., 2020: Jtools: Analysis and Presentation of Social Scientific Data. Available in: <https://cran.r-project.org/package=jtools>
- Meißner, H., Cramer, M., Reulke, R., 2018: Towards Standardized Evaluation of Image Quality for Airborne Camera Systems. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 42:295–300.
- Meißner, H., Cramer, M., Reulke, R., 2020: Evaluation of Structures and Methods for Resolution Determination of Remote Sensing Sensors. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11994 LNCS: 59–69.
- Orych, A., 2015: Review of Methods for Determining the Spatial Resolution of UAV Sensors. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives. 40:391–395.
- Pricope, N. G., Mapes, K. L., Woodward, K. D., Olsen, S. F., Britton Baxley, J., 2019: Multi-Sensor Assessment of the Effects of Varying Processing Parameters on Uas Product Accuracy and Quality. *Drones*, 3:1–17.
- R Core Team 2020: R: A Language and Environment for Statistical Computing. Available in: <https://www.r-project.org/>
- RStudio Team 2019: RStudio: Integrated Development Environment for R. Available in: <https://www.rstudio.com/>
- Schneider, C. A., Rasband, W. S., Eliceiri, K. W., 2012: NIH Image to ImageJ: 25 Years of Image Analysis. *Nature Methods*, 9:671–675.
- Stöcker, C., Koeva, M., Nex, F., 2018: Deliverable 4.2 Data Quality Assessment of UAV-Based Products for Land Tenure Recording. H2020 its4land 687828, 55 p.
- Wickham, H., 2016: *Ggplot2: Elegant Graphics for Data Analysis*. Springer-Verlag New York, 213 p.
- Wickham, H., Hester, J., 2020: *Readr: Read Rectangular Text Data*. Available in: <https://CRAN.R-project.org/package=readr>

**Příloha 2. Kubišta J.; Surový P. Forest structure from UAV: software type has more influence on Structure from Motion point cloud than flight conditions. 2022**

# Forest structure from UAV: software type has more influence on Structure from Motion point cloud than flight conditions.

Jaroslav Kubišta<sup>1,2,\*</sup>, Peter Surový<sup>1</sup>

<sup>1</sup> Faculty of Forestry and Wood Sciences, Czech University of Life Sciences, Prague, Kamýčká 129, 165 00 Praha, Czech Republic

<sup>2</sup> Forest Management Institute Brandýs nad Labem, Czech Republic

\* Correspondence: kubista.jaroslav@uhul.cz

**Abstract:** Information about individual tree positions and heights help inform managers about forest structure, all of which plays a crucial role for forest inventory and management decisions. Increasing affordability of unmanned aerial vehicles (UAV) and the relevant processing software for UAV imagery data has improved the availability of on-demand monitoring of many environmental values and it widens the diversity of the potential user groups. Based on dense point clouds from various flight mission images obtained by the UAV DJI Phantom 3 Professional, we compared the point clouds reconstructed by two major software products, WebODM (freeware and open-source) and Agisoft Metashape (commercial). Our aim was to compare the quality of the point clouds themselves and the metrics available from these clouds as reconstructed by each program. For reference data we used laser scans from an unmanned aerial system, which included a Riegl VUX-1 scanner mounted on a RiCOPTER vehicle. We were able to reconstruct dense point clouds with an average accuracy of 0.31 m (standard deviation = 0.36 m); accuracy was defined as the cloud-to-cloud distance based on the reference point cloud. This accuracy was observed to significantly decrease with flight altitude, and we found a significant difference between the software products used for the point cloud reconstructions (WebODM had greater accuracy). Light conditions during the flight missions did not appear to have a significant influence on point cloud accuracy. We demonstrated that a small, hobbyist grade UAV paired with an open-source software, WebODM, can serve as an affordable solution for forest monitoring.

**Citation:** Kubišta, J.; Surový, P. Forest structure from UAV: software type has more influence than flight conditions. *Forests* **2021**, *12*, x. <https://doi.org/10.3390/xxxxx>

Academic Editor: Firstname Last-name

Received: date

Accepted: date

Published: date

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2021 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

**Keywords:** UAV; point cloud; forest structure; OpenDroneMap; WebODM

## 1. Introduction

Growing demand for wide portfolio of timely and accurate information on forests leads to increase in costs and thus stimulates efforts in seeking innovative methods and techniques of forest monitoring including remote sensing [1]. Apart from thriving development in laser scanning, which brings unprecedented detail to the forest monitoring [2][3], new photogrammetry method Structure from Motion (SfM) dramatically changed the extent of cameras and their carriers suitable for highly cost-effective acquisition of combined 3D and spectral remote sensing data with wide application in physical geography [4] and monitoring of forests [5].

Unmanned aerial vehicles (UAV) are becoming more and more affordable. Currently user-friendly UAVs, able to obtain RGB imagery are widely available [6]. Also, software equipment necessary to process imagery data into point clouds or orthophotos using SfM method can easily be found with a wide portfolio of options, from paid cloud-based solutions, such as DroneDeploy [7] or Pix4D [8], through commercial software, of which we have to mention at least Agisoft Metashape [9], to an open-source software such as the command line toolkit OpenDroneMap [10] with web interface called WebODM [11]. All



these developments lead to widening of the group of interested persons ready to enhance their forest survey with UAV remote sensing methods.

Still, the qualitative parameters of expected SfM outputs and their dependence on different conditions and algorithms used are not sufficiently described. Lack of acquisition and processing protocols guaranteeing certain quality of SfM outputs independent on forest type or phenology stage is identified as one of the crucial problems SfM needs to deal with [5][12].

Statistically significant influence of flight altitude, flight speed and light conditions on the spatial resolution of UAV imagery was confirmed [13]. This paper aims to explore the impact of same conditions (flight altitude, flight speed and light conditions) on the quality of photogrammetry point clouds derived from UAV imagery.

As previous studies [14][15][16] revealed significant differences in the results of different softwares used for SfM point cloud reconstruction, the quality of point clouds generated in two different softwares (Agisoft Metashape and WebODM) was compared, to answer the question whether open-source software can be competitive to commercial one.

Photogrammetric point cloud representing the surface of forest stand can serve as the means for description of the current state of the forest, reflecting for example changes induced by harvest but also changes in crowns induced by other factors such a wind or snow damage.

Different studies have proved that airborne laser scanning (ALS) or Unmanned aerial Laser Scanning (ULS) based point clouds are reaching similar or even better accuracy in the denomination of tree heights than usual field measurement approaches [17][3]. This places ALS and ULS point clouds as a quality benchmark for computer reconstruction of forest sites. Therefore, we decided to use the ULS point cloud as a reference for the comparison of photogrammetry point clouds.

## 2. Materials and Methods

Two study sites were established in different mixed forest stands to cover the most common tree species in the Czechia, which are Norway spruce (*Picea abies* 43.0%), European beech (*Fagus sylvatica* 10.1%), Scots pine (*Pinus sylvestris* 9.8%) and oaks (*Quercus robur*, *Quercus petraea* 7.8%) [18].

Both sites are situated in the Central Bohemian region. First site, called Skorkov Figure 1(a) is located on the mostly flat terrain stand with species composition predominantly of Scots pine and Common oak. Different age classes are present in a rather rectangular composition, typical for pine management in this region. The second site, called Skalice Figure 1(b), was established in a more spatially diverse forest stand with prevailing Norway spruce supplemented by European beech on slope terrain.

The basic characteristics of both sites are given in Table 1 **Chyba! Nenalezen zdroj odkazů.**


**Table 1.** Study sites parameters

Site	Skorkov	Skalice
<b>WGS 84 (center)</b>	Lat: 50.2143906N, Lon: 14.7160739E	Lat:49.9141571N, Lon: 14.8710025E
<b>Area</b>	9.309 ha	3.629 ha
<b>Terrain</b>	flat	slope with 20% inclination
<b>Altitude</b>	188-190m AMSL	399-431m AMSL
<b>Tree species</b>	Scots pine ( <i>Pinus sylvestris</i> ), Common oak ( <i>Quercus robur</i> )	Norway spruce ( <i>Picea abies</i> ), European beech ( <i>Fagus sylvatica</i> )

45  
4647  
4849  
5051  
5253  
5455  
5657  
5859  
6061  
6263  
6465  
6667  
6869  
7071  
7273  
7475  
7677  
7879  
8081  
82

83

84



85

**Figure 1.** Study sites (a) Skorkov; (b) Skalice

86

**Images acquisition.** DJI Phantom 3 Professional as an example of a widely available, low-cost, user-friendly UAV was used to acquire images for Digital Aerial Photogrammetry (DAP) point clouds reconstruction. The parameters of the DJI FC300X camera carried by this UAV are specified in Table 2 [19].

87

88

89

90

**Table 2.** DJI FC300X camera specification

91

Sensor	Sony EXMOR 1/2.3" CMOS Effective pixels: 12.4 M
Lens	20 mm (35 mm format equivalent) f/2.8 focus at $\infty$
ISO Range	100-1600 (photo)
Electronic Shutter Speed	8 - 1/8000 s
Image Size	4000×3000

92

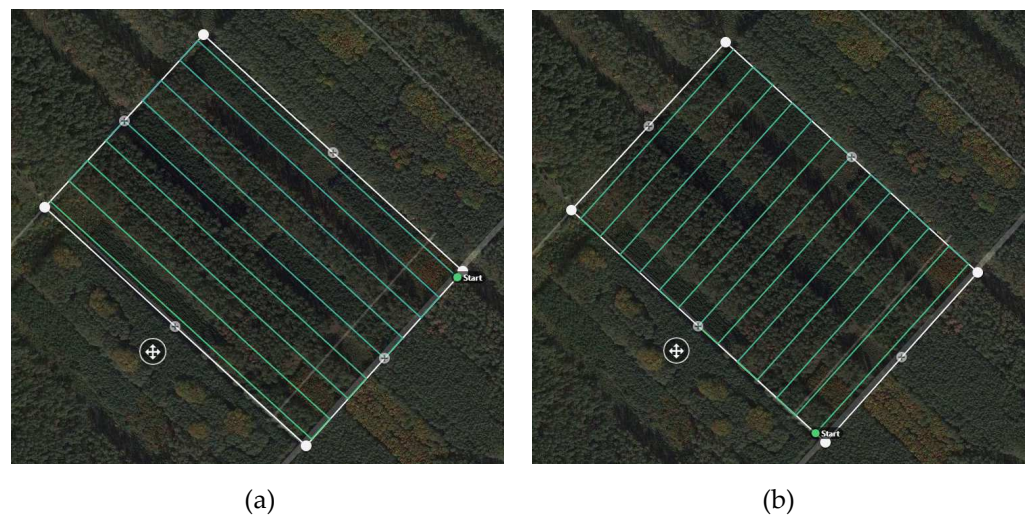
In total 26 standard flight missions were performed during 7 days at 4 flight altitude levels with the aim of covering different light conditions. In each case, the flight mission was planned with both front and side overlap set to 75%. The flight trajectory was oriented parallel to the longer side of the study site Figure 2(a).

93

94

95

96



**Figure 2.** Flight trajectory in standard (a) and special (b) missions

97

Also, 3 special missions were performed with the aim to obtain images originating from more diverse angles to perform optimized camera calibration in WebODM. In this case two missions (flight altitude 100 and 150 meters) were flown with path oriented in 90 degrees to standard missions Figure 2(b) and one (flight altitude 100 meters) with camera tilt of 75 degrees to get non-nadir-oriented images. An overview of the flight days and missions is in Table 3.

98

99

100

101

102

103

Looking for suitable mission planning software, DroneDeploy [2] was chosen as it allows for import of the study site borders polygon shapefile. This feature greatly improves comparability of repeated missions. All missions were planned and carried out using DroneDeploy except for one of the special missions where a 75-degree tilt of the camera was required. As DroneDeploy did not allow for such setting, Pix4DCapture app [3] was used in this case.

104

105

106

107

108

109

**Table 3.** Flight days details

110

Date	Start	End	Site	Missions	Flight altitudes (m) *)				Weather
					75	100	125	150	
17.06.2020	12:54	14:01	Skorkov	2		a		a	overcast, high clouds, light wind
20.08.2020	6:35	7:18	Skorkov	4	a	a	a	a	clear sky, calm
21.08.2020	10:31	11:14	Skorkov	4	a	a	a	a	clear sky, very light wind
03.09.2020	11:21	12:14	Skalice	4	a	a	a	a	partly cloudy, variable wind (thermals)
09.09.2020	11:38	12:14	Skalice	4	a	a	a	a	clear sky, very light wind
19.10.2020	12:45	13:51	Skorkov	4+3	a	abt	a	ab	high breaking clouds, light wind
11.11.2020	11:35	12:10	Skalice	4	a	a	a	a	overcast, high clouds, calm

\*) a: parallel to the longer side trajectory, b: parallel to the shorter side trajectory, t: parallel to the longer side trajectory, camera tilt 75 degrees.

111

112

**ULS data acquisition.** For each study site, ULS point cloud was also acquired using UAV VUX-SYS (RIEGL Laser Measurement System GmbH, Horn, Austria) setup for UAV-borne data acquisition consisting of the UAV RiCOPTER, the VUX-1UAV laser scanner, and the AP-20 inertial measurement unit (IMU) [20].

113

114

115

116

The results of this dataset were later on used as a reference for the evaluation of DAP point clouds generated from imagery obtained by UAV DJI Phantom 3 Professional.

In all UAV flights, respective national requirements as stated in [21] valid at the time of flight were complied, namely maximum flight height below 300 meters, visual line of sight, airspace restrictions and minimal distance from people and buildings.

Further images and resulting point cloud processing workflow is described in Figure 3 and following paragraphs.

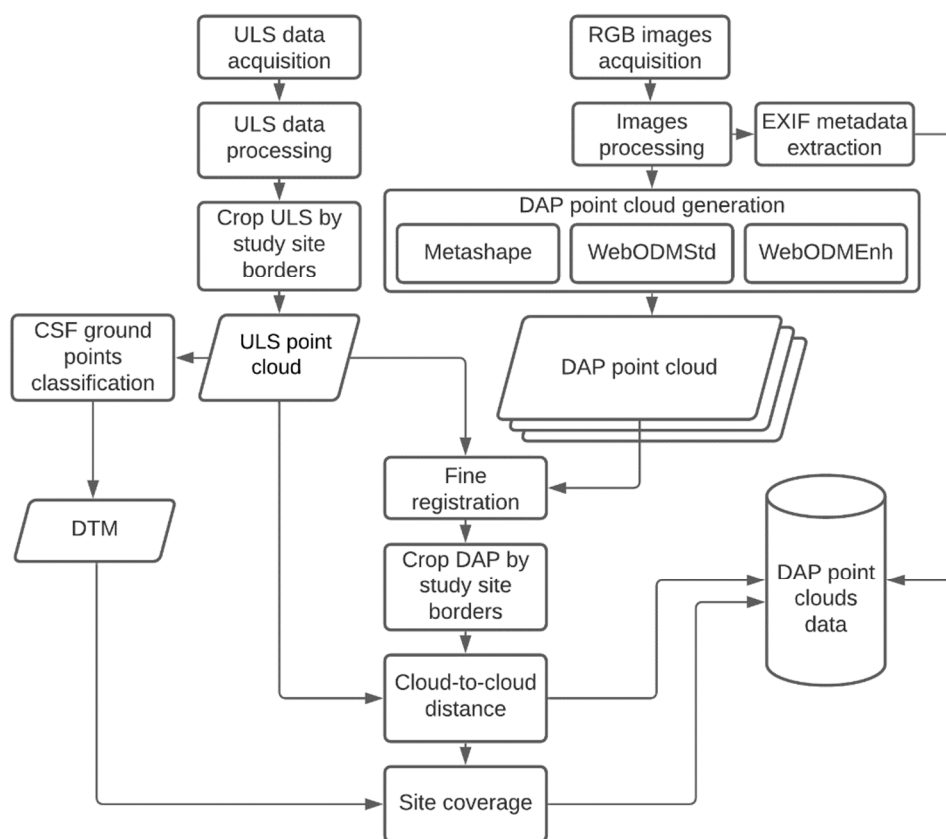


Figure 3. DAP point cloud processing workflow chart

**Images processing.** EXIF metadata of  $x,y,z$  axis speed, aperture and exposure time were extracted from all images using Exiftool utility [22]. Speed was calculated on the basis of the  $x,y,z$  axis speed vectors. Aperture was set to constant value (maximum aperture was used that equals to 2.0 in case of this camera) in camera settings prior to each flight. Still EXIF metadata were used to confirm (successfully) that all images are of the same aperture value. Therefore, exposure time could be used as a descriptor of light conditions. For each mission imagery set, an average speed and exposure time was calculated.

Characteristics of the set of resulting images set are summarized in Table 4.

Table 4. Standard missions image sets characteristics

Characteristic	Skalice, n = 12 <sup>1</sup>	Skorkov, n = 14 <sup>1</sup>
Images number	155 (95 to 248)	162 (98 to 252)
Flight Altitude		
75	3 (25%)	3 (21%)
100	3 (25%)	4 (29%)
125	3 (25%)	3 (21%)
150	3 (25%)	4 (29%)
Exposure time	0.017 (0.004 to 0.040)	0.015 (0.004 to 0.067)

Characteristic	Skalice, n = 12 <sup>1</sup>	Skorkov, n = 14 <sup>1</sup>
Flight speed	9.04 (5.70 to 11.70)	9.46 (7.50 to 11.80)

<sup>1</sup>n (%), Mean (Min to Max)

**DAP point clouds generation.** Image sets of each mission were processed by Structure from motion procedure to dense point clouds. Two softwares were used: Agisoft Metashape as an example of commercial software successfully used for different purposes such as coastal area monitoring [23], historical site survey [14], agriculture [24] and forest monitoring [25][16][26]. The other compared software was WebODM as an open-source alternative used also in a various field such as glacier monitoring [27], or land cover change detection [28].

Results of this procedure can be highly influenced by parameters settings. On the other hand, settings parameters of both softwares are not easily comparable, which makes the task of similar settings very difficult. Therefore, different approach was chosen with default settings used in both softwares. This approach allows for comparison of results based on the default setup of the software, which is usually the starting point for further fine-tuning.

To further explore possibilities of WebODM, recommended procedure of camera calibration process [29] was explored. For this reason, three special flight missions were performed, to gain more images from various flight altitudes and angles, including also non-nadir orientation (75 degrees camera tilt) as recommended in relevant chapter of WebODM user guide [29]. In this case all image sets from one flight day including special flight missions – in total 7 flight missions (21,22,22cross,22tilt,23,24 and 24cross) with 1176 images were used to produce single point cloud. Results of camera calibration process gained during this point cloud generation were saved and later on used in all standard mission image sets procedure.

In total three DAP point clouds were produced from each standard mission image set. One in Agisoft Metashape with default settings (denoted as Metashape), second in WebODM with default settings (WebODMstd) and third using WebODM with optimized camera calibration parameters (WebODMenh).

ULS Point clouds for both sites were prepared from the raw data acquired by UAV VUX-SYS, using smoothed best estimate of trajectory (SBET) based on reference station (RS) post-processing kinematics (PPK) with the virtual BS from Trimble VRS Now, prepared in the environment of RiPROCESS with RiPRECISION module [20]. Point cloud classification was carried out in the same environment.

**Point clouds comparison.** To compare the DAP point clouds quality and accuracy, CloudCompare [30] software was used.

First ULS point clouds were prepared for both study sites by cropping (segmenting) the point cloud with the polyline representing the boundaries of study site.

Comparison pipeline of single DAP point cloud was performed with following steps:

1. Register DAP point cloud (Tool/Registration/Fine Registration (ICP)) using the ULS point cloud as a reference.
2. Crop (segment) DAP point cloud with the polyline representing the borders of study site.
3. As a means to describe spatial accuracy of DAP point cloud, point-to-point comparison of DAP and ULS point cloud (Tools/Distances/Cloud distances) was performed. Results of this comparison were saved in a new scalar field of DAP point cloud.
4. Export statistics (mean and standard deviation) of this new scalar field (cloud-to-cloud distance) as well as the total number of points in resulting cropped DAP point cloud to database. As study sites are not of the same size it is not possible to compare directly number of points. Rather relative metrics points density (number of points per square meter) was used. This was simply calculated as the number of the points divided by the area of study site.

As the density of DAP point clouds in some cases varied significantly throughout the entire study site, following steps were done to cover this feature of DAP point clouds.

1. First subset of points representing ground was identified in ULS point cloud using the Cloth Simulation Filter [31] plugin of CloudCompare.
2. This subset was later on used as a ground reference in calculation of DAP point cloud site coverage expressed here by the amount of ULS ground points with representing points in DAP point cloud (Tools/Volume/Compute 2.5D volume in CloudCompare)

All analyses were carried out in R-Studio version 1.4.1103 [32] with R version 4.0.3 [33] using following libraries: JTools [34], Readr [35], GGplot2 [36], gtsummary [37].

### 3. Results

In total 78 point clouds were computed from 26 standard mission imagery sets. Summary characteristics are in Table 5.

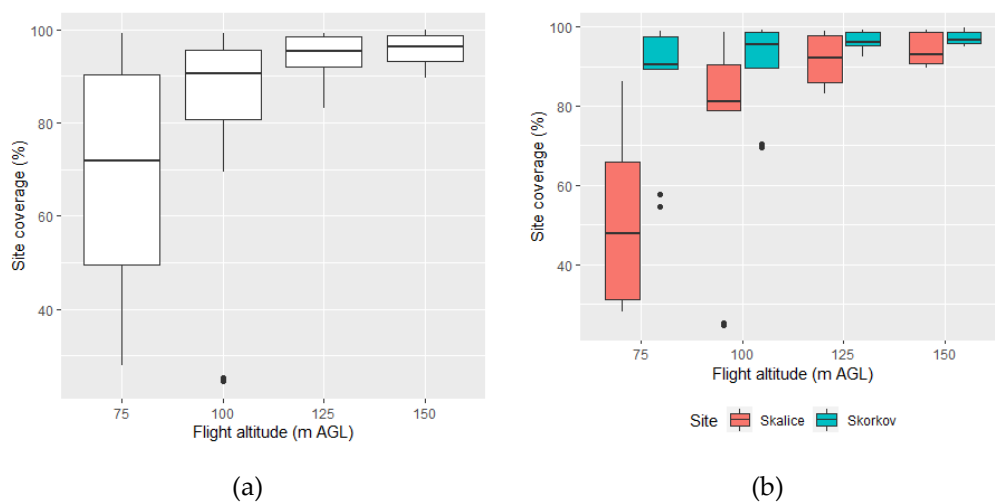
**Table 5.** DAP point clouds characteristics

Variable	Metashape <sup>1</sup>	WebODMenh <sup>1</sup>	WebODMstd <sup>1</sup>
Points density (points/m <sup>2</sup> )	79.61 (30.43 to 181.23)	52.20 (9.90 to 103.04)	51.45 (9.52 to 101.92)
Site coverage (%)	93.94 (31.00 to 99.80)	81.58 (25.30 to 96.70)	81.67 (24.50 to 96.70)
Cloud-to-cloud distance (m)	0.40 (0.26 to 0.60)	0.25 (0.13 to 0.65)	0.31 (0.18 to 0.62)


<sup>1</sup>Values in the table: Mean (Min to Max)

#### 3.1 Site coverage

Lower flight altitude resulted in lower site coverage (larger proportion of study site which is not covered by DAP point cloud) as seen on Figure 4Chyba! Nenalezen zdroj odkazů.(a). This can be attributed to worse performance in reconstruction of point clouds from imagery obtained at lower flight altitudes where distance to actual tree tops is simply too small. With trees height around 30m, flight altitude 75m above ground means distance between camera and surface around 45m. This hypothesis is further supported by worse results in site Skalice Figure 4Chyba! Nenalezen zdroj odkazů.(b) which was located on the slope terrain, with the take-off point in the bottom part of slope. The flight altitude controlled by DroneDeploy mission planning app was kept constant relatively to take-off point. This means that the overlap of images at the top of slope was in case of Skalice study site lower than planned which led to worse performance in point cloud reconstruction at these parts of study site, especially in lower flight altitudes. This trend was visually confirmed, as seen in Figure 5Chyba! Nenalezen zdroj odkazů..



**Figure 4.** Site coverage of DAP point clouds reconstructed from images obtained at different flight altitudes (a) and at different study sites (b). Figure includes all 78 point clouds.



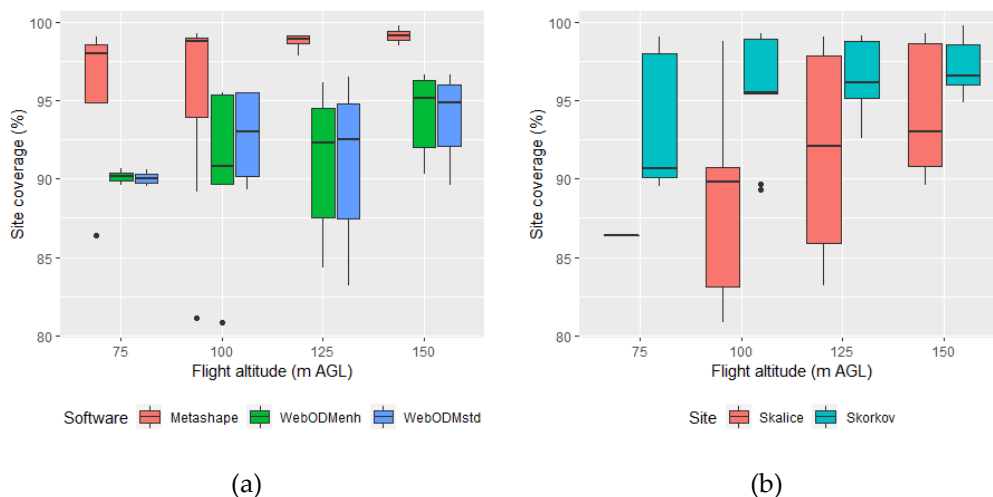
**Figure 5.** Coverage of study site ground (grey) by DAP point cloud (green) from 75m (a) and 150m (b) missions. Sideview with Flight altitude level 75m(blue) and 150m(red). 215  
216

To allow for reasonable comparison of results, only point clouds covering more than 80% of study site ground were included in further evaluation procedure. This limited the dataset to 63 point clouds as seen in Table 6 **Chyba! Nenalezen zdroj odkazů.** 217  
218  
219

**Table 6.** DAP point clouds selection (site coverage>80%) characteristics 220

Variable	Metashape, n = 24 <sup>1</sup>	WebODMenh, n = 20 <sup>1</sup>	WebODMstd, n = 19 <sup>1</sup>
Points density (points/m <sup>2</sup> )	81.35 (35.02 to 181.23)	57.74 (32.15 to 103.04)	57.10 (31.42 to 101.92)
Site coverage (%)	97.24 (81.10 to 99.80)	91.89 (80.80 to 96.70)	92.34 (83.20 to 96.70)
Cloud-to-cloud distance(m)	0.41 (0.26 to 0.60)	0.22 (0.14 to 0.30)	0.30 (0.19 to 0.62)

<sup>1</sup> n: number of point clouds; Values in the table: Mean (Min to Max) 221



**Figure 6.** Site coverage of DAP point clouds reconstructed by different software (a) from images obtained at different study sites (b) and at different flight altitudes. Figure includes only point clouds with coverage > 80% (63 point clouds) 222  
223  
224

To further evaluate how is the site coverage influenced by different parameters of imagery sets and point clouds reconstruction, generalized linear model (GLM) with gamma distribution was built iteratively, considering following parameters of individual DAP point clouds: 225  
226  
227  
228

- Flight altitude; 229
- Flight speed – mean value of flight speed extracted from individual images; 230

- Exposure time – mean value of exposure extracted from individual images; 231
- Software(settings) used for point clouds reconstruction; 232
- Site. 233

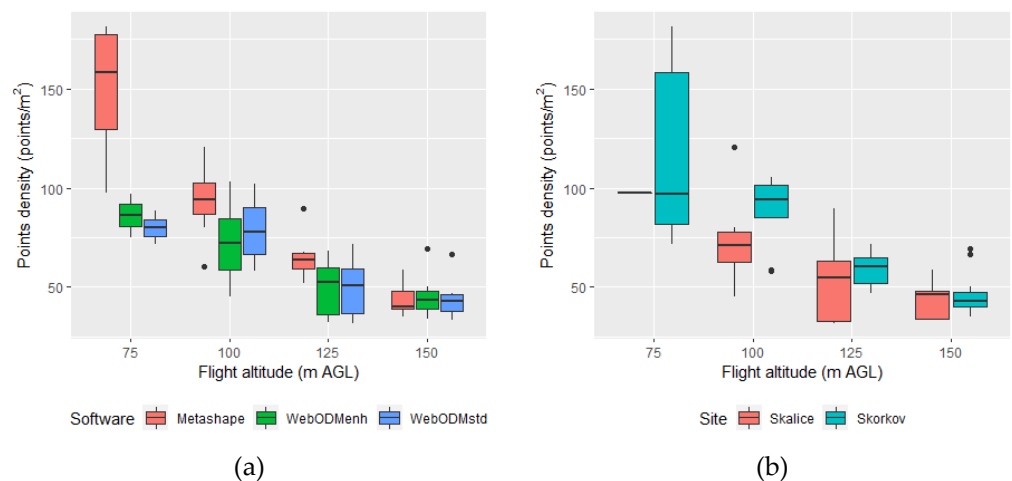
Out of these five variables, flight altitude, flight speed, software and site were found as significant explanatory variables. Exposure time did not prove as significant explanatory variable for site coverage. For selected model details see Table A1, Figure A1 and Figure A2 in Appendix A. 234  
235  
236  
237

### 3.2 Points density 238

Figure 7 show expected decreasing trend of points density with increasing flight altitude which can be logically explained by lower spatial resolution of images obtained in higher altitudes. 239  
240  
241

Results of Metashape are of higher points density than WebODM. Both settings versions of WebODM seems to perform rather similar Figure 7(a). 242  
243

Point clouds from study site Skalice representing slope terrain seems to reach lower points density than on flat study site Skorkov Figure 7(b). 244  
245  
246



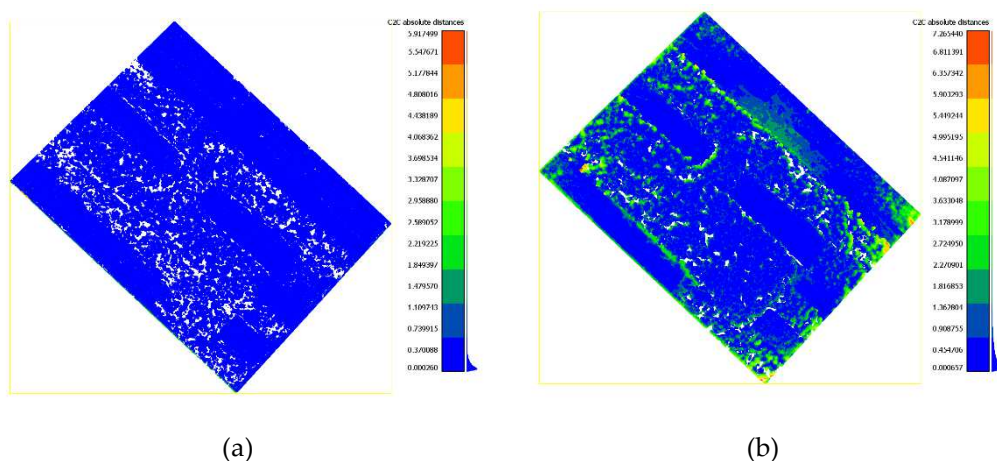
**Figure 7.** Points density of DAP point clouds reconstructed by different software (a) from images obtained at different study sites (b) and at different flight altitudes. Figure includes only point clouds with coverage > 80% (63 point clouds) 247  
248  
249

Generalized linear model was iteratively fitted, using same five parameters as in previous part, to describe influence on points density. The best performing model was the one considering flight altitude, flight speed, software and site parameters. All of these were confirmed as significant explanatory variable. Exposure time was not confirmed as significantly influencing points density. For selected model details see Appendix A Table A2, Figure A3 and Figure A4. 250  
251  
252  
253  
254  
255

### 3.3 Spatial precision 256

The mean value of cloud-to-cloud distance to reference ULS point cloud computed for each of 63 selected DAP point clouds reached values between 0.13 Figure 8(a) and 0.61 meters Figure 8(b), mean value was 0.31 meters. 257  
258  
259

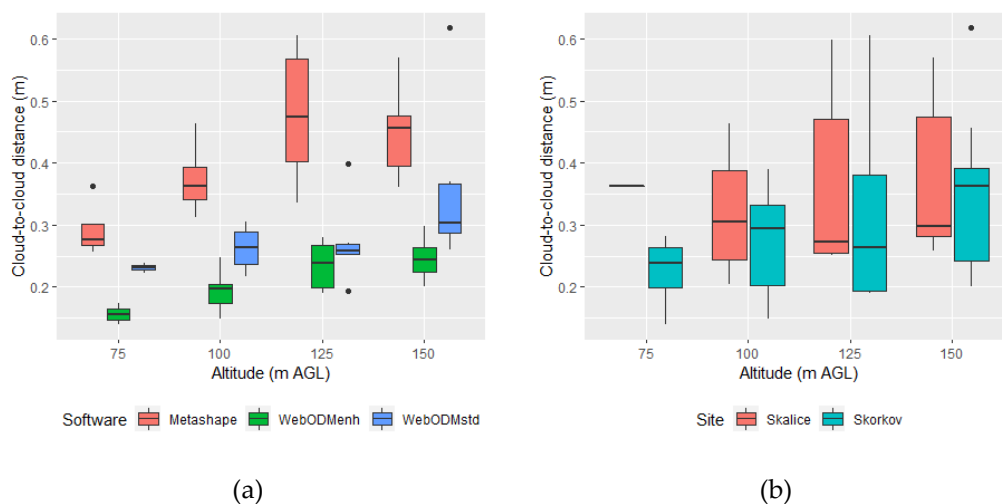




**Figure 8.** Examples of mean Cloud-to-cloud distance of best (a) 0.13m and worse (b) 0.61m point clouds within the limited data set of 63 point clouds. 260  
261

Mean cloud-to-cloud distance shows expected logical trend of worse results with increasing flight altitude. 262  
263

Considering the mean cloud-to-cloud distance, the best performing are point clouds reconstructed by WebODM with optimized camera calibration parameters (WebODM-Menh). WebODM with default settings (WebODMstd) generated point clouds show slightly worse results, but still perform better than Metashape Figure 9(a). As for the study sites, DAP point clouds from Skalice exhibits slightly worse results Figure 9(b). 264  
265  
266  
267  
268



**Figure 9.** Mean cloud-to-cloud distance related to flight altitude, software used for point cloud reconstruction (a) and study site (b). Figure includes only point clouds with coverage > 80% (63 point clouds) 270  
271  
272

To further evaluate how is the cloud-to-cloud distance influenced by different parameters of imagery sets and point clouds reconstruction, generalized linear model with gamma distribution was built iteratively, considering same five parameters of individual DAP point clouds as in previous cases. 273  
274  
275  
276

The best performing model was the one considering only flight altitude, software and site parameters. All of these were significant. For selected model details see Table A3 and Figure A5 in Appendix AChyba! Nenalezen zdroj odkazů.. Flight altitude, software and site effects on the expected accuracy of point cloud represented by predicted mean cloud-to-cloud distance is described in Figure A6 Appendix AChyba! Nenalezen zdroj odkazů.. 277  
278  
279  
280  
281

In none of iteratively fitted models did parameters exposure time or flight speed result as statistically significant.

#### 4. Discussion

Flight altitude, flight speed and light conditions described through image exposure time were found as significantly influencing spatial resolution of UAV obtained images [13].

In this paper we evaluated influence of these parameters on the quality of DAP point cloud reconstructed through SfM process. Only the point clouds itself were evaluated. Whether varying point cloud parameters, such as different points density or spatial precision impacts significantly forest characteristics derived from this point cloud needs to be further examined. For example, increasing points density of ALS point cloud was proved to affect the reliability of Lorey's height, basal area, volume and stem density estimates of Norway spruce dominated forest stand with high reliability even at points density of 2 points per m<sup>2</sup> [38]. On the other hand as described in [39] points density above certain threshold was not further affecting results of individual tree detection in ALS point cloud.

Flight altitude was confirmed as significantly influencing the quality of resulting DAP point clouds in terms of points density (decreasing with increasing flight altitude), coverage of study site (improving with increasing flight altitude) and its spatial accuracy (worse accuracy with increasing flight altitude). Similar results regarding worse spatial accuracy with higher flight altitudes reported [40][41].

The contrary influence on particular characteristics (cloud-to-cloud distance and coverage) underlines the problem of finding the optimal flight altitude. Lower flight altitudes bring images with higher spatial resolution which should support the keypoints identification and lead to better results of SfM reconstruction. On the other hand smaller part of surface captured by single image in lower flight altitude can lead to lower number of features resulting in worse image matching, which can only partially be accounted for by increasing the overlap of images [5].

Flight speed was found as significantly influencing points density and site coverage, both decreasing with increasing flight speed. This can be attributed to lower spatial resolution of images obtained at higher speed as concluded in [13], which might logically result in lower amount of keypoints identified in individual images during SfM procedure leading to lower points density of final dense point cloud as well as lower coverage.

Exposure time was not confirmed as significant predictor for any of observed DAP point cloud quality parameters (points density, site coverage and spatial accuracy). This is contradictory to findings related to spatial resolution being affected by lighting conditions [13], but can be explained as the magnitude of lighting conditions effect was the smallest comparing to flight altitude and flight speed in quoted study.

Even the results of point clouds reconstructed from 150m flight altitude imagery sets seems to be sufficient for use in general forestry practice as the worse achieved average cloud-to-cloud distance was 0.64 meters. Compared to typical field survey tree height measurement methods (indirect laser rangefinder supported tangent measurement), this is still a competitive result. For example, Andersen et al. [3] were able to reach the accuracy of the field tree height measurement  $-0.27 \pm 0.27$  m (mean  $\pm$  SD) using a hand-held laser rangefinder Impulse 100. Each tree was a subject to three height measurements with an average as a result. This is quite beyond general practice, so usual accuracy of field tree height measurement can be expected worse. Other researchers have reported similar values for the standard deviation of the measurement of field tree height, such as 0.5m [42]. Worth noting is also the fact that field measurements of tree height are subject to random errors as reported by Larjavaara and Muller-Landau [43]

As for the software comparison, Metashape in default settings was clearly able to reconstruct slightly denser point clouds than WebODM (in both settings) especially in

lower flight altitudes. This fact also influences the site coverage of reconstructed point clouds, which in the case of Metashape was reaching better results than WebODM.

On the other hand, WebODM outperformed Metashape in the accuracy of reconstructed DAP point clouds compared to reference ULS point cloud. Point clouds reconstructed in Metashape were much more prone to noise artifacts.

Comparison of results from both softwares showed, that WebODM as an open-source alternative was competitive to commercial products represented here by Metashape. Usability of WebODM was confirmed also by other studies, such as for example by Groos et al [27] or White et al [28], whereas unsuccessful trials [44] can be attributed to an early stage of ODM package when survey was performed.

This paper confirmed that WebODM point cloud reconstruction accuracy can be significantly improved by using the optimized camera calibration parameters resulting from processing of images from various flight altitudes and angles [29].

Results also confirmed significant influence of study site on the accuracy of DAP point cloud. The most likely hypothesis for this might be the terrain profile, as study site located on flat terrain performed significantly better than study site with slope terrain. Still, although significant, the influence of site variable seems to be rather weak, which can be also translated as good applicability of described method for variable conditions in terms of terrain, species composition or spatial structure of forest stand.

One of the outcomes of this study would also be a recommendation to use mission planning software capable of keeping constant flight altitude above ground throughout the study site, not only constant altitude above the take-off point, as was the case with DroneDeploy mission planning app used in this study. This as a result complicated reconstruction of point clouds in more diverse terrain on study site Skalice, as part of the site seems to be simply too close to UAV camera in lower flight altitudes for successful tie points identification.

## 5. Conclusions

Even though best points density can be reached by use of imagery obtained on lower flight altitude, short distance between canopy surface and camera can highly influence ability to reconstruct successfully dense point cloud which can lead to incomplete coverage of study site. Using higher flight altitudes can be beneficial in terms of the area covered by single flight with still reasonable accuracy of resulting point cloud.

As the light conditions did not prove to be significantly influencing quality parameters of resulting DAP point cloud, we conclude, that when necessary, even (reasonably) worse light conditions allows for images acquisition usable for forest monitoring.

Mission planning software capable of keeping constant altitude above ground should be preferred to minimize problems with tie points identification resulting in partial point cloud coverage problems.

Open-source software WebODM was proven as a competitive to commercial Agisoft with same or even better accuracy of resulting point clouds. Using affordable UAV DJI Phantom Professional and WebODM, DAP point clouds representing real forest stand can be obtained with sufficient accuracy. This further widens the possibilities to engage in UAV surveys.

**Author Contributions:** Conceptualization, J.K. and P.S.; methodology, J.K.; software, J.K.; validation, J.K., P.S.; formal analysis, J.K., P.S.; investigation, J.K.; resources, J.K.; data curation, J.K.; writing—original draft preparation, J.K.; writing—review and editing, J.K., P.S.; visualization, J.K.; supervision, P.S.; project administration, J.K.; funding acquisition, P.S. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research received no external funding.

**Conflicts of Interest:** The authors declare no conflict of interest.

Appendix A

385

**Table A1.** Generalized linear model of site coverage variable explained by selected parameters of DAP point clouds. (Null deviance: 0.177697 on 62 degrees of freedom, Residual deviance: 0.063599 on 57 degrees of freedom)

386

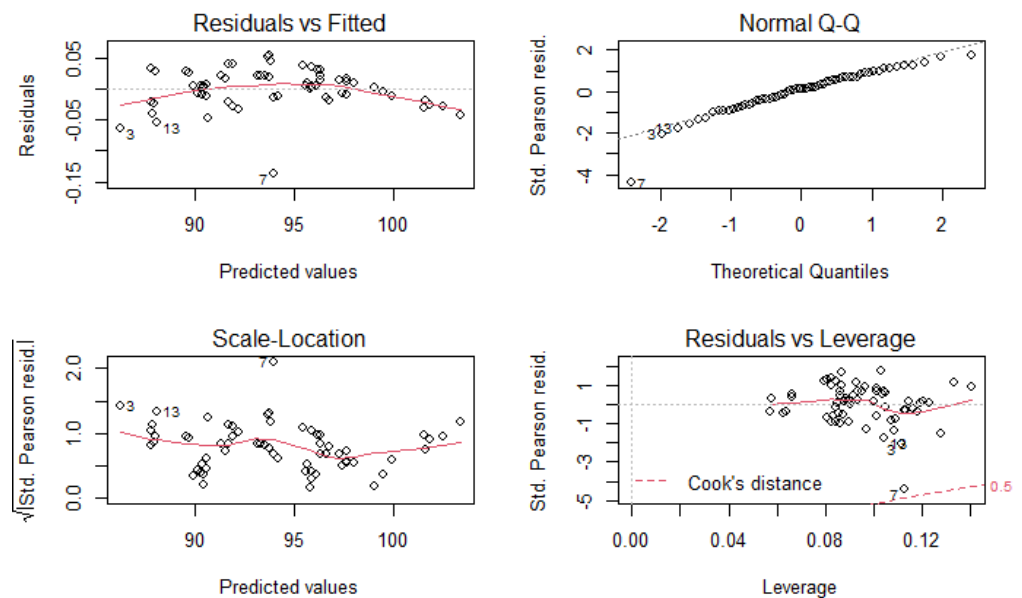
387

388

Characteristic	Beta	95% CI <sup>1</sup>	p-value
(Intercept)	88.68	83.41, 93.98	<0.001
AltitudePlan	0.120	0.069, 0.172	<0.001
SW			
Metashape	—	—	
WebODMenh	-5.937	-7.785, -4.087	<0.001
WebODMstd	-5.750	-7.634, -3.863	<0.001
Site			
Skalice	—	—	
Skorkov	5.739	4.148, 7.325	<0.001
SpeedDron	-0.924	-1.804, -0.049	0.043

<sup>1</sup>CI = Confidence Interval

389

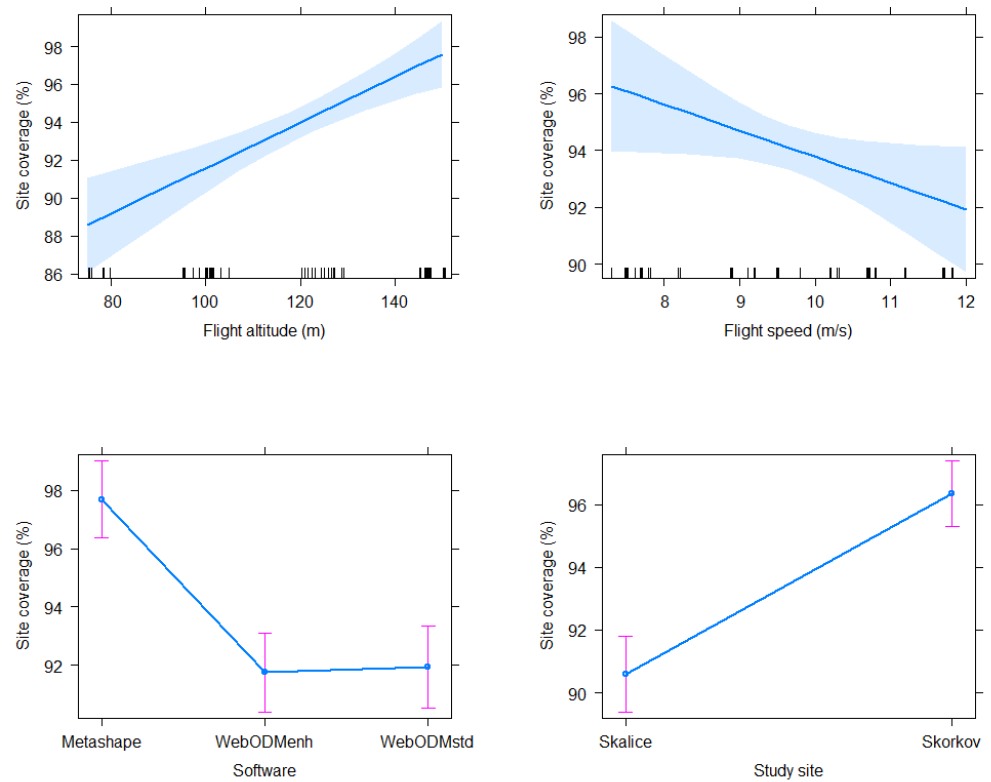


390

**Figure A1.** Diagnostic plots of generalized linear model describing site coverage as a variable dependent on flight altitude, flight speed, software and site explanatory variables.

391

392



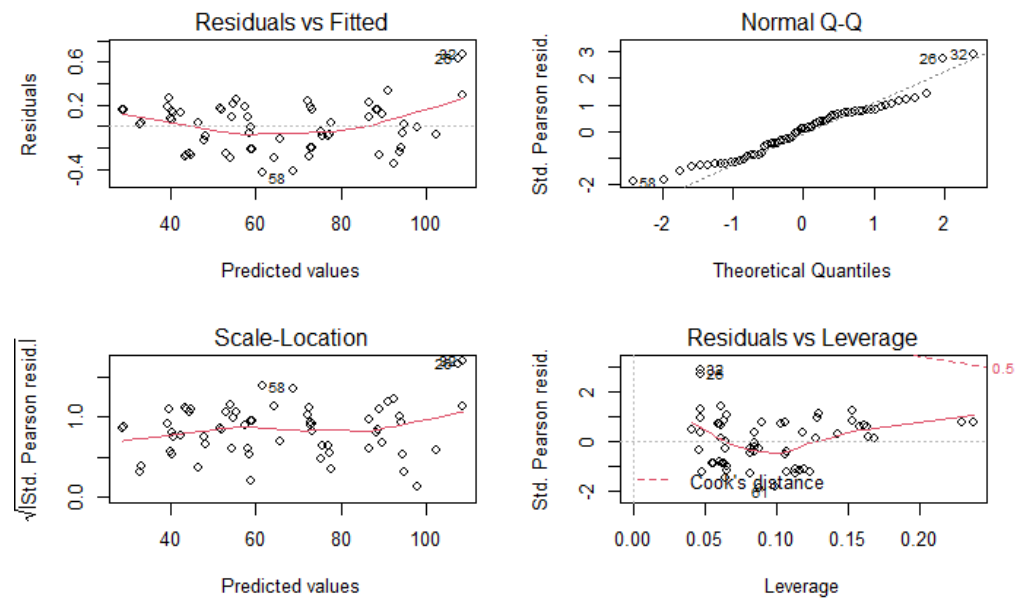
**Figure A2.** Effects of different parameters on GLM- predicted site coverage of DAP point cloud. 393

**Table A2.** Generalized linear model of points density variable explained by selected parameters of DAP point clouds. (Null deviance: 11.854 on 62 degrees of freedom, Residual deviance: 3.267 on 57 degrees of freedom) 394  
395  
396

Characteristic	Beta	95% CI <sup>1</sup>	p-value
(Intercept)	180.3	153.7, 208.2	<0.001
AltitudePlan	-0.311	-0.567, -0.049	0.017
SW			
Metashape	—	—	
WebODMenh	-13.43	-22.55, -4.690	0.003
WebODMstd	-13.79	-22.97, -5.001	0.002
Site			
Skalice	—	—	
Skorkov	11.29	4.499, 18.15	0.001
SpeedDron	-7.782	-12.01, -3.767	<0.001

<sup>1</sup>CI = Confidence Interval

398



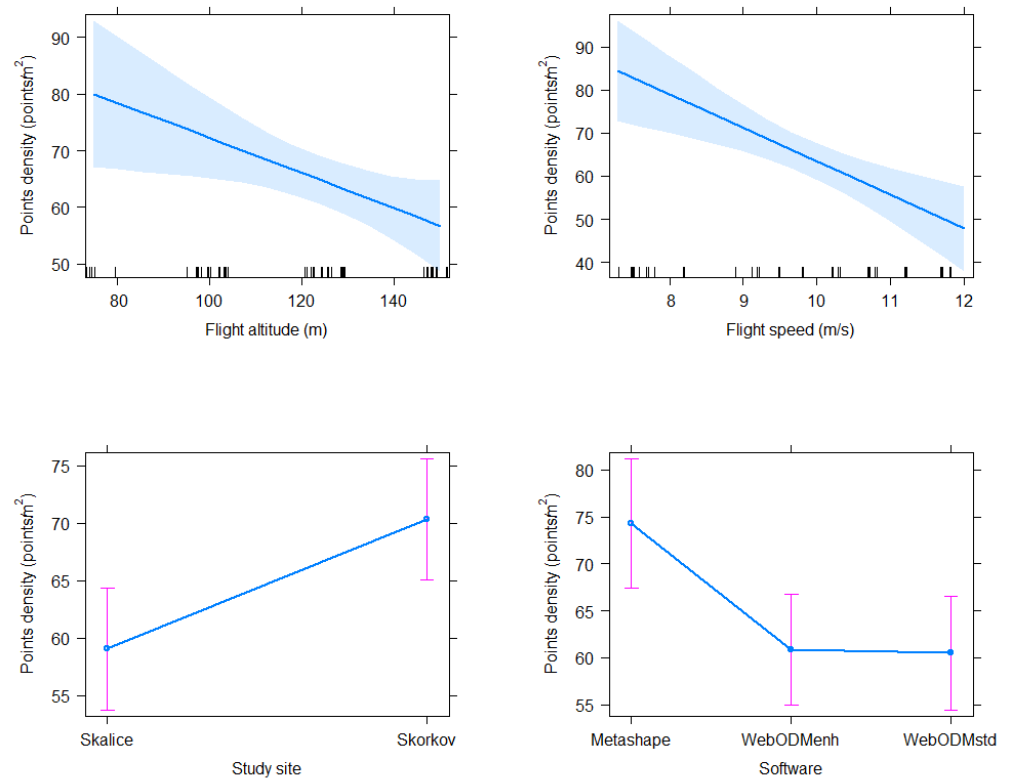
399

**Figure A3.** Diagnostic plots of generalized linear model describing points density as a variable dependent on flight altitude, flight speed, software and site explanatory variables.

400

401

402



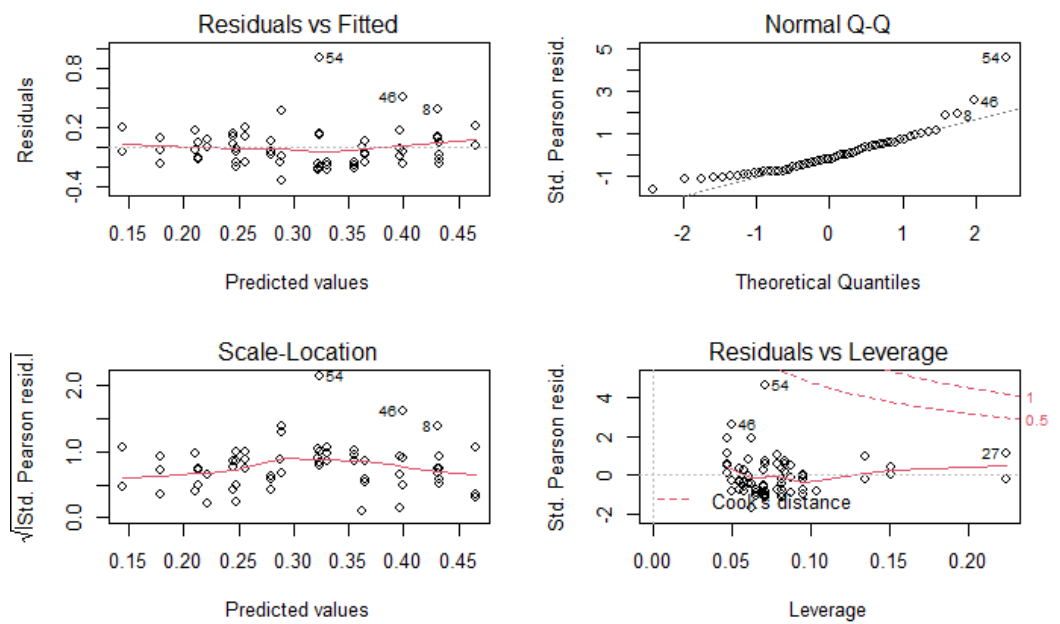
**Figure A4.** Effects of different parameters on GLM-predicted points density of DAP point cloud

403

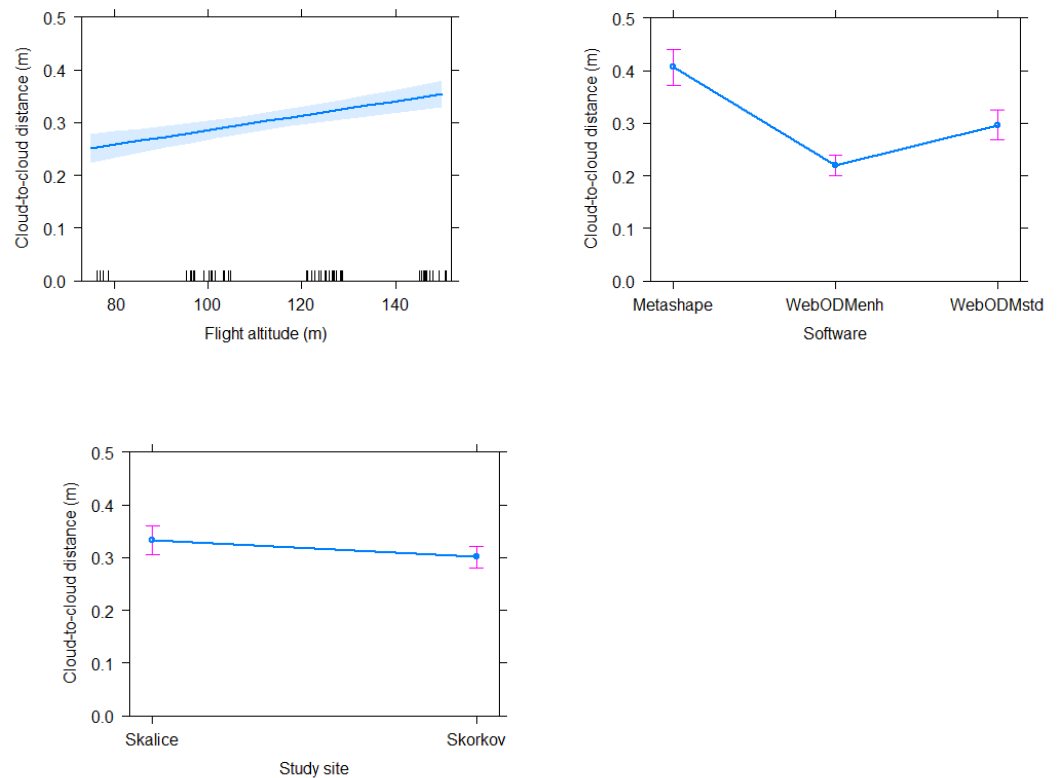
**Table A3.** Results of the generalized linear model describing cloud-to-cloud distance as a variable dependent on flight altitude, software and site (Null deviance: 7.5304 on 62 degrees of freedom, Residual deviance: 2.1167 on 58 degrees of freedom)

Characteristic	Beta	95% CI <sup>1</sup>	p-value
(Intercept)	0.260	0.185, 0.337	<0.001
AltitudePlan	0.001	0.001, 0.002	<0.001
SW			
Metashape	—	—	
WebODMenh	-0.186	-0.225, -0.149	<0.001
WebODMstd	-0.109	-0.153, -0.067	<0.001
Site			
Skalice	—	—	
Skorkov	-0.032	-0.065, -0.001	0.050

<sup>1</sup>CI = Confidence Interval



**Figure A5.** Diagnostic plots of generalized linear model describing mean cloud-to-cloud distance as a variable dependent on flight altitude, software and site explanatory variables.



**Figure A6.** Effects of different parameters on GLM- predicted cloud-to-cloud distance

411

412

## References

413

1. McRoberts, R.E.; Tomppo, E.O. Remote sensing support for national forest inventories. *Remote Sens. Environ.* **2007**, *110*, 412–419. [10.1016/j.rse.2006.09.034](https://doi.org/10.1016/j.rse.2006.09.034).
2. Gatzliolis, D.; Andersen, H.E. A guide to LIDAR data acquisition and processing for the forests of the pacific northwest. *USDA For. Serv. - Gen. Tech. Rep. PNW-GTR* **2008**, 1–32. [10.2737/PNW-GTR-768](https://doi.org/10.2737/PNW-GTR-768).
3. Andersen, H.E.; Reutebuch, S.E.; McGaughey, R.J. A rigorous assessment of tree height measurements obtained using airborne lidar and conventional field methods. *Can. J. Remote Sens.* **2006**, *32*, 355–366. [10.5589/m06-030](https://doi.org/10.5589/m06-030).
4. Smith, M.W.; Carrivick, J.L.; Quincey, D.J. Structure from motion photogrammetry in physical geography. *Prog. Phys. Geogr.* **2015**, *40*. [10.1177/0309133315615805](https://doi.org/10.1177/0309133315615805).
5. Iglhaut, J.; Cabo, C.; Puliti, S.; Piermattei, L.; O'connor, J.; Rosette, J.; Uk, A.A.; Gutiérrez Quirós, G. Structure from Motion Photogrammetry in Forestry: a Review. **2019**. [10.1007/s40725-019-00094-3](https://doi.org/10.1007/s40725-019-00094-3).
6. Pricope, N.G.; Mapes, K.L.; Woodward, K.D.; Olsen, S.F.; Britton Baxley, J. Multi-sensor assessment of the effects of varying processing parameters on uas product accuracy and quality. *Drones* **2019**, *3*, 1–17. [10.3390/drones3030063](https://doi.org/10.3390/drones3030063).
7. DroneDeploy, I. DroneDeploy Drone mapping software Available online: [dronedeploy.com](https://dronedeploy.com).
8. Pix4D SA Pix4D 2020.
9. Agisoft-LLC Agisoft Metashape Professional Edition, Version 1.55. *Agisoft LLC* 2019.
10. OpenDroneMap Authors ODM - A command line toolkit to generate maps, point clouds, 3D models and DEMs from drone, balloon or kite images 2021.
11. WebODM authors WebODM 2021.

431



12. Eltner, A.; Kaiser, A.; Castillo, C.; Rock, G.; Neugirg, F.; Abellán, A. Image-based surface reconstruction in geomorphometry—merits, limits and developments. *Earth Surf. Dyn.* **2016**, *4*, 359–389. 10.5194/esurf-4-359-2016. 432  
433
13. Kubišta, J.; Surový, P. Spatial resolution of unmanned aerial vehicles acquired imagery as a result of different processing conditions. *Cent. Eur. For. J.* **2021**, *67*, 148–154. 10.2478/forj-2021-0011. 434  
435
14. Alidoost, F.; Arefi, H. COMPARISON of UAS-BASED PHOTOGRAMMETRY SOFTWARE for 3D POINT CLOUD GENERATION: A SURVEY over A HISTORICAL SITE. *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.* **2017**, *4*, 55–61. 436  
10.5194/isprs-annals-IV-4-W4-55-2017. 437  
438
15. Gross, J.W.; Heumann, B.W. A statistical examination of image stitching software packages for use with Unmanned Aerial Systems. *Photogramm. Eng. Remote Sensing* **2016**, *82*, 419–425. 10.14358/PERS.82.6.419. 439  
440
16. Fraser, B.T.; Congalton, R.G. Issues in Unmanned Aerial Systems (UAS) data collection of complex forest environments. *Remote Sens.* **2018**, *10*. 10.3390/rs10060908. 441  
442
17. Sibona, E.; Vitali, A.; Meloni, F.; Caffo, L.; Dotta, A.; Lingua, E.; Motta, R.; Garbarino, M. Direct measurement of tree height provides different results on the assessment of LiDAR accuracy. *Forests* **2017**, *8*, 1–12. 10.3390/f8010007. 443  
444
18. *Národní inventarizace lesů v České republice - výsledky druhého cyklu 2011-2015*; Kučera, M., Adolt, R., Eds.; Ústav pro hospodářskou úpravu lesů Brandýs nad Labem: Brandýs nad Labem, 2019; ISBN 978-80-88184-23-2. 445  
446
19. DJI Phantom 3 Professional User manual 2017. 447
20. Riegl RIEGL RIEGL VUX-SYS VUX-SYS Complete Sensor System for Kinematic Laser Scanning. **2019**. 448
21. Czech Republic *Letecký Předpis L 2 Pravidla Létání.*; 2020; 449
22. Harvey, P. ExifTool 2016. 450
23. Goncalves, J.A.; Henriques, R. UAV photogrammetry for topographic monitoring of coastal areas. *ISPRS J. Photogramm. Remote Sens.* **2015**, *104*, 101–111. 10.1016/j.isprsjprs.2015.02.009. 451  
452
24. Ouédraogo, M.M.; Degré, A.; Debouche, C.; Lisein, J. The evaluation of unmanned aerial system-based photogrammetry and terrestrial laser scanning to generate DEMs of agricultural watersheds. *Geomorphology* **2014**, *214*. 453  
10.1016/j.geomorph.2014.02.016. 454  
455
25. Tomašík, J.; Mokroš, M.; Saloň, Š.; Chudý, F.; Tunák, D. Accuracy of Photogrammetric UAV-Based Point Clouds under Conditions of Partially-Open Forest Canopy. *Forests* **2017**, *8*, 151. 10.3390/f8050151. 456  
457
26. Jensen, J.L.R.; Mathews, A.J. Assessment of image-based point cloud products to generate a bare earth surface and estimate canopy heights in a woodland ecosystem. *Remote Sens.* **2016**, *8*. 10.3390/rs8010050. 458  
459
27. Groos, A.R.; Bertschinger, T.J.; Kummer, C.M.; Erlwein, S.; Munz, L.; Philipp, A. The potential of low-cost UAVs and open-source photogrammetry software for high-resolution monitoring of alpine glaciers: A case study from the kanderfirn (Swiss Alps). *Geosci.* **2019**, *9*. 10.3390/geosciences9080356. 460  
461  
462
28. White, C.; Petrasova, A.; Reckling, W.; Mitasova, H. Automated Land Cover Change detection through rapid UAS updates of Digital Surface Models. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2020**, *XLII-3/W11*. 10.5194/isprs-archives-XLII-3-W11-155-2020. 463  
464  
465
29. Toffanin, P. *OpenDroneMap: The Missing Guide*; first.; UAV4GEO, 2019; 466
30. Cloudcompare Cloudcompare 2.11.1 2021. 467
31. Zhang, W.; Qi, J.; Wan, P.; Wang, H.; Xie, D.; Wang, X.; Yan, G. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sens.* **2016**, *8*, 1–22. 10.3390/rs8060501. 468  
469
32. RStudio Team RStudio: Integrated Development Environment for R 2019. 470
33. R Core Team R: A Language and Environment for Statistical Computing 2020. 471
34. Long, J.A. jtools: Analysis and Presentation of Social Scientific Data 2020. 472
35. Wickham, H.; Hester, J. readr: Read Rectangular Text Data 2020. 473

- 
36. Wickham, H. *ggplot2: Elegant Graphics for Data Analysis*; 1st ed.; Springer-Verlag New York, 2016; ISBN 978-3-319-24277-4. 474
37. Sjoberg, D.D.; Whiting, K.; Curry, M.; Lavery, J.A.; Larmarange, J. Reproducible Summary Tables with the gtsummary Package. *R J.* **2021**, *13*, 570–580. 10.32614/RJ-2021-053. 475  
476
38. Magnussen, S.; Næsset, E.; Gobakken, T. Reliability of LiDAR derived predictors of forest inventory attributes: A case study with Norway spruce. *Remote Sens. Environ.* **2010**, *114*, 700–712. 10.1016/j.rse.2009.11.007. 477  
478
39. Kandare, K.; Ørka, H.O.; Chan, J.C.W.; Dalponte, M. Effects of forest structure and airborne laser scanning point cloud density on 3D delineation of individual tree crowns. *Eur. J. Remote Sens.* **2016**, *49*, 337–359. 10.5721/EuJRS20164919. 479  
480
40. Agüera-Vega, F.; Carvajal-Ramírez, F.; Martínez-Carricondo, P. Accuracy of Digital Surface Models and Orthophotos Derived from Unmanned Aerial Vehicle Photogrammetry. *J. Surv. Eng.* **2017**, *143*, 04016025. 10.1061/(ASCE)SU.1943-5428.0000206. 481  
482  
483
41. Smith, M.W.; Vericat, D. From experimental plots to experimental landscapes: topography, erosion and deposition in sub-humid badlands from Structure-from-Motion photogrammetry Measuring erosion in dynamic landscapes. **2015**. 484  
485  
10.1002/esp.3747. 486
42. Luoma, V.; Saarinen, N.; Wulder, M.A.; White, J.C.; Vastaranta, M.; Holopainen, M.; Hyyppä, J. Assessing precision in conventional field measurements of individual tree attributes. *Forests* **2017**, *8*, 1–16. 10.3390/f8020038. 487  
488
43. Larjavaara, M.; Muller-Landau, H.C. Measuring tree height: A quantitative comparison of two common field methods in a moist tropical forest. *Methods Ecol. Evol.* **2013**, *4*, 793–801. 10.1111/2041-210X.12071. 489  
490
44. Madawalagama, S.L.; Athukorala, D.R.M.; Jayamal, K.C.; Ochi, S.; Samarakoon, L. Assessment of UAV based low cost photogrammetric system for aerial mapping. *38th Asian Conf. Remote Sens. - Sp. Appl. Touching Hum. Lives, ACRS 2017* **2017**, *2017-October*, 1V. 491  
492  
493  
494

**Příloha 3. Kubišta J.; Surový P. Individual tree identification in ULS point clouds using a crown width mixed-effects model based on NFI data. 2022.**

# Individual tree identification in ULS point clouds using a crown width mixed-effects model based on NFI data.

Jaroslav Kubišta <sup>1,2\*</sup> and Peter Surový <sup>1</sup>

<sup>1</sup> Faculty of Forestry and Wood Sciences, Czech University of Life Sciences, Prague, Kamýčká 129, 165 00 Praha, Czech Republic

<sup>2</sup> Forest Management Institute Brandýs nad Labem, Czech Republic

\* Correspondence: kubista.jaroslav@uhul.cz

**Abstract:** We used a linear mixed-effects model to relate crown width to height, with inventory plot as a random effect, for trees in Czechia based on data from the National Forest Inventory (NFI). This model was used to estimate window size for a local maximum filter procedure (LMF) to detect individual tree tops in unmanned aerial laser scanning (ULS) point clouds of mixed species forest stands with diverse structures. Random parameters of the model were estimated for study site based on several sample trees. Models calibrated with 5 and more samples achieved significantly better results (mean percentage error; MPE -0.17 for 5 samples) in comparison to a fixed-effects model (MPE -0.62). Lower performance was observed in dense stands with trees between 5 and 10 meters in height. We concluded that locally-calibrated models predicting crown widths from tree heights might serve as a universal point of departure in searching for an optimal window size setting in LMF procedures.

**Keywords:** Local calibration; UAV; ULS; LMF; ITD

**Citation:** Kubišta, J.; Surový, P. Individual tree identification in ULS point clouds using a crown width mixed-effects model based on NFI data. *Remote Sens.* **2022**, *14*, x. <https://doi.org/10.3390/xxxxx>

Academic Editor: Firstname Last-name

Received: date

Accepted: date

Published: date

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2021 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

## 1. Introduction

Due to mass production and increasing affordability, the use of unmanned aerial vehicles (UAV) for forest monitoring is no longer the prerogative of advanced scientific teams. A similar trend has been observed in software for processing data acquired by UAVs into 3D point clouds representing forest trees in the case of laser scanning (light detection and ranging - Lidar), or its surface in the case of photogrammetry. Still, subsequent steps are necessary for extracting the relevant information from forest point clouds, which tends to be quite fragmented, and it often requires intensive fitting for differing situations.

The detection of individual tree tops from UAV-based photogrammetry point clouds is a frequently discussed procedure, and different methods have been reviewed by several authors, for example [1]. The local maximum filter (LMF) is one of the methods most commonly used. Several studies suggest that using LMF with a variable window size gives more promising results, especially in more diverse conditions [2]. Nevertheless, the correct size of the window, whether fixed or variable, is critical to the results, and an incorrect size can lead to serious errors. Determining the window size is often a trial-and-error process for particular stands or situations. The R-project[3] LidR package [4] allows for a variable window size for LMF based on the chosen function of the Z-coordinate of point clouds in which the tree tops are identified. Tree crown width might serve as a good parameter for setting the window size based on the tree height [2]. In this method, a model is built using tree height to predict the crown diameter.

Several studies concluded that the correlation between crown diameter and tree height was rather low, therefore, crown diameter prediction models are usually built using tree stem diameter and several other independent variables [5][6][7]. Because these

variables are not available in our particular case, we tried to overcome this using a linear mixed-effects model with NFI plots treated as a random effect. Local calibration [8][9] of this model was expected to provide an ideal means of establishing an appropriate LMF variable window size for a given area of interest. The Czechia National Forest Inventory (NFI) [10] data provides a great opportunity to build such a model at the country level. Unmanned aerial laser scanning (ULS) point clouds, together with field survey results of tree counts on sample plots, represented a promising means to assess the performance of local calibration based on different numbers of samples.

## 2. Materials and Methods

### *Study site*

Our study site, Skorkov (Lat: 50.2143906N, Lon: 14.7160739E; Position WGS 84), northeast of Prague was established in a mixed forest stand of mostly flat terrain (188–190 m AMSL) with species composition dominated by *Pinus silvestris* L. and *Quercus robur* L. Different age classes are present in the 9.31 ha rather rectangular arrangements, which is typical for *Pinus* management in this region.

### *Data acquisition*

The ULS point clouds were acquired using the UAV VUX-SYS setup (RIEGL Laser Measurement System GmbH, Horn, Austria) for UAV-borne data acquisition, which consists of the UAV RiCOPTER, the VUX-1UAV laser scanner, and the AP-20 inertial measurement unit [11]. The laser scanner was set to its maximum pulse frequency of 550 kHz with a registration of 200 scanning lines per second. The flight was performed at a constant altitude of 90 m aboveground, with a constant ground speed of 6 m·s<sup>-1</sup>. This setup reached an average point density of 200 points·m<sup>-2</sup> for each scanning line. Due to the overlap of individual scanning lines, the final mean point density was around 600 points·m<sup>-2</sup>. In all UAV flights, we complied with the respective national requirements, as stated in [12] and valid at the time of flight (September 2020), namely a maximum flight height below 300 m, visual line of sight, airspace restrictions, and a minimal distance from people and buildings.

### *Laser point cloud generation*

The ULS point cloud was prepared from the data acquired by an UAV Ricopter equipped with a Riegl VUX-SYS1 sensor. We used the smoothed best estimates of trajectory based on the reference station post-processing kinematics with the virtual base station from Trimble VRS Now (Trimble Inc., Sunnyvale, California USA), prepared in the environment of RiPROCESS with the RiPRECISION module [11]. Point cloud classification (for ground and non-ground points) was conducted in the same software environment.

### *Sample plot surveys*

To gather relevant data for the evaluation of individual tree identification using an LMF procedure, we conducted a field survey. We established 39 circular plots with a variable plot radius related to average tree height within the main canopy Table 1. Sample plot size.

**Table 1.** Sample plot size classes based on average tree heights of the main canopy.

Plot class	Tree height (m)	Plot radius (m)	Plot area (m <sup>2</sup> )	Minimal register limit
1	<3	3.00	28.27	1.5 m height
2	3–10	5.00	78.54	1.5 m height
3	>10	12.62	500.00	7 cm DBH*

\* DBH – diameter at breast height (1.3 m height)

On each sample plot, all trees over the minimal register limit were counted. Randomly chosen tree was also sampled for height and crown parameters. In class 1 plots, maximum and minimum crown projection diameters were measured by tape, and crown width was calculated as an average of these two measurements. For class 2 and 3 plots, we used a procedure similar to NFI Surveys [10] that included measuring ground projection of at least five points, and crown extent was defined using the Field-Map software/hardware set (IFER – Monitoring and Mapping Solutions Ltd., Jílové u Prahy, Czechia).



Figure 1. Layout and relative size indicators of variable radius sample plots at study site.

Crown width model data

The NFI data acquired by the Forest Management Institute since 2001 were used to build linear mixed-effects models for tree crown width predictions of individual trees based on height. The intended use of the model within the LMF procedure was limited to a single predictor variable, height, thus we did not include other frequently employed variables [5][6][7], such as diameter at breast height (DBH), to construct our crown prediction models. The NFI dataset included data on more than ninety-four thousand trees measured on more than twenty-two thousand plots. Only trees from the upper tree layer, as defined by the International Union of Forest Research Organizations, with observed crown projection area and height measurements were selected. The NFI field surveys [10] identify tree crowns in the form of a horizontal projection area. For the purpose of this study, we calculated crown width as a function of crown area assuming a circular shape centered on the tree stem.

Table 2. Selected summary of NFI data.

Characteristic	n <sup>1</sup> = 94,066
Plots (n)	22,532
Mean height (m)	25 (4 to 54)
Mean crown width (m)	5.57 (1.35 to 19.33)
Species group	
Abies alba Mill.	1,202 (1.3%)

Characteristic	n <sup>1</sup> = 94,066
Acer spp.	1,709 (1.8%)
Alnus spp.	2,177 (2.3%)
Betula spp.	2,382 (2.5%)
Carpinus betulus L.	890 (0.9%)
Fagus sylvatica L.	6,475 (6.9%)
Fraxinus spp.	1,340 (1.4%)
Larix decidua Mill.	4,300 (4.6%)
Other broadleaved hard spp.	970 (1.0%)
Other broadleaved soft spp.	2,672 (2.8%)
Other coniferous spp.	763 (0.8%)
Picea abies (L.) Karst.	48,767 (52%)
Pinus sylvestris L.	13,691 (15%)
Quercus spp.	6,728 (7.2%)

<sup>1</sup>Mean (Range); n (%)

### Model

A simple linear mixed-effects model was built iteratively with different transformations of predictor or predicted variables to achieve optimal results. The best performing model was:

$$\ln(CW_{ki}) = \beta_0 + \beta_1 H_{ki}/100 + \alpha_{0k} + \alpha_{1k} H_{ki}/100 + e_{ki} \quad \text{Eq 1}$$

where  $CW_{ki}$  is the crown width of tree  $i$  in stand/plot  $k$  (m),  $H_{ki}$  is the height of tree  $i$  in stand/plot  $k$  (m),  $\beta_0$  and  $\beta_1$  are fixed population parameters to be estimated,  $\alpha_{0k}$  and  $\alpha_{1k}$  are random parameters to be estimated having zero expectations for stand  $k$ , and  $e_{ki}$  is the random residual error for tree  $i$  on stand/plot  $k$ . The  $H_{ki}$  variable had to be scaled, otherwise the model would not converge. This model is basically similar to that described by Lappi [8], which used height-DBH data.

The model parameters were first estimated using all trees from the NFI dataset with crown width and height measurements ( $n = 94,066$ ), regardless of species, and the NFI plots were treated as a random parameter. This model was named as f1. We developed the model in this manner in an effort to account for parameters other than height as represented all together by individual inventory plot.

From the field surveys of the study site, we know that a limited number of tree species are present, with three species representing the majority – *P. sylvestris*, *Q. robur*, and *Quercus rubra* L. Therefore, we decided to subset the NFI dataset to limit it to only *P. sylvestris* and *Quercus* species, which we then used to construct model f2.

### Model calibration

Use of a linear mixed-effects model allows for calibration within particular stands. Based on sample data of crown widths and tree heights obtained at the stand of interest, values for random parameters from equation Eq 1 can be estimated [9] according to Eq 2.

$$\hat{a} = (Z' \hat{R}^{-1} Z + \hat{D}^{-1})^{-1} Z' \hat{R}^{-1} (y - \hat{\mu}) \quad \text{Eq 2}$$

where  $\hat{a}$  is the matrix of estimated random parameters;  $Z$  is the design matrix associated with random parameters;  $\hat{D}$  is an estimate of  $D$ , the variance-covariance matrix for the random parameters;  $\hat{R} = \hat{\sigma}_{e_{ki}}^2 \times I$  is the estimated variance-covariance matrix for residual errors of individual trees where  $\hat{\sigma}_{e_{ki}}^2$  is the square of the residual standard error;  $\hat{\mu}$  is a vector of predicted values from the fixed effect model, and  $y$  is a vector of observations of the dependent variable from the particular stand.

To evaluate this calibration method on our model, we iteratively took out one plot from the NFI dataset as a calibration plot. The LME model (Eq 1) was fitted to the NFI dataset without the calibration plot. Calibration was repeatedly performed based on

height and crown width data of 1,3,5, and 10 random trees from the calibration plot according to Eq 2.

Crown width was then estimated based on both the marginal model (without random parameters) and the calibrated model with estimated random parameters. Both estimates were compared to field-measured crown width values from the calibration plot using the normalized root mean squared error (nRMSE; Eq 3). This procedure was repeated one hundred times to assess the performance of the calibrated models.

$$nRMSE = \frac{\sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}}{\bar{y}} \quad \text{Eq 3}$$

where  $n$  is the number of observations,  $y$  is the observed value, and  $\hat{y}$  is the estimated value.

#### Study site calibration

For calibration of global models explained in section 0, data for the crown widths and heights measured in sample plots were used. A total of 39 trees were measured for this calibration. To evaluate the influence of the different number of calibration measurements, calibration of both models was performed with randomly chosen 3,5,10, and all 39 calibration samples. Together with the uncalibrated marginal models, a total of 10 formulas were prepared to be used in the LMF procedure. Model function names are identified by the model used (f1; f2), and the number of sample trees used to calibrate the model (e.g., cal3 = 3 sample trees used); for example, Model f2 calibrated with 10 sample trees is identified as f2\_cal10. Details of both models, necessary for local calibration are presented in **Appendix A**.

#### Trees identification

The ULS point cloud was processed through the following pipeline performed in R statistical package [3] using the LidR [4] and ForestTools [13] packages.

1. Read ULS point cloud data.
2. Perform normalization of point cloud with ground points classified by the cloth simulation filter [14].  
Then for each of the 10 versions of the models.
3. Run the LMF procedure to identify the local maximum within a circular window with the diameter defined by the results of the formula using Z coordinates as the height variables.
4. Intersect resulting tree tops with sample plots.
5. Compare the number of trees identified by the LMF procedure and the number of trees from our field survey. Comparisons were made based on the percentage error (PE) Eq 4 and mean percentage error (MPE) Eq 5.

$$PE = \frac{\hat{y}_i - y_i}{y_i} \quad \text{Eq 4}$$

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{\hat{y}_i - y_i}{y_i} \quad \text{Eq 5}$$

where  $n$  is the number of sample plots,  $y$  is the observed number of trees at sample plot  $i$ , and  $\hat{y}$  is the estimated number of trees at sample plot  $i$

All analyses were conducted in R-Studio version 1.4.1103 [15] with R version 4.0.3 [3] using the following libraries: LidR [4], ForestTools [13], sjPlot [16], JTools [17], Readr [18], GGplot2 [19], gtsummary [20].

### 3. Results



3.1 Models

186

Results of models f1 and f2, are visible in Table 3 and also in Appendix A

187

Table 3. Linear mixed-effects models f1 and f2 results

188

Predictors	Model f1 ln(CW)			Model f2 ln(CW)		
	Estimates	CI	p	Estimates	CI	p
(Intercept)	0.9692	0.9552 – 0.9831	<0.001	1.0471	1.0140 – 1.0802	<0.001
H/100	2.9192	2.8671 – 2.9714	<0.001	2.7494	2.6134 – 2.8854	<0.001
Random Effects						
$\sigma^2$		0.0579			0.0588	
$\tau_{0k}$		0.3248			0.3792	
$\tau_{1k}$		3.0351			4.7034	
$\rho_{01k}$		-0.8865			-0.8578	
ICC		0.6090			0.6663	
$N_k$		22,532			7,009	
Observations		94,066			20,419	
Marginal R <sup>2</sup> / Conditional R <sup>2</sup>		0.226 / 0.697			0.129 / 0.709	

Marginal and conditional R-squared statistics, based on [21]

189

3.2 Model calibration test

190

Using the procedure described in 0, a single plot from the NFI dataset (randomly selected from plots with more than 15 trees measured) was used as a hypothetical new plot. Repeated calibration of the model fitted to the rest of the dataset was performed, using 1,3,5, or 10 trees from the calibration plot. For each of these calibrated models, crown width was estimated and compared to the original values from the NFI dataset **Figure 2**.


191

192


193

194

195




(a)



(b)

**Figure 2.** Test calibration example (a) calibration results (solid line) using 3 calibration trees (black dots) compared to uncalibrated model (dashed line); (b) effect of calibration (solid line) on nRMSE compared to uncalibrated model (dashed line).

This procedure was repeated one hundred times. Overall performance of the calibration process is evident in Figure 3, with a better fit of models when calibrated with more sample trees, although differences between 3,5, and 10 sample trees was relatively small. Using this procedure, it is evident that the fixed-effects model can be improved by the calibration process.



**Figure 3.** Test calibration results (0 trees for calibration is the equivalent of an uncalibrated fixed-effects model).

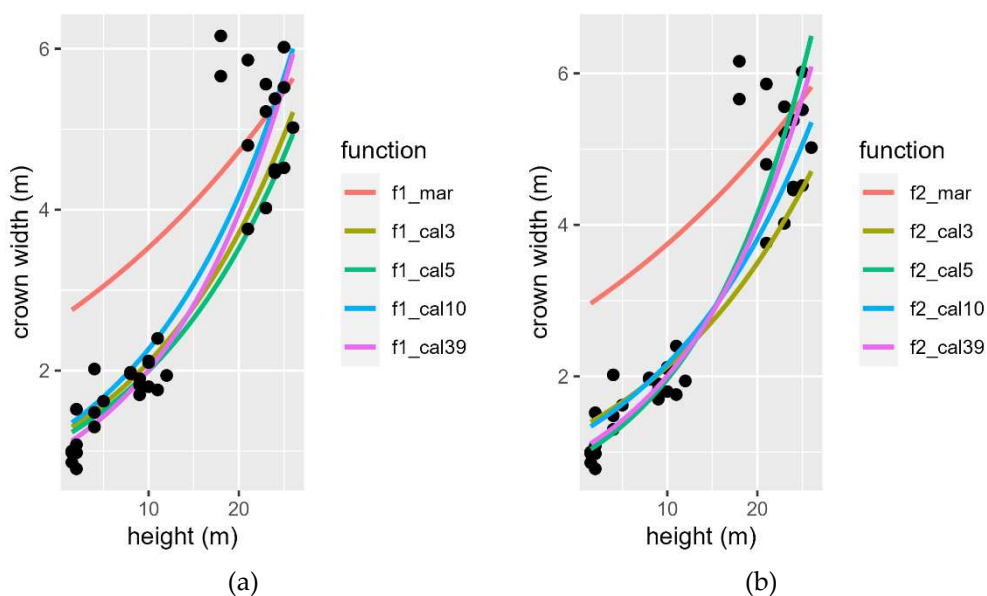
A Kruskal-Wallis test of the nRMSE values based on the number of samples used for calibration demonstrated a significant difference between groups (p-value =  $1.219e^{-13}$ ). Subsequent Dunn’s test confirmed the optimal use of at least 3 samples for calibration; further increase of sample numbers did not contribute any significant improvements Table 4.

**Table 4.** Dunn’s test p-values for nRMSE grouped by number of samples used for calibration.

samples (n)	0	1	3	5
1	0.001			
3	0.000	0.033		
5	0.000	0.003	0.443	
10	0.000	0.001	0.219	0.608

### 3.3 Study site model calibration

A similar procedure was used for local calibration of model f1 and f2 based on data obtained from the sample plots at the study site. Again, several versions with 3, 5, 10 and the complete set of field-measured tree samples (39) were assessed. Together with uncalibrated fixed-effects model, we produced 10 formulas to model crown widths based on tree heights **Figure 4.** Study site model calibrations and **Chyba! Nenalezen zdroj odkazů..**

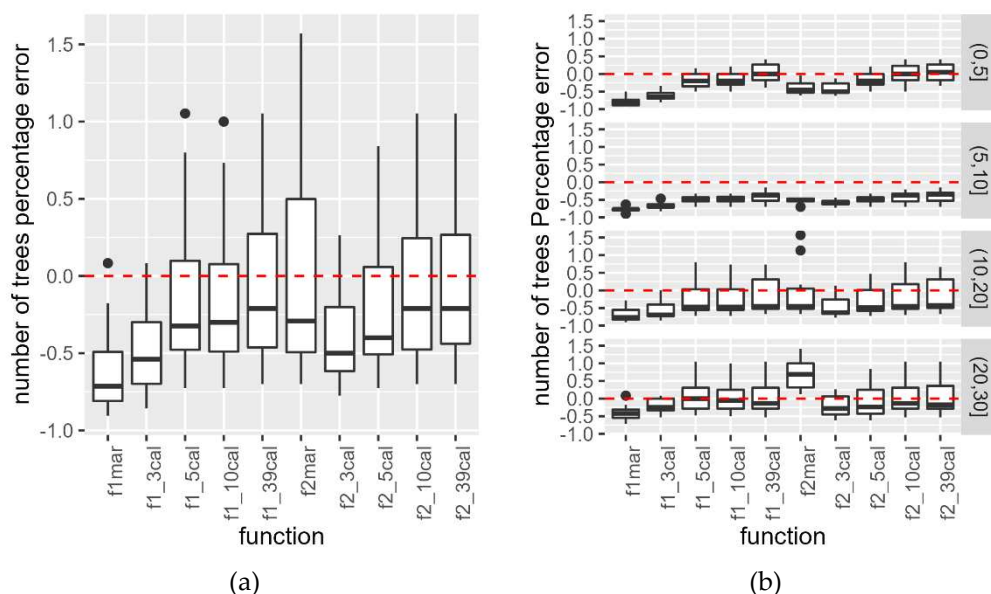


**Figure 4.** Study site model calibrations (a) model f1 all species; (b) model f2 *Pinus* spp. and *Quercus* spp. Calibration data displayed as black points.

### 3.5 Tree identification

The MPE between field survey-observed and LMF-identified number of trees on sample plots was on average -0.23, varying from -0.62 to 0.04 (standard deviation of 0.21). The nRMSE had values between 0.50 and 0.78. Distribution of MPE by function used for the LMF procedure is described in Figure 5 (a), which indicates overall better results of calibrated functions, with the surprising exception of the fixed-effects only model for *Pinus* and *Quercus* spp., f2mar.

To better assess the influence of tree height, sample plots were divided into four consecutive categories according to max height of trees observed on plot. Figure 5 b) and **Table 5** reveal that the unexpected good performance of the f2mar function results from the average of overestimating the number of the tallest trees on one hand, and underestimating the number of the smallest trees on the other hand. Table 9 also displays the increased accuracy of calibrated models – with comparable performance of 5- and 10-sample calibrations to the full 39-sample calibration. According to nRMSE, the best performing model, f2\_39cal, is closely followed by all models with 5 and more samples used for calibration. In terms of height categories, the most underestimated was the number of trees 5 to 10 m in height.



**Figure 5.** Percentage error between LMF-identified and field survey-observed number of trees on sample plots (a) divided by function used for LMF procedure, and (b) divided by height category of sample plots. 241  
242  
243

**Table 5.** Mean percentage error between LMF-identified and field survey-observed number of trees on sample plots. 244  
245

Func-tion	nRMSE	Tree Count MPE by Height category				
		<i>all</i>	<i>0 to 5m</i>	<i>5 to 10m</i>	<i>10 to 20m</i>	<i>20 to 30m</i>
f1mar	0.78	-0.62	-0.77	-0.77	-0.68	-0.40
f1_3cal	0.68	-0.48	-0.60	-0.67	-0.57	-0.23
f1_5cal	0.53	-0.17	-0.19	-0.49	-0.21	0.05
f1_10cal	0.53	-0.18	-0.17	-0.49	-0.23	0.02
f1_39cal	0.51	-0.08	0.02	-0.42	-0.15	0.09
f2mar	0.61	0.03	-0.38	-0.52	-0.06	0.69
f2_3cal	0.61	-0.39	-0.42	-0.58	-0.45	-0.22
f2_5cal	0.54	-0.23	-0.17	-0.49	-0.29	-0.09
f2_10cal	0.52	-0.09	-0.00	-0.43	-0.17	0.09
f2_39cal	0.50	-0.08	0.07	-0.41	-0.17	0.07

A Kruskal-Wallis test suggested significant differences of tree count error by model functions used for LMF (p-value =  $9.302e^{-06}$ ). A subsequent Dunn’s test revealed significant improvement of results when at least 5 samples were used for calibration (**Table 6**). Using model f2, fitted only to data of tree species present on the study site, did not bring expected improvements in any of the models. 246  
247  
248  
249  
250

**Table 6.** Dunn’s test p-values for tree count error grouped by function used for LMF. 251

	f1mar	f1_3cal	f1_5cal	f1_10cal	f1_39cal	f2mar	f2_3cal	f2_5cal	f2_10cal
f1_3cal	0.439								
f1_5cal	<b>0.006</b>	0.071							
f1_10cal	<b>0.005</b>	0.067	0.998						
f1_39cal	<b>0.001</b>	<b>0.014</b>	0.665	0.683					
f2mar	<b>0.001</b>	<b>0.009</b>	0.537	0.554	0.905				
f2_3cal	0.175	0.706	0.228	0.218	0.063	<b>0.037</b>			
f2_5cal	<b>0.013</b>	0.167	0.810	0.791	0.451	0.347	0.445		

f2_10cal	<b>0.001</b>	<b>0.018</b>	0.692	0.710	0.961	0.837	0.068	0.511	
f2_39cal	<b>0.001</b>	<b>0.014</b>	0.646	0.665	0.966	0.942	0.056	0.435	0.925

#### 4. Discussion

Iterative tests of local calibration of a global LME model revealed significant improvements of model performance, even with only a single calibration sample. Three samples were interpreted to be the optimal amount because further increases in the number of samples did not bring significant improvements. Several studies have similarly recommended only a limited number of samples for calibration of mixed-effects height–diameter models [22][23][24].

Local maximum filter belongs to one of the most commonly used approaches for individual tree tops detection in point clouds [1]. Determining the appropriate window size for LMF is often a trial-and-error process for particular stands or situations. We tried to improve this situation using tree crown width to set the LMF window size.

Most reported approaches use other predictor variables, most often DBH, for crown projection rather than height [5][25][26], and, thus, it basically disqualifies using those models for local maximum filter techniques for the detection of individual tree tops.

Our suggested approach of a linear mixed-effect model to predict tree crown width based on tree height using a few samples (results at our study site suggested at least five) obtained on site for local calibration might serve as a viable option. Our presented model reached a conditional R-square value of 0.70, which seems more promising than a similar model built on a much smaller data sample, which had an R-square value of 0.51 [2].

With the proposed method of LMF individual tree detection based on crown width determined window size using ULS point cloud data, we were able to achieve an nRMSE around 0.50. The MPE metric, ranging between -0.62 and +0.03, revealed that in most cases our approach led to a lower number of trees identified compared to the field survey. This can be attributed to the problematic distinction of single trees in *Pinus* and *Quercus* forest types with such a diverse structure on our particular study site. Not all trees have grown into the canopy layer, and the distinction of those trees is rather difficult, especially with broadleaved species. This is also supported by the poor performance with trees between 5 and 10 meters. Somewhat similar results with tree detection rates ranging from 50% to 140% using different methods for ITD on ULS point clouds were reported by Wang et al. [27]. A study by Grznárová et al. [28] produced a detection rate of 95% for coniferous forests and 71% in broadleaved forests. Nevalainen et al. [29] achieved tree identification rates between 64 and 97%. Results with 38 to 85% of trees undetected across plots was also reported by Jeronimo et al. [30] with poorer individual tree detection of smaller trees. Throughout the cited studies it is clearly visible, that ITD precision decreases with increased forest structure complexity.

#### 5. Conclusions

Our results of individual tree top detection reached only limited accuracy in terms of the number of trees identified in sample plots. Nevertheless, the presented approach using a local maximum filter with variable window size governed by locally-calibrated models predicting crown width from tree heights might serve as a universal point of departure in searching for optimal window size settings in LMF procedures.

**Author Contributions:** Conceptualization, J.K. and P.S.; methodology, J.K.; software, J.K.; validation, J.K., P.S.; formal analysis, J.K., P.S.; investigation, J.K.; resources, J.K.; data curation, J.K.; writing—original draft preparation, J.K.; writing—review and editing, J.K., P.S.; visualization, J.K.; supervision, P.S.; project administration, J.K.; funding acquisition, P.S. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research received no external funding.

**Acknowledgments:** Authors would like to thank the Forest Management Institute for providing data from the National Forest Inventory, and, from the same organization, Radim Adolt for consultations of mixed-effects models, Jiří Nechvíle, Jan Máslo, Zdeněk Link, and Josef Málek for surveying of sample plots. Also, colleagues from the Faculty of Forestry and Wood Sciences, namely Martin Slavík and Karel Kuželka, for the airborne laser scanning data acquisition.

**Conflicts of Interest:** The authors declare no conflict of interest.

## Appendix A Models results

307

Table A1. Model f1 (all species) details

308

<i>Predictors</i>	<i>Estimates</i>	<i>ln(CW)</i>		<i>p</i>
		<i>CI</i>		
(Intercept)	0.9691528265	0.9551970430 – 0.9831086099		<0.001
H/100	2.9192160556	2.8670704505 – 2.9713616608		<0.001
Random Effects				
$\sigma^2$		0.0579225773		
$\tau_{00}$		0.3248247819		
$\tau_{11}$		3.0351135705		
Q <sub>01</sub>		-0.8865128648		
ICC		0.6090064317		
N <sub>pid</sub>		22532		
Observations		94066		
Marginal R <sup>2</sup> / Conditional R <sup>2</sup>		0.226 / 0.697		

Table A2. Model f2 (pine and oaks only) details

309

<i>Predictors</i>	<i>Estimates</i>	<i>ln(CW)</i>		<i>p</i>
		<i>CI</i>		
(Intercept)	1.0471117767	1.0140393762 – 1.0801841773		<0.001
H/100	2.7494035917	2.6133807717 – 2.8854264117		<0.001
Random Effects				
$\sigma^2$		0.0587756430		
$\tau_{00}$		0.3791901633		
$\tau_{11}$		4.7029756295		
Q <sub>01</sub>		-0.8577703035		
ICC		0.6662831293		
N <sub>pid</sub>		7009		
Observations		20419		
Marginal R <sup>2</sup> / Conditional R <sup>2</sup>		0.129 / 0.709		

310

311





Figure A1. Model f1 diagnostic plots

312








Figure A2. Model f2 diagnostic plots

## References

1. Ke, Y.; Quackenbush, L.J. A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. *Int. J. Remote Sens.* **2011**, *32*, 4725–4747. 10.1080/01431161.2010.494184. 314
2. Popescu, S.C.; Wynne, R.H.; Nelson, R.F. Estimating plot-level tree heights with lidar: Local filtering with a canopy-height based variable window size. *Comput. Electron. Agric.* **2003**, *37*, 71–95. 10.1016/S0168-1699(02)00121-7. 316
3. R Core Team R: A Language and Environment for Statistical Computing 2020. 317
4. Roussel, J.-R.; Auty, D. Airborne LiDAR Data Manipulation and Visualization for Forestry Applications 2021. 318
5. Fu, L.; Sun, H.; Sharma, R.P.; Lei, Y.; Zhang, H.; Tang, S. Nonlinear mixed-effects crown width models for individual trees of Chinese fir (*Cunninghamia lanceolata*) in south-central China. *For. Ecol. Manage.* **2013**, *302*, 210–220. 319
6. Gill, S.J.; Biging, G.S.; Murphy, E.C. Modeling conifer tree crown radius and estimating canopy cover. *For. Ecol. Manage.* **2000**, *126*, 405–416. 10.1016/S0378-1127(99)00113-9. 320
7. Bechtold, W.A. Crown-Diameter Prediction Models for 87 Species of Stand-Grown Trees in the Eastern United States. *South. J. Appl. For.* **2003**, *27*, 269–278. 10.1093/sjaf/27.4.269. 321
8. Lappi, J. Calibration of Height and Volume Equations with Random Parameters. *For. Sci.* **1991**, *37*, 781–801. 322
9. Lynch, T.B.; Holley, A.G.; Stevenson, D.J. A random-parameter height-dbh model for cherrybark oak. *South. J. Appl. For.* **2005**, *29*, 22–26. 10.1093/sjaf/29.1.22. 323
10. Adolt, R.; Kučera, M.; Zapadlo, J.; Andrlík, M.; Čech, Z.; Coufal, J. *Pracovní postupy pozemního šetření NIL2; Ústav pro hospodářskou úpravu lesů Brandýs nad Labem*, 2013; ISBN 9788090542327. 324
11. Riegl RIEGL RIEGL VUX-SYS VUX-SYS Complete Sensor System for Kinematic Laser Scanning. **2019**. 325
12. Czech Republic *Letecký Předpis L 2 Pravidla Letání*.; 2020; 326
13. Plowright, A.; Roussel, J.-R. ForestTools: Analyzing Remotely Sensed Forest Data 2021. 327
14. Zhang, W.; Qi, J.; Wan, P.; Wang, H.; Xie, D.; Wang, X.; Yan, G. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sens.* **2016**, *8*, 1–22. 10.3390/rs8060501. 328
15. RStudio Team RStudio: Integrated Development Environment for R 2019. 329
16. Lüdecke, D. sjPlot: Data Visualization for Statistics in Social Science 2021. 330
17. Long, J.A. jtools: Analysis and Presentation of Social Scientific Data 2020. 331
18. Wickham, H.; Hester, J. readr: Read Rectangular Text Data 2020. 332
19. Wickham, H. *ggplot2: Elegant Graphics for Data Analysis*; 1st ed.; Springer-Verlag New York, 2016; ISBN 978-3-319-24277-4. 333
20. Sjoberg, D.D.; Whiting, K.; Curry, M.; Lavery, J.A.; Larmarange, J. Reproducible Summary Tables with the gtsummary Package. *R J.* **2021**, *13*, 570–580. 10.32614/RJ-2021-053. 334
21. Nakagawa, S.; Johnson, P.C.D.; Schielzeth, H. The coefficient of determination R<sup>2</sup> and intra-class correlation coefficient from generalized linear mixed-effects models revisited and expanded. *J. R. Soc. Interface* **2017**, *14*. 10.1098/rsif.2017.0213. 335
22. Trincado, G.; VanderSchaaf, C.L.; Burkhart, H.E. Regional mixed-effects height-diameter models for loblolly pine (*Pinus taeda* L.) plantations. *Eur. J. For. Res.* **2007**, *126*, 253–262. 10.1007/s10342-006-0141-7. 336
23. Calama, R.; Montero, G. Stand and tree-level variability on stem form and tree volume in *Pinus pinea* L.: A multilevel random components approach. *Investig. Agrar. Sist. y Recur. For.* **2006**, *15*, 24. 10.5424/srf/2006151-00951. 337
24. Jayaraman, K.; Lappi, J. Estimation of height-diameter curves through multilevel models with special reference 338

- to even-aged teak stands. *For. Ecol. Manage.* **2001**, *142*, 155–162. 10.1016/S0378-1127(00)00347-9. 356
25. Condés, S.; Sterba, H. Derivation of compatible crown width equations for some important tree species of Spain. *For. Ecol. Manage.* **2005**, *217*, 203–218. 10.1016/j.foreco.2005.06.002. 357  
358
26. Sönmez, T. Diameter at breast height-crown diameter prediction models for picea orientalis. *African J. Agric. Res.* **2009**, *4*, 215–219. 359  
360
27. Wang, Y.; Hyypä, J.; Liang, X.; Kaartinen, H.; Yu, X.; Lindberg, E.; Holmgren, J.; Qin, Y.; Mallet, C.; Ferraz, A.; et al. International Benchmarking of the Individual Tree Detection Methods for Modeling 3-D Canopy Structure for Silviculture and Forest Ecology Using Airborne Laser Scanning. *IEEE Trans. Geosci. Remote Sens.* **2016**, *54*, 5011–5027. 10.1109/TGRS.2016.2543225. 361  
362  
363  
364
28. Grznárová, A.; Mokroš, M.; Surový, P.; Slavík, M.; Pondelík, M.; Merganič, J. THE CROWN DIAMETER ESTIMATION FROM FIXED WING TYPE OF UAV IMAGERY. **2019**. 10.5194/isprs-archives-XLII-2-W13-337-2019. 365  
366  
367
29. Nevalainen, O.; Honkavaara, E.; Tuominen, S.; Viljanen, N.; Hakala, T.; Yu, X.; Hyypä, J.; Saari, H.; Pölönen, I.; Imai, N.N.; et al. Individual tree detection and classification with UAV-Based photogrammetric point clouds and hyperspectral imaging. *Remote Sens.* **2017**, *9*. 10.3390/rs9030185. 368  
369  
370
30. Jeronimo, S.M.A.; Kane, V.R.; Churchill, D.J.; McGaughey, R.J.; Franklin, J.F. Applying LiDAR individual tree detection to management of structurally diverse forest landscapes. *J. For.* **2018**, *116*, 336–346. 371  
372  
373  
374