

**Česká zemědělská univerzita v Praze**

Fakulta lesnická a dřevařská

Katedra hospodářské úpravy lesů



**Fakulta lesnická  
a dřevařská**

**Produktivita dřevin na geografickém celku využitím moderních materiálů**

**DPZ pro modelování lesa**

**Woody species productivity on a geographical unit using modern remote  
sensing materials for forest modelling**

Dizertačná práce

Autor: Ing. Zlatica Melichová

Školitel: doc. Ing. Peter Surový, PhD.

Študijný program: Lesní inženýrství

Prílohy: 0

V Praze

2024

# Zadanie

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta lesnická a dřevařská

## ZADÁNÍ DISERTAČNÍ PRÁCE

Autorka práce:	Ing. Zlatica Melichová
Studijní program:	Lesní inženýrství
Obor:	Hospodářská úprava lesa
Vedoucí práce:	doc. Ing. Peter Surový, PhD.
Garantující pracoviště:	Katedra hospodářské úpravy lesů a DPZ
Jazyk práce:	Čeština
Název práce:	<b>Produktivita dřevin na geografickém celku využitím moderních materiálů DPZ pro modelování lesa</b>
Název anglicky:	<b>Woody species productivity on a geographical unit using modern remote sensing materials for forest modeling</b>
Cíle práce:	Hlavním cílem práce je navrhnout a popsat metodu na zpracování leteckých lidarových dat a jejich využití pro odhad růstové dynamiky.  Práce se zaměří na detekci změn v lesních ekosystémech z bitemporálních dat, kvantifikaci úbytku a přírůstu pomocí lidarové technologie. Výstupem by měly být podklady pro tvorbu růstových modelů a postupy pro odhad produktivity v daném území.
Metodika:	Oblast výzkumu bude Národní park České Švýcarsko, které se nachází v severní části České republiky. K řešení bude v práci využívána kombinace dat z laserového skeneru z roku 2019 a historická lidarová data vyhotovená v NPČŠ v roce 2005 Technickou univerzitou Dresden.  Práce se zaměří na spracování a analýzu v jednotlivých letech, navrhne a popíše postupy spracování včetně filtrace, klasifikace bodových mračen, rasterizace a tvorbu normalizovaného modelu výšek (anglicky Canopy Height Model CHM).  Budou popsány postupy pro odhad a delineaaci holin.  Budou popsány postupy a metody pro odhad růstové dynamiky, možnosti použití těchto dat pro tvorbu růstových modelů a odhad produktivity stanoviště bonity.  Výsledky budou publikovány ve vědeckých publikacích
Doporučený rozsah práce:	70-80 stran
Klíčová slova:	produktivita, DPZ, bitemporální laserové data, růstové modely, bonita

### Doporučené zdroje informací:

1. Bollandsås, Ole Martin, Timothy G. Gregoire, Erik Næsset, and Bernt Håvard Øyen. 2013. "Detection of Biomass Change in a Norwegian Mountain Forest Area Using Small Footprint Airborne Laser Scanner Data." *Statistical Methods and Applications* 22(1): 113–29.
2. Gobakken, Terje, Lauri Korhonen, and Erik Næsset. 2013. "Laser-Assisted Selection of Field Plots for an Area-Based Forest Inventory." *Silva Fennica* 47(5): 1–20.
3. Hawbaker, Todd J. et al. 2009. "Improved Estimates of Forest Vegetation Structure and Biomass with a LiDAR-Optimized Sampling Design." *Journal of Geophysical Research: Biogeosciences* 114(3): 1–11.
4. Maltamo, Matti et al. 2007. "Experiences and Possibilities of ALS Based Forest Inventory in Finland." *ISPRS Workshop on Laser Scanning 2007 and SilviLaser 2007* (May 2014): 270–79. [http://www.isprs.org/proceedings/XXXVI/3-W52/final\\_papers/Maltamo\\_2007\\_keynote.pdf](http://www.isprs.org/proceedings/XXXVI/3-W52/final_papers/Maltamo_2007_keynote.pdf).
5. Næsset, Erik, and Terje Gobakken. 2005. "Estimating Forest Growth Using Canopy Metrics Derived from Airborne Laser Scanner Data." *Remote Sensing of Environment* 96(3–4): 453–65.
6. Noordermeer, Lennart et al. 2019. "Comparing the Accuracies of Forest Attributes Predicted from Airborne Laser Scanning and Digital Aerial Photogrammetry in Operational Forest Inventories." *Remote Sensing of Environment* 226(April): 26–37. [https://www.sciencedirect.com/science/article/pii/S0034425719301178?dgcid=rss\\_sd\\_all](https://www.sciencedirect.com/science/article/pii/S0034425719301178?dgcid=rss_sd_all).
7. Noordermeer, Lennart, Ole Martin Bollandsås, Terje Gobakken, and Erik Næsset. 2018. "Direct and Indirect Site Index Determination for Norway Spruce and Scots Pine Using Bitemporal Airborne Laser Scanner Data." *Forest Ecology and Management* 428(June): 104–14. <https://doi.org/10.1016/j.foreco.2018.06.041>.
8. Tompalski, P., Coops, N. C., White, J. C., & Wulder, M. A. (2016). Enhancing forest growth and yield predictions with airborne laser scanning data: Increasing spatial detail and optimizing yield curve selection through template matching. *Forests*, 7(11), 1–20. <https://doi.org/10.3390/f7110255>
9. Tompalski, Piotr et al. 2018. "Combining Multi-Date Airborne Laser Scanning and Digital Aerial Photogrammetric Data for Forest Growth and Yield Modelling." *Remote Sensing* 10(2): 1–21.
10. Tompalski, Piotr, Nicholas C. Coops, Joanne C. White, Michael A. Wulder, and Paul D. Pickell. 2015. "Estimating Forest Site Productivity Using Airborne Laser Scanning Data and Landsat Time Series." *Canadian Journal of Remote Sensing* 41 (3): 232–45. <https://doi.org/10.1080/07038992.2015.1068686>.
11. White, J. C., Stepper, C., Tompalski, P., Coops, N. C., & Wulder, M. A. (2015). Comparing ALS and image-based point cloud metrics and modelled forest inventory attributes in a complex coastal forest environment. *Forests*, 6(10), 3704–3732. <https://doi.org/10.3390/f6103704>
12. Yu, X. et al. 2008. "Obtaining Plotwise Mean Height and Volume Growth in Boreal Forests Using Multi-Temporal Laser Surveys and Various Change Detection Techniques." *International Journal of Remote Sensing* 29(5): 1367–86.

Předběžný termín: 2023/24 ZS - FLD - SDZ

## Anotace

Táto dizertačná práca skúma možnosti využitia dát diaľkového prieskumu Zeme (DPZ) pre odhad charakteristík a parametrov rastových modelov lesných porastov, stanovenie a odhad ich dynamiky a popis dôležitých parametrov ako je napríklad bonita porastu. Práca využíva dáta leteckého laserového skenovania a to viac-intervalové, konkrétne boli použité dáta z bezzásahovej oblasti národného parku České Švýcarsko z roku 2005 poskytnuté Technickou Univerzitou v Drážďanoch a dáta získané na katedre hospodárskej úpravy lesa, fakulty lesníckej a drevárskej, Českej Zemědělskej Univerzity v Prahe z roku 2019.

Dizertácia je postavená na štyroch vedeckých prácach. Prvá práca (Melichová et al., 2023) popisuje kvantifikáciu úbytku lesa pomocou moderných gisových metód, konkrétne automatickej úpravy komplexných polygónov holín z rozdielových skenov. Druhá práca (Surový & Melichová, 2023) popisuje možnosti využitia metód strojového učenia a pokročilých štatistických metód pre odhad zásob lesných porastov.

Tretia práca (Melichová et al. 2024) by sa dala považovať za kľúčovú pre dizertačnú tému, popisuje možnosti využitia bitemporálneho lidarového skenu pre odhad parametrov rastovej funkcie a pomocou metód strojového učenia popisuje možnosti odhadu bonity daného porastu. Práca porovnáva možnosti odhadu relatívnej aj absolútnej bonity a porovnáva presnosť a správnosť pri použití len metrík laserového skenu, a v kombinácii metrík a veku porastu. Vek sa ukazuje ako parameter významne ovplyvňujúci kvalitu modelu, ale aj keď dnes nie je priamo z dát DPZ dostupný, opakovaným dlhodobým skenovaním je možné ho získať napríklad metódou popísanou v článku 1.

Posledný článok (Surový et al., v tisku) je technická štúdia využitia nízkonákladových skenerov pre pozemné dáta.

Celkovo táto dizertačná práca významne prispieva k štúdiám možnosti využitia laserových dát ako alternatívy alebo doplnku pozemných meraní, umožňujúc tak do budúcnosti získavať väčšie množstvo a kvalitnejších dát a prispieť tak nielen k informácii o stave lesa ale aj o jeho vývoji, raste, produkcii či stave ohrozenia a tým pomôcť lepším rozhodnutiam o hospodárení prípadne o jeho ochrane.

**Kľúčové slová:** rastové modely, bitemporálny laserový sken, letecké laserové skenovanie.

## **Annotation**

This dissertation thesis explores the possibilities of using remote sensing data (RS) to estimate characteristics and parameters of forest stand growth models, determine and estimate their dynamics, and describe important parameters such as site index. The work utilizes airborne laser scanning data, specifically bitemporal data, with data from the untouched area of České Švýcarsko National Park in 2005 provided by the Technical University of Dresden and data obtained from the Department of Forest Management, Faculty of Forestry and Wood Sciences, Czech University of Life Sciences in Prague in 2019.

The dissertation thesis is based on four scientific papers. The first paper (Melichová et al., 2023) describes the quantification of forest loss using modern GIS methods, specifically the automatic updating of complex clear-cut polygons from difference scans. The second paper (Surový & Melichová, 2023) describes the possibilities of using machine learning methods and advanced statistical methods to estimate forest stand resources.

The third paper (Melichová et al., 2024) could be considered crucial to the dissertation topic, describing the possibilities of using bitemporal lidar scanning to estimate growth function parameters. It also explores the use of machine learning methods to estimate site index. The paper compares the possibilities of estimating relative and absolute site index and compares the accuracy and correctness when using only lidar metrics and in combination with stand age. Age proves to be a significantly influential parameter in the model's quality, and although it is not directly available from RS data today, repeated long-term scanning can obtain it, for example, using the method described in paper 1.

The last paper (Surový et al., in press) is a technical study of the use of low-cost scanners for ground data.

Overall, this dissertation significantly contributes to the studies of the potential use of lidar data as an alternative or complement to ground measurements, enabling the acquisition of larger quantities and higher-quality data in the future. It contributes not only to information about the state of the forest but also its development, growth, production, or threat status, thereby aiding better decisions regarding management or conservation.

**Keywords:** growth models, bitemporal laser scan, airborne laser scanning.



## **Prehlásenie**

Prehlasujem, že som dizertačnú prácu *Produktivita dřevin na geografickém celku využitím moderních materiálů DPZ pro modelování lesa* spracovala samostatne pod vedením Doc. Ing. Petra Surového, PhD. a všetky použité pramene uvádzam v zozname použitým zdrojov. Som si vedomá, že zverejnením dizertačnej práce súhlasím s jej zverejnením podľa zákona č. 111/1998 Zb. o vysokých školách v platnom znení, a to bez ohľadu na výsledok jej obhajoby.

V Praze dňa 30.1.2024

Ing. Zlatica Melichová

## **Pod'akovanie**

V prvom rade by som chcela poďakovať svojmu školiteľovi, váženému doc. Ing. Petrovi Surovému, PhD., za odborné vedenie počas celej doby štúdia, trpezlivosť a cenné rady. Ďalej by som chcela poďakovať všetkým kolegom, s ktorými som mala tú česť pracovať, za ich podnetné pripomienky. V neposlednej rade moje poďakovanie patrí rodine a priateľom, za ich podporu počas celého štúdia.

## Obsah

1	Úvod.....	14
1.1	Rastová dynamika .....	15
1.1.1	Empirické modely.....	16
1.1.2	Štrukturálne modely.....	17
1.1.3	Procesné modely .....	17
1.2	Časovo- hierarchická úroveň.....	18
1.3	Hierarchicko- priestorová úroveň .....	20
2	Ciele práce .....	22
3	Klasické meranie stromových charakteristík.....	22
3.1	Hrúbka stromu.....	22
3.2	Výška stromu .....	22
3.3	Zisťovanie hrúbkového prírastku .....	23
3.4	Senzory diaľkového prieskumu Zeme .....	23
3.4.1	Pasívne systémy .....	24
3.4.2	Aktívne systémy .....	25
3.4.3	Elektromagnetické žiarenie.....	26
4	LiDAR .....	28
4.1	Vývoj technológie .....	28
4.2	Letecké laserové skenovanie.....	29
4.3	Konštrukcia laserového skeneru .....	30
4.3.1	Laserová jednotka .....	30
4.3.2	Skener .....	30
4.3.3	Kontrolná jednotka .....	32
4.3.4	GPS .....	33
4.3.5	Navigačná jednotka.....	34
4.4	Výstup z leteckého laserového skenovania.....	35
4.5	Využitie LiDARU v lesníctve .....	36

4.5.1	INDIVIDUAL TREE DETECTION .....	37
4.5.2	AREA-BASED APPROACH.....	38
5	Metodika .....	39
5.1	Národný park České Švýcarsko .....	39
5.2	Zonácia Národného parku .....	41
5.3	Geomorfologické členenie .....	42
5.4	Pedologické charakteristika územia.....	42
5.5	Hydrológia.....	43
5.6	Floristicko-fytogeografická charakteristika .....	44
6	Charakteristika prirodzenej lesnej vegetácie .....	45
6.1	Letecké laserové dáta z roku 2005 .....	46
6.2	Letecké laserové dáta z roku 2019 .....	49
6.3	Softwarové spracovanie dát .....	50
6.3.1	PDAL - Knižnica abstrakcie bodových dát .....	51
6.3.2	Filtovanie, klasifikácia, rasterizácia bodového mračna a generovanie DTM 52	
6.4	Detekcia holín .....	52
6.5	Využitia metód strojového učenia a pokročilých štatistických metód pre odhad zásob lesných porastov .....	54
6.6	Detekcia prírastku .....	55
6.6.1	Štatistické modelovanie a tvorba modelov na základe strojového učenia... 57	
6.7	Odhad hrúbky stromu za pomoci terestriálnych laserových skenerov.....	57
7	Výsledky .....	60
7.1	Automatická detekcia holín odvodená z lidarových dát .....	60
7.2	Využitia metód strojového učenia a pokročilých štatistických metód pre odhad zásob lesných porastov .....	76
7.3	Odhad prírastku a bonity z bitemporálnych lidarových dát .....	86

7.4	Odhad hrúbky stromu za pomoci terestriálneho pozemného a mobilného laserového skeneru.....	113
8	Diskusia .....	126
9	Záver .....	130
	Referencie .....	131

## Zoznam obrázkov

Obrázok 1: Klasifikácia modelov lesa na základe metód modelovania (Fabrika & Pretzsch, 2011) .....	16
Obrázok 2: Klasifikácia modelov podľa časovo-hierarchickej úrovne (Fabrika & Pretzsch, 2011) .....	19
Obrázok 3: Klasifikácia modelov podľa hierarchicko-priestorovej úrovne (Fabrika & Pretzsch, 2011).....	21
Obrázok 4: Pasívny systém diaľkového prieskumu Zeme (vľavo), aktívny systém diaľkového prieskumu Zeme (vpravo).....	24
Obrázok 5: Elektromagnetická vlna (Mason & Schmetz, 1992).....	27
Obrázok 6: Elektromagnetické spektrum (Eckerstorfer & Bühler, 2015) .....	28
Obrázok 7: Druhy skenovacieho mechanizmu (Wujanz, 2016) .....	30
Obrázok 8: Schéma znázorňujúca základné princípy fungovania a hlavné systémové komponenty technológie ALS (Fernandez-Diaz et al., 2014) .....	31
Obrázok 9: LiDAR s diskretným návratom a plným priebehom vlny (Daly, 2011) .....	32
Obrázok 10: Druhy stop podľa typu skeneru (Fernandez-Diaz et al., 2014).....	32
Obrázok 11: Princíp určovania polohy pomocou globálneho systému určovania polohy (GPS) .....	33
Obrázok 12: IMU s 2 typmi senzorov .....	34
Obrázok 13: IMU s 3 typmi senzorov .....	35
Obrázok 14: Mračno bodov z leteckého laserového skenovania.....	36
Obrázok 15: Výsledok detekcie individuálnych stromov (ITD) založený na údajoch ALS v kombinácii s prístupom local maxima. Čierne kríže označujú jednotlivé stromy.(Fatehi et al., 2017)..	38
Obrázok 16: Schéma The Area-Based Approach (White et al. 2013).....	39
Obrázok 17: Národný park České Švýcarsko ( <a href="https://www.region-ceskesvycarsko.cz/oblasti/ceske-svycarsko/">https://www.region-ceskesvycarsko.cz/oblasti/ceske-svycarsko/</a> ).....	40
Obrázok 18: Hydrologická sieť NPČŠ .....	44
Obrázok 19: TopoSys, ukážka konštrukcie skeneru s optickými vláknami (Wehr & Lohr, 1999) .....	46
Obrázok 20: TopoSys Falcon II (Dolanský, 2004).....	46
Obrázok 21: Vzor skenovania systému TopoSys ALS (Wehr & Lohr, 1999) .....	47

Obrázok 22: Trajektória letu v NPČŠ v roku 2005 (Trommler, 2007).....	48
Obrázok 23: Skener Leica ALS70-CM.....	49
Obrázok 24: Povrchová stopa skenovacieho systému Leica ALS70 (Leica ASL70-CM)	49
Obrázok 25: Zobrazenie ako pracuje nástroj Minus(Minus (Spatial Analyst), ArcGIS Pro 3.2) .....	53
Obrázok 26: Polygón holiny klasifikovaný za pomoci LLS.....	54
Obrázok 27: Príklady použitia algoritmu RANSAC v rôznych situáciách. Horný riadok ukazuje použitie RANSAC pri neúplnom skenovaní kmeňa; dolný riadok ukazuje použitie RANSAC pri rôznych metódach skenovania. ....	58

### **Zoznam tabuliek**

Tabuľka 1: Zonácia NPČŠ.....	41
Tabuľka 2: Špecifikácia zberu údajov z roku 2005 .....	47
Tabuľka 3: Špecifikácia zberu údajov z roku 2019 .....	50
Tabuľka 4: Ukážka metadát prekonvertovaných pomocou TopoSys Converter V.2.2.0 ..	50

### **Zoznam Grafov**

Graf 2: Zobrazujúci úhrn zrážok v NPČŠ.....	41
---	----

## Zoznam použitých symbolov a skratiek

3D	three-dimensional	trojdimenzionálny
ABA	Area Based Approach	plošný prístup
ALS	Airborne Laser Scanning	letecké laserové skenovanie
CAD	Computer-Aided Design	počítačom podporované projektovanie
DBH	Diameter at breast height	prsna hrúbka
dGPS	Differential Global Positioning System	diferenciálny globálny pozičný systém
DPZ		dial'kový priezok Zeme
DTM	Digital Terrain Models	digitálny model terénu
FOV	Field of View	uhol záberu
GIS	Geographic Information System	geografický informačný systém
GPS	Global Positioning System	globálny pozičný systém
CHKO		chránená krajinná oblasť
CHM	Canopy Height Model	model výšok korún
IDT	Individual Tree Detection	Individuálna detekcia stromov
IMU	Inertial Measurement Unit	inerciálna meračská jednotka
INS	Inertial Navigation System	inerciálneho navigačného systému
InSAR	Interferometric synthetic aperture radar	Interferometrický radar so syntetickou aperturou
kHz		kilohertz
LHP		lesný hospodársky plán
LIDAR	Light Detection And Ranging	detekovanie a meranie svetla
LLS		letecké laserové skenovanie
L-systémy		Lindenmayerove systémy



MAE	mean absolute error	stredná absolútna chyba
MAX		maximum
MIN		minimum
NIR	Near Infrared	blízke infračervené
NP		národný park
NPČŠ		Národný park České Švýcarsko
PCT90		deväťdesiaty percentil
PDAL	Point Data Abstraction Library	knižnica abstrakcie bodových dát
POS	Position and orientation systém	poziční a orientační systém
PPS	Puls per second	pulz za sekundu
RADAR	Radio Detection and Ranging	rádiové rozpoznávaní a zaměřování
RANSAC	Random sample consensus	Náhodný výberový konsenzus
RMSE	Root Mean Squared Error	střední kvadratická chyba
RS	remote sensing	dial'kový priezkum Zeme
SAR	Synthetic aperture radar	
SONAR	Sound Navigation And Ranging	zvuková navigácia a meranie
STD	Standard Deviation	smerodajná odchýlka
SUM		suma
TLS	Terrestrial Laser Scannig	pozemné laserové skenovanie
VIS	vissible	viditeľné

## 1 Úvod

Dynamika a rast lesa predstavujú neoddeliteľnú súčasť hospodárenia s lesom. Pre dosiahnutie trvalej udržateľnosti lesného hospodárenia je nevyhnutné disponovať informáciami o súčasnom stave a budúcom raste lesa (Riofrío et al., 2023). Od prvých inventarizácií založených na trvalých plochách a ich opakovaných meraniach sa technológia odhadu rastu lesa/stromov vyvíjala prostredníctvom dendrochronologických metód až po sofistikované 3D techniky založené na meraniach architektúry (Antonelli, 1992, Perttunen, 2008). Trojrozmerné údaje z diaľkového prieskumu Zeme, či už ide o dáta z laserového skenovania alebo digitálnej fotogrametrie, poskytujú čoraz presnejšie informácie o stavbe porastu (Tompalski et al., 2018). V súčasnosti sa však na odhad taxačných veličín a monitorovanie lesa využíva prevažne národná inventarizácia lesov, ktorej priestorové pokrytie nie je dostatočné vzhľadom na veľkosť a počet inventarizačných plôch a na rozlohu lesa (Avitabile & Camia, 2018). Hodnotenie rastu z diaľkového prieskumu je možné prostredníctvom opakovaných meraní (v odlišných časových intervaloch) rovnakého stromu alebo porastu, pričom rozdiely v meraniach priamo odhadujú rast. Predovšetkým v chránených oblastiach, kde sa zásahy minimalizujú a dochádza k prirodzenému vývoju lesa, môže byť diaľkový prieskum Zeme využitý na odhad rastovej dynamiky lesa. História tejto problematiky zaznamenala príspevky mnohých autorov (Næsset & Gobakken, 2005, X. Yu et al., 2008, Tompalski et al., 2016); ktorí zhodnotili využitie diaľkového prieskumu Zeme na odhadovanie rôznych charakteristík porastu. Dáta z opakovaného leteckého laserového skenovania sa dajú využiť nielen na hodnotenie rastu ale aj na odhad produkčnej schopnosti stanovišťa tzv. bonity (Noordermeer et al., 2020, Socha et al., 2020)

Rastové a produkčné modely sú rozhodujúcim nástrojom pre hodnotenie rastu a udržateľnosti produkcie. Odhad bonity je podstatnou zložkou týchto modelov na hodnotenie kvality stanovišťa (Riofrío et al., 2023). V Českej republike sa na hodnotenie kvality stanovišťa používa bonita. V súčasnosti je najpoužívanejšou veličinou výška porastu, ktorá vychádza z priemernej alebo dominantnej výšky porastu (Weiskittel et al., 2011). Bonita môže byť absolútna alebo relatívna. Relatívna bonita vyjadruje relatívnu kvalitu stanovišťa, zatiaľ čo absolútna bonita priamo udáva hodnoty priemerných alebo stredných výšok porastov, zvyčajne v 100 rokoch. Bonita je priamym indikátorom kvality

porastu na danom stanovišti, určuje jeho produkciu, rýchlosť rastu či kvalitu očakávanej produkcie zo sortimentačného hľadiska. Dynamika a rast stromov a porastov je popisovaná v čase pomocou rastových modelov, u ktorých je práve bonita ich hlavným indikátorom, napríklad vo forme asymptoty, to jest hornej hodnoty, ktorú je schopný daný jedinec alebo porast dosiahnuť. Veda, ktorá sa zaoberá popisom, či už matematickým alebo slovným alebo algoritmickým, toho ako sa stromy a porasty vyvíjajú je rastová dynamika (z anglického forest growth), a je obsahom výuky predmetov ako modelovanie rastu lesa, náuka o produkcii lesa a podobne.


### **1.1 Rastová dynamika**

Dynamika rastu lesa popisuje, ako sa jednotlivé stromy a les ako celok v priebehu času menia a vyvíjajú. Dynamiku rastu lesa ovplyvňuje množstvo faktorov, vrátane podmienok prostredia, druhovej skladby, disturbancií a spôsobov hospodárenia. Zachytenie a porozumenie týmto zmenám je dôležité pre vývoj porastov, spôsob ich následného obhospodarovania a taktiež ich adaptácie na klimatickú zmenu. V prípade lesa, kedy sa naše rozhodnutia odzrkadlia o niekoľko generácii neskôr, možnosť otestovať si apriori správnosť navrhovaného postupu je výhodou. Jednou z možností je simulácia, kedy s počítačovým modelom nahrádzame reálny systém a tak vieme vidieť správanie reálneho systému v budúcnosti. Simulátory lesných ekosystémov sú počítačové programy, ktoré napodobňujú chovanie lesných ekosystémov. Tieto simulátory umožňujú modelovať rôzne typy lesov, vrátane rôznych druhov drevín, vekových tried a štruktúr lesa a taktiež by mali vedieť reagovať na podmienky prostredia, hospodárske zásahy a sociálne faktory.

Výstupy z týchto simulátorov nezahŕňajú len produkciu, ale aj štruktúru lesa, biodiverzitu, biomasy, náklady a výnosy. Stochastické prvky by mali byť tiež zakomponované do modelu, na rozdiel od rastových tabuliek, ktoré sú okrem iných nevýhod deterministické, to jest neudávajú možný rozptyl predpovedí, a môžu hlavne pre laika pôsobiť zavádzajúco.

Modely lesa sú rozdelené do niekoľkých skupín, kvôli lepšej orientácii. Prvou a základnou klasifikáciou je rozdelenie modelov podľa Metódy modelovania. Toto rozdelenie je na základe používaných algoritmov a na základe toho ako pristupujeme k modelovaniu. Klasifikáciu zobrazuje trojuholník modelov (Obrázok 1). Na vrchole tohto trojuholníka sa nachádzajú Empirické modely. Tieto modely sú najviac agregované a konštruované na základe štatistických vzťahov odvodených z empirických meraní. Na jednej strane sú

štrukturálne modely, na modelovanie morfológie stromov na základe topológie orgánov a architektúry rastliny. Na druhej strane sú procesné modely, ktoré sa sústreďujú na fyziologické procesy ako sú fotosyntéza, respirácia a alokácia. Strany trojuholníka popisujú hybridné modely, ktoré kombinujú dva rôzne modelovacie prístupy. Semi-empirické modely sú príkladom hybridných modelov, ktoré sú bližšie k empirickým modelom. Ďalším príkladom sú funkčno-štrukturálne modely, ktoré kombinujú procesné a štrukturálne modelovanie a sú bližšie k štrukturálnym modelom.



Obrázok 1: Klasifikácia modelov lesa na základe metód modelovania (Fabrika & Pretzsch, 2011)

### 1.1.1 Empirické modely

Empirické modely (známe aj ako biometrické, štatistické alebo korelačné modely) sa zameriavajú na zmenu biometrických veličín v čase. Tieto modely sú odvodené z empirických dát a štatistických metód, čo znamená, že sú platné len pre základný súbor dát, z ktorého boli odvodené. Ak sa chcú použiť na iný súbor dát, je potrebné ich kalibrovať a upraviť parametre modelu.

Empirické modely využívajú ako prvotný vstup stavové premenné ako hrúbku a výšku stromov, kruhovú základňu a zásobu porastu. Môžu sa tiež zaoberať modelovaním biomasy a alokáciou prvkov. Tieto premenné sú odvodené zo vzťahov k prvotným výstupom modelu.

Empirické modely môžu zahrňovať modelovanie tvaru kmeňa a koruny stromov, štruktúry porastu, konkurencie medzi stromami, odumierania stromov a rastu stromov. V závislosti na charaktere modelu sa vyberajú príslušné skupiny submodelov. Výsledkom sú aktualizované stavové premenné lesného porastu. Tieto modely sa podľa úrovne modelovania ďalej delia na stromové, frekvenčné a porastové, semi- empirické.

### **1.1.2 Štrukturálne modely**

Štrukturálne modely (tiež známe ako morfológické modely) sa zameriavajú na vývoj morfológie jednotlivých stromov na základe topológie orgánov a architektúry stromu. Tieto modely používajú matematický aparát odvodený z fraktálnej geometrie a sú založené na rekurzívnom nahrádzaní reťazcov, ktoré je popísané rastovými gramatikami. Rastové gramatiky definujú morfológické rysy rastliny, ktoré sú generované prostredníctvom takzvaných Lindenmayerových systémov (L-systémov). Tieto modely môžu byť deterministické, stochastické, kontextovo-senzitívne, parametrické a ďalšie, v závislosti od ich charakteru. Štrukturálne modely sa snažia odvodiť štruktúru stromu, zahrňujúc formovanie kmeňa, vetiev, listov a plodov. Ich výstupy sú morfológické rysy stromov, ktoré neskôr môžu slúžiť na odvodenie biometrických stavových premenných, biomasy a obsahu chemických prvkov. Tieto modely môžu byť využívané na modelovanie jednotlivých stromov alebo populácií stromov s konkurenčnými vzťahmi medzi jednotlivými jedincami.

Existuje niekoľko nástrojov a systémov pre štrukturálne modelovanie rastlín, vrátane univerzálnych modelovacích nástrojov na L-systémy, ako aj špecializovaných modelov, ktoré zahrňajú črty procesných modelov. Tieto modely môžu byť využité na generovanie realistických vizuálnych reprezentácií rastlín pre rôzne účely vrátane systémov typu CAD a virtuálnej reality (Fabrika & Pretzsch, 2011).

### **1.1.3 Procesné modely**

Procesné modely sa v súčasnosti rýchlo rozvíjajú a majú viacero ekvivalentných názvov, vrátane ekofyziologických modelov, biochemických modelov, biogeochemických modelov, mechanistických modelov, kauzálnych modelov a "flux" modelov. Tieto modely sa zameriavajú na modelovanie kauzálnych procesov v lesných ekosystémoch na úrovni fyziológie stromov.

Procesné modely sa spoliehajú menej na empirické údaje a štatistické vzťahy a viac na ekofyziologické poznanie biologických procesov. Experimenty pre tieto modely sú finančne náročnejšie a komplexnejšie, zahrňajúce podrobné merania klimatických

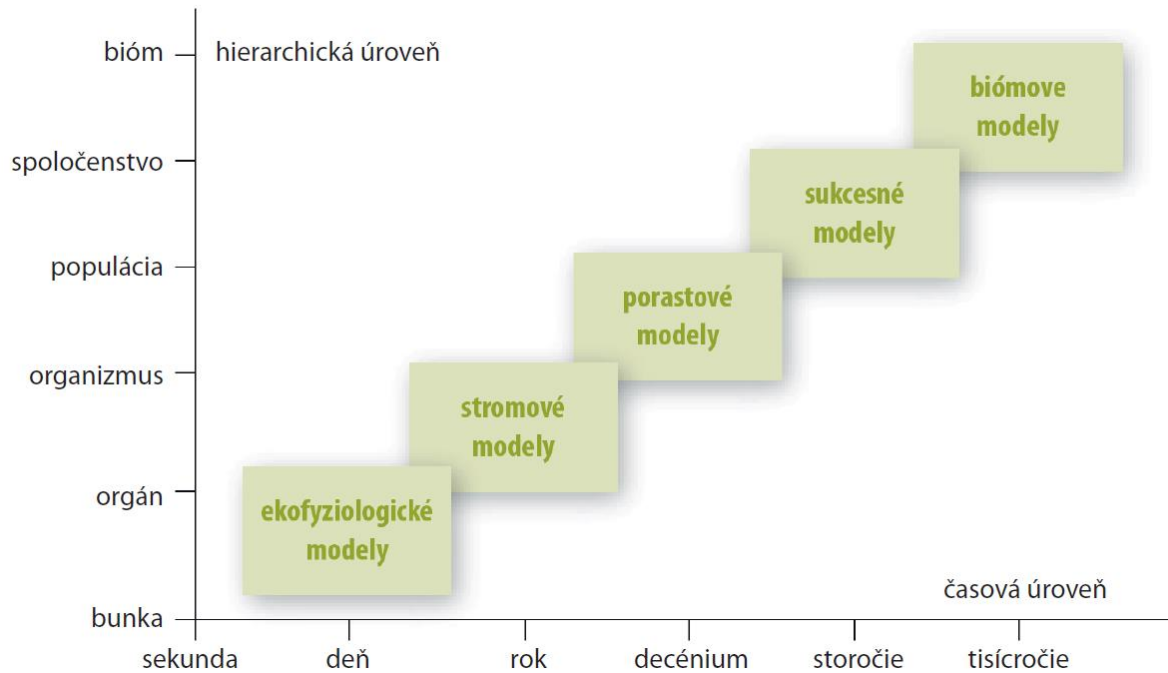
podmienok, pôdy, kolobehu vody, svetelného žiarenia, vrátane fotosyntézy, respirácie a iných procesov. Tieto merania sú často priebežné počas celej sezóny.

Procesné modely sa zameriavajú na modelovanie rôznych biologických procesov vrátane absorpcie svetla, intercepce, evapotranspirácie, fotosyntézy, respirácie, alokácie, senescencie a ďalších. Ich výstupy zahŕňajú alokáciu uhlíka v biomase stromov a primárnu produkciu biomasy.

Kalibrácia procesných modelov je často náročná a vyžaduje hľadanie správnych systémových parametrov, ktoré môžu zahŕňať rôzne ekofyziologické veličiny alebo konštanty. Tieto modely majú všeobecnejšiu platnosť a môžu byť aplikované na rôzne úrovne ekosystémov. Existuje mnoho rôznych modelov s rôznymi prístupmi a zameraním na konkrétne aspekty ekofyziológie stromov a lesných ekosystémov (Fabrika & Pretzsch, 2011).

## **1.2 Časovo- hierarchická úroveň**

V lesnom prostredí prebiehajú procesy od bunky až po celú biosféru. Hierarchické úrovne v živote lesa nie sú definované len priestorovo, ale aj časovo. Zmeny na rôznych úrovniach sú časovo ovplyvnené pozíciou v hierarchii, a to od buniek až po biosféru a trvajú sekundy až tisícročia (Obrázok 2). Taktiež nadradené úrovne ovplyvňujú tie podradené pomocou riadiacich parametrov a podradené úrovne zase ovplyvňujú nadradené pomocou signálov. Pre každú hierarchickú úroveň sa vytvárajú špeciálne modely (Fabrika & Pretzsch, 2011).



Obrázok 2: Klasifikácia modelov podľa časovo-hierarchickej úrovne (Fabrika & Pretzsch, 2011)

**Ekofyziologické modely** popisujú rastové zmeny na úrovni orgánov prostredníctvom kauzálnych procesov, ako je fotosyntéza, dýchanie a alokácia. Tieto modely sa zaoberajú procesnými vzťahmi a minimalizujú použitie štatistických vzťahov alebo ich vôbec nepoužívajú. Často modelujú procesy s denným intervalom. Táto skupina modelov je najpočetnejšia a najrozmanitejšia.

**Stromové modely** pri modelovaní rozkladajú porast na jednotlivé stromy a simulujú ich vzájomné interakcie ako priestorovo-časový systém. Tieto modely sa zväčša zameriavajú na štatisticky odvodený systém rovníc na riadenie rastového správania jednotlivých stromov v závislosti na ich rastovom nastavení. Z časového hľadiska typicky pracujú s minimálnym modelovým intervalom jedného roku.

**Porastové modely** sú v podstate najstaršími metódami modelovania vývoja porastov, ktoré sa zameriavajú na sumárne a priemerné porastové veličiny. Tieto modely v podstate zahŕňajú všetky typy rastových tabuliek. Avšak za skutočne vhodné a presnejšie modely sa považujú tie, ktoré obsahujú dobre formulované biometrické zákony prostredníctvom matematických rovníc a sú implementovateľné do počítača. Existujú špecifické prípady, ktoré predstavujú prechod medzi modelmi zameranými na stromy a porasty. Sú to modely

s výpoveďou o frekvencii počtu kmeňov (napríklad v hrúbkových stupňoch). Modely sú riešené na báze diferenciálnych rovníc, regresných modelov prepisu rozdelenia početností alebo stochastických evolučných modelov. Základnou jednotkou týchto frekvenčných modelov je skupina stromov, ktoré patria do rovnakej zatriedovanej kategórie (napríklad hrúbkový stupeň alebo veková trieda). Vzhľadom k tomu, že porastové modely simulujú zmeny celej populácie (porastu) alebo zmeny v distribúcii početnosti, časovým horizontom, ktorý je modelovo relevantný, je obdobie desiatich rokov (decénium) alebo dokonca päť rokov.

**Sukcesné modely** sa zaoberajú dynamikou rastu v rozsiahlych systémoch, ktoré sa skladajú z mozaikovitých a čiastkových plošných jednotiek. Ich základnou modelovou jednotkou je spoločenstvo stromov. Tieto modely sú zamerané predovšetkým na predpovedanie dlhodobej sukcesie neobhospodarovaných lesných porastov a na dôsledky zmenených rastových podmienok v produkcii biomasy. Z časového hľadiska sa zaujímajú o zmeny, ktoré sa vzťahujú na stáročia. Medzi predstaviteľov týchto modelov patria tzv. "gap" alebo "patch" modely.

**Biómové modely** sú podobne zamerané ako sukcesné modely, ale zameriavajú sa na celé krajiny alebo dokonca kontinenty a z časového hľadiska môžu analyzovať zmeny pre väčšie časové intervaly.

Pri modelovaní je potrebné si uvedomiť cieľ modelovania, potrebnú úroveň priestorového rozsahu, potrebný časový interval modelovania ako aj úroveň detailnosti existujúcich vstupných údajov a úroveň detailnosti požadovaných výstupných údajov. Je dôležité použiť vhodný model pre danú hierarchickú úroveň. Môže sa stať, že pre konkrétnu úroveň neexistujú modely a v tom prípade je možné použiť vyššiu alebo nižšiu hierarchickú úroveň. Presun z vyššej úrovne na nižšiu sa nazýva "downscale" a opačný presun "upscale" (Fabrika & Pretzsch, 2011).

### **1.3 Hierarchicko- priestorová úroveň**

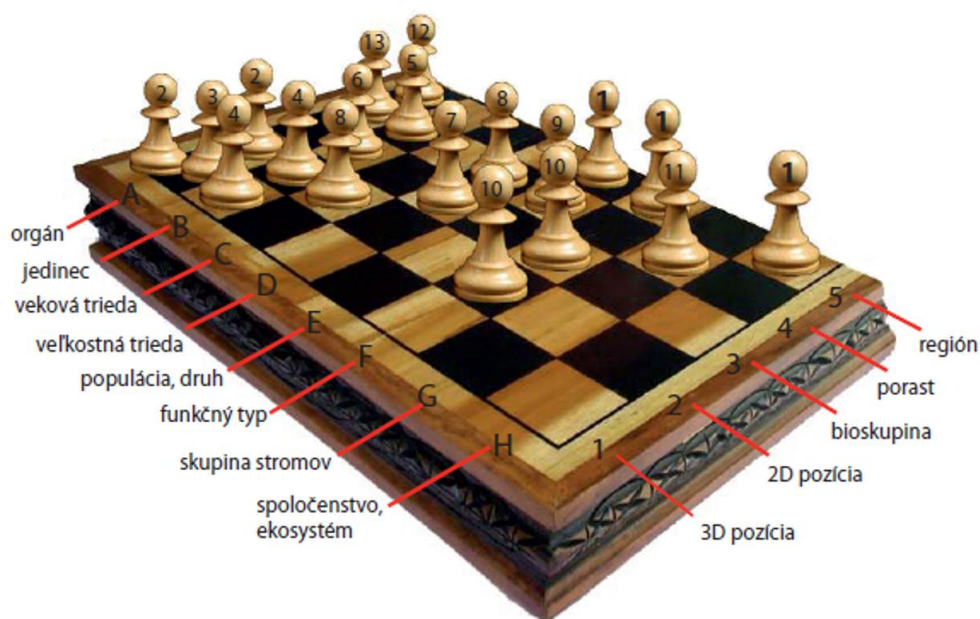
Klasifikácia modelov v tejto úrovni sa zameriava na sledovanie chovania lesných ekosystémov pod vplyvom klimatických zmien alebo po rôznych prirodzených a umelých narušeníach. Tieto modely sa využívajú na nájdenie vhodnej varianty obhospodarovania lesa v súvislosti s udrжанím trvalosti produkcie lesa a plnenia mimoprodukčných funkcií lesa. Hierarchické úrovne môžeme rozdeliť do ôsmich kategórií a to: orgán, jedinec,



veľkostná trieda, veková trieda, populácia alebo druh, funkčný typ, bioskupina stromov („patch“ alebo „gap“) a spoločenstvo, respektíve ekosystém alebo bióm. Priestorové úrovne môžeme rozdeliť do piatich kategórií, kde sa jedná o trojrozmernú pozíciu, dvojrozmernú pozíciu, bioskupinu, porast alebo región.

Trojrozmerná poloha vyžaduje informácie o presnom umiestnení jednotky v trojrozmernom priestore, definovaný súradnicami x, y, z. V dvojrozmernom priestore stačí informácia o horizontálnom umiestnení (súradnice x, y). Pri ostatných úrovniach je dostačujúce identifikovať príslušnosť jednotky k bioskupine, porastu alebo regiónu.

Na obrázku 3 je zobrazených všetkých 13 modelov do tzv. šachovnice modelov. Každá kategória predstavuje špecifický typ modelu so štandardnou polohou v tejto šachovnici. Niektoré typy modelov majú viacero štandardných polôh, ktoré závisí od použitia (Fabrika & Pretzsch, 2011).



Obrázok 3: Klasifikácia modelov podľa hierarchicko-priestorovej úrovne (Fabrika & Pretzsch, 2011)

## **2 Ciele práce**

Hlavným cieľom práce je navrhnúť a popísať metódu na spracovanie leteckých lidarových dát s ich využitie pre odhad rastovej dynamiky.

Práca je zameraná na zisťovanie zmien v lesných ekosystémoch na základe bitemporálnych dát, kvantifikáciu úbytku a prírastkov pomocou technológie LiDAR. Výstupy by mali poskytnúť podklady pre tvorbu rastových modelov a postupy pre odhad produktivity v danom území. V práci sú spracované dve hypotézy:

1. Letecké laserové snímkovanie je možné využiť pre odhad rastovej dynamiky na veľkom územnom celku (celoplošne).
2. Dáta z výškového prírastku je možné využiť na odhad bonity.

## **3 Klasické meranie stromových charakteristík**

K tradičným spôsobom získavania porastových veličín z lesa patria nástroje ako priemerky, výškomery a pásma. Pomocou nich ešte stále získavame veličiny ako výška stromu, hrúbka a ďalšie, ktoré potom slúžia na výpočet ďalších charakteristík a používajú sa taktiež na overenie presnosti výsledkov získaných pomocou diaľkového prieskumu Zeme.

### **3.1 Hrúbka stromu**

Medzi základnú dendrometrickú veličinu patrí hrúbka priečného prierezu kmeňa, čo je vzdialenosť dvoch rovnobežných dotyčníc vedených protiľahlými bodmi obvodu prierezu. Tradičné metódy merania hrúbky stromov zahŕňajú použitie priemerky alebo obvodového pásma pripevneného kolmo na os kmeňa, štandardne vo výške 1,3 m nad päťou kmeňa. Hrúbka sa môže merať aj v iných výškach napríklad pri päte kmeňa alebo v rôznych percentách výšky kmeňa. Pri meraní hrúbky stromu za použitia priemerky je potrebné dodržiavať pravidlá merania ako je správne umiestnenie priemerky, správna výška a aby sa priemerka dotýkala kmeňa v troch bodoch (Kuželka et al., 2014).

### **3.2 Výška stromu**

Výška stromu sa meria za pomoci výškomeru, ktorý slúži na nepriame meranie výšok. Nepriame meranie výšok je založené na dvoch princípoch, geometrickom a trigonometrickom. Výškomery, ktoré sa používajú na meranie využívajú dve technológie a to ultrazvukové meranie alebo laserové meranie v závislosti od hustoty porastu. Výška

stromu sa nemeria na každom strome v poraste, ale meria sa výška reprezentatívnej vzorky stromov. Dôvodom je menšia variabilita výšky stromov v rámci porastu a dreviny v porovnaní s hrúbkou stromu (Sun et al., 2020).


### **3.3 Zisťovanie hrúbkového prírastku**

Hrúbkový prírastok definujeme ako rozdiel medzi hrúbkou na konci a na začiatku sledovanej periódy dĺžky  $n$ . Na zisťovanie prírastku existujú deštrukčné a nedeštrukčné metódy. V prípade dlhodobého sledovania postačuje meranie pomocou milimetrovej priemerky alebo obvodového pásma. V prípade, že chceme mať informácie o prírastku v priebehu vegetačného obdobia je vhodné použiť dendrometre. Ak by sme chceli zisťovať prírastok do minulosti, využijeme analýzu letokruhov, ktoré sú viditeľné na vývrtoch získaných pomocou Preslerového nebožieca (Kuželka et al., 2014).

### **3.4 Senzory diaľkového prieskumu Zeme**

Alternatívnou metódou získavania dát o lese a v podstate alternatívou merania lesa sú dáta diaľkového prieskumu Zeme. Dáta z rôznych nosičov ako sú satelity, lietadla, drony či pozemne nosiče je možné v princípe získavať dvoma spôsobmi a to za pomoci merania aktívneho alebo pasívneho signálu.

Existujú dve základné klasifikácie diaľkového prieskumu Zeme na základe zdroja signálu, ktorý využívajú na skúmanie objektu: aktívne a pasívne (Van Genchten, 2008) (Obrázok 4). Pasívne aj aktívne systémy merajú množstvo svetla odrazeného od objektov transformáciou svetelného signálu na elektrický výstup. Oba typy senzorov zaznamenávajú intenzitu signálu v rámci intervalu vlnovej dĺžky, známej ako „pásma“ alebo „kanál“, špecifickej šírke v rámci elektromagnetického spektra (Turner et al., 2003). Spektrálne rozlíšenie senzoru je definované šírkou pásiem v elektromagnetickom spektre, ktoré dokáže detegovať. Táto charakteristika určuje schopnosť senzoru identifikovať spektrálne rozdiely. Každý objekt má odlišný spektrálny podpis, založený na tom, ako odráža alebo vyžaruje elektromagnetické žiarenie. Vyšší počet pásiem z užšou spektrálnou šírkou (Turner et al., 2003).



Obrázok 4: Pasívny systém diaľkového prieskumu Zeme (vľavo), aktívny systém diaľkového prieskumu Zeme (vpravo)

### 3.4.1 Pasívne systémy

Pasívne systémy nevyžarujú vlastné žiarenie, ale závisia na zachytávaní žiarenia vyžarovaného daným objektom alebo na detekcii odrazeného žiarenia od tohto objektu (Mason & Schmetz, 1992). Najbežnejším typom žiarenia, ktoré detegujú pasívne senzory je viditeľné svetlo (Van Genchten, 2008). Pri tomto type zberu dát, optická oblasť zahŕňa predovšetkým viditeľné žiarenie, infračervené žiarenie, tepelné infračervené a mikrovlnné žiarenie (Zuzulová et al., 2020). Avšak negatívum tejto technológie je že, diaľkový prieskum Zeme pasívnymi senzormi je ovplyvnený premenlivými podmienkami na oblohe. To zahŕňa znečistenie, prach, uhol slnečného zenitu a oblaky, ktoré predstavujú premenlivé osvetlenie naprieč krajinou a tak isto môžu ovplyvňujú vlnovú dĺžku dopadajúceho svetla. Uhly dopadu žiarenia sa menia počas dňa aj počas ročných období (Fitzgerald, 2010). Pasívne senzory môžeme taktiež rozdeliť na priame a nepriame, podľa toho, či využívajú odrazené slnečné žiarenie alebo využívajú vlastné vyžarovanie objektu (Di & Yu, 2023). Pasívne senzory sa využívajú na monitorovanie krajinného pokryvu a monitoring využívania pôdy. Údaje popisujúce odrazenú alebo emitovanú energiu zo zemského povrchu sú štatisticky alebo vizuálne analyzované na identifikáciu objektov (Turner et al., 2003). Medzi prístroje s pasívnym systémom zaraďujeme nasledovné (Zuzulová et al., 2020):

1. Akcelerometer: prístroj na meranie zrýchlenia: dva typy - jeden pre translačné zrýchlenie a druhý pre uhlovú akceleráciu objektov.

2. Hyperspektrálny rádiometer: pokročilý multispektrálny senzor detegujúci stovky úzkych spektrálnych pásiem, ktorý umožňuje jemné rozlišovanie cieľov na základe ich spektrálnej odozvy.
3. Obrazový rádiometer: je schopný skenovať s cieľom poskytnúť dvojrozmernú sústavu pixelov na tvorbu obrazu, pričom skenovanie sa vykonáva mechanicky alebo elektronicky.
4. Rádiometer: kvantitatívne meria intenzitu elektromagnetického žiarenia v špecifických pásmach, často identifikovaných podľa časti spektra, ktorú pokrývajú.
5. Sounder: Meria vertikálne rozloženie atmosférických parametrov, ako je teplota, tlak a zloženie, pomocou multispektrálnych informácií.
6. Spektrometer: deteguje, meria a analyzuje spektrálny obsah dopadajúceho elektromagnetického žiarenia, zvyčajne pomocou mriežok alebo hranolov na rozptýlenie žiarenia na spektrálne rozlišovanie.
7. Spektrorádiometer: meria intenzitu žiarenia vo viacerých pásmach vlnovej dĺžky (multispektrálne), často s vysokým spektrálnym rozlíšením, určené na diaľkové snímanie špecifických geofyzikálnych parametrov.
8. SONAR: (Sound Navigation And Ranging) SONAR je v tomto prípade pasívna technológia, ktorá len prína ale nevysiela zvukové signály vysielané inými objektami. Táto metóda sa využíva hlavne na detekciu akustických signálov v podmorskom prostredí (Maranda, 2008).

### 3.4.2 Aktívne systémy

Na rozdiel od pasívnych systémov, aktívne systémy nepoužívajú prirodzený zdroj žiarenia, ale sami vysielajú žiarenie. Toto vyslané žiarenie je zachytené a zaznamenané po odraze od objektu alebo prostredia. Aktívne systémy zvyčajne operujú v oblasti rádiového a mikrovlnného žiarenia. Medzi typy používaného žiarenia patrí svetlo, ultrazvuk alebo röntgen. Pri týchto technikách sa vyžaduje laserový vysielateľ a prijímač (Zuzulová et al., 2020, Van Genchten, 2008). Štruktúra vegetácie a nadmorská výška terénu sa často meria pomocou aktívnych senzorov. Systémy detekcie svetla a merania svetla (LiDAR) pracujú vo viditeľnom až blízkom infračervenom pásme, zatiaľ čo rádiová detekcia a meranie vzdialenosti (RADAR) vyžaruje žiarenie o dlhších mikrovlnných vlnových dĺžkach. Charakteristiky energetických impulzov ovplyvňujú intenzitu a pravdepodobnosť spätných signálov. Sila a čas spätného signálu sa používajú na opis fyzikálnych vlastností objektov,

ktoré sa sledujú diaľkovým snímaním (Turner et al., 2003). Medzi prístroje s aktívnym systémom zaradíme nasledovné:

1. RADAR: (Ratio Detection and Ranging) je systém založený na vysielaní dlhých mikrovlnných signálov atmosférou a následnom zachytávaní odrazeného žiarenia od terénu. Radarový systém obvykle pracuje v oblasti vysokofrekvenčnej alebo mikrovlnnej časti vysokofrekvenčného spektra a slúži k určovaniu polohy a/alebo pohybu objektov (Zuzulová et al., 2020) (Sardar, 1997).
2. SAR: (Synthetic Aperture Radars) je typ radaru obsahuje softvérové postupy na senzore na matematické zlepšenie priestorového rozlíšenia a na zvládnutie viacerých snímok toho istého objektu (Hay, 2000).
3. InSAR: (Interferometric Synthetic Aperture Radar (InSAR) InSAR využíva dva alebo viac radarových snímok so syntetickou clonou (SAR) určitej oblasti na analýzu a získanie informácií o topografii a deformačných vzoroch krajiny (Lu et al., 2007).
4. SONAR: (Sound Navigation And Ranging) atívny SONAR vysielá do vody akustický signál alebo pulz zvuku. Pokiaľ je v dráhe nejaký predmet, zvuk sa odrazí od predmetu a vráti sa ako ozvena späť do sonarového prevodníka. Stanovením doby medzi zvukovým impulzom a jeho príjmom môže prevodník určiť vzdialenosť a veľkosť objektu (<https://oceanservice.noaa.gov/facts/sonar.html>).
5. LiDAR: (Light Detection and Ranging) tento systém meria čas, ktorý lúče svetla potrebujú k dopadu na predmet alebo povrch a návratu späť do laserového skeneru. Táto technológia bude podrobnejšie popísaná nižšie.

### 3.4.3 Elektromagnetické žiarenie


V predchádzajúcom opise jednotlivých technológií bolo spomenuté elektromagnetické žiarenie. Elektromagnetické žiarenie je druh energie, ktorá sa šíri priestorom vo forme vln (Obrázok 5). Skladá sa z kmitajúcich elektrických a magnetických polí, ktoré sú kolmé na seba navzájom a na smer pohybu žiarenia (Verhoeven, 2018). Rýchlosť pohybu cez priestor sa rovná rýchlosti svetla ( $2.998 \times 10^8$  m/s) (Percuoco, 2014).

Elektromagnetické žiarenie vyžarujú všetky objekty nad absolútnou nulou (0 K,  $-273$  °C). Stefan-Boltzmanov zákon opisuje celkové množstvo energie, ktoré objekty vyžarujú:

$$M = \sigma T^4$$


kde  $M$  je celkový výstup (emitovaný žiarivý tok na jednotku plochy) z povrchu materiálu ( $\text{W m}^{-2}$ ),  $\sigma$  je Stefanova–Boltzmanova konštanta ( $5,6 \times 10^{-8} \text{ W m}^{-2} \text{ K}^{-4}$ ) a  $T$  je absolútna teplota emitujúceho materiálu (K). Celkové množstvo energie vyžarovanej objektom preto rýchlo rastie s teplotou (Hay, 2000).

Elektromagnetické vlny vznikajú kmitaním nabitých častíc a môžu sa šíriť atmosférou aj vesmírnym vákuom. Tieto vlny majú rôzne vlnové dĺžky, pričom kratšie vlnové dĺžky zodpovedajú vyšším frekvenciám. Rádiové, mikrovlnné a infračervené vlny majú dlhšie vlnové dĺžky, zatiaľ čo ultrafialové, röntgenové a gama žiarenie majú oveľa kratšie vlnové dĺžky. Viditeľné svetlo patrí do stredu spektra. Iba tento úzky rozsah energie je detekovateľný ľudským okom, zatiaľ čo na detekciu ostatných foriem elektromagnetického žiarenia sú potrebné špecializované prístroje (Obrázok 6).



Obrázok 5: Elektromagnetická vlna (Mason & Schmetz, 1992)

Svetlo možno merať vo viditeľnom (VIS, približne 400-700 nm) a blízkom infračervenom rozsahu (NIR, približne 700-2500 nm). Odrazové vlastnosti rastlín, ktoré sú určené ich absorpciou, transmitanciou alebo odrazivosťou svetla, súvisia s fyziologickým stavom rastlín (Erdle et al., 2011).



Obrázek 6: Elektromagnetické spektrum (Eckerstorfer & Bühler, 2015)

## 4 LiDAR

Pojem LiDAR pochádza z anglického termínu (Light Detection and Ranging). Okrem tohto termínu, môžeme používať aj ekvivalentné pojmy ako laserový skener alebo pomenovanie technológie ako laserové skenovanie (Dolanský, 2004). Technológia LiDAR (Light Detection And Ranging) určuje vzdialenosť medzi pozemnými objektmi a senzormi, ktoré merajú čas, za ktorý sa vyslaný impulz energie vráti do snímača (Meng et al., 2010). Ide o technológiu, ktorá poskytuje trojrozmerné informácie o objektoch na zemskom povrchu. Tieto informácie sa potom môžu použiť na vytvorenie digitálneho modelu povrchu a terénu, a to aj v oblastiach s hustým lesným porastom (Căţeanu & Ciubotaru, 2021). V závislosti od metódy zberu údajov možno laserové skenovanie rozdeliť do dvoch kategórií:

1. Pozemné laserové skenovanie, ktoré sa delí na statické (Olofsson et al., 2014) a (Liang et al., 2016) a mobilné (Liang et al., 2018) a (Pierzchała et al., 2018).
2. Letecké laserové skenovanie sa využíva na všetkých troch úrovniach (nízko, stredne a vysoko letiace platformy). Na satelitnej úrovni je to pomocou satelitu GEDI (Saarela et al., 2018).

### 4.1 Vývoj technológie

Vývoj LiDAR-u prešiel od vynálezu Rubínového lasera Theodorom Maimanom v roku 1960 štyrmi etapami. Laserové diaľkomery, ktoré sa pôvodne používali na vojenské účely, sa postupne zmenšili, zvýšila sa ich účinnosť a rozšírili sa v rôznych oblastiach. Problémy, ako napríklad nízka presnosť za každého počasia a možné poškodenie očí, však podnietili vývoj tretej generácie laserových diaľkomerov. Táto generácia rieši problémy s bezpečnosťou očí, elektronickou technológiou, spotrebou energie a presnosťou. Výskum a aplikácie sa rozšírili po celom svete, pričom rôzne laserové diaľkomerné systémy sa



zameriavajú na jednozväzkové, dvojrozmerné a trojrozmerné merania. Kľúčové technologické pokroky v optických systémoch a spracovaní signálu v 80. rokoch 20. storočia viedli k vyspelým produktom v 90. rokoch. Trh s hardvérom a dátovými produktmi LiDAR zaznamenal značný rast. Okrem toho technológia LiDAR našla uplatnenie v bezpilotných lietadlách (UAV) a autonómnom riadení (Wang et al., 2020, Nelson, 2013).

## **4.2 Letecké laserové skenovanie**

Z technológii, ktoré používajú LiDAR je najviac rozšírené letecké laserové skenovanie pre svoju dostupnosť a veľkosť záujmového územia, ktoré je v rozsahu tisícov hektárov. Keďže typická oblasť lesného podniku alebo celku sa pohybuje v rozsahu 10 tisíc hektárov, dokáže táto technológia efektívne pokryť túto oblasť počas jedného letu (Surový & Kuželka, 2019).

Pri leteckom laserovom skenovaní je najčastejšie systém LiDAR nesený lietadlom s pevným krídlom, rotorovým alebo ultraľahkým lietadlom. Pri leteckom laserovom skenovaní sa pulz svetla o známom smere emitovaný skenerom najskôr dostane na povrch (napríklad listy korún stromov) a časť fotónov, z ktorých je lúč svetla tvorený sa odrazí naspäť. Zariadenie emitujúce laser rozpozná tieto odrazené fotóny a vypočíta čas medzi počiatočnou emisiou a ich návratom. Následne zariadenie vypočíta polohou odkiaľ tento odraz prišiel, za pomoci známych veličín ako je rýchlosť pulzu (rýchlosť svetla), miesto emisie, smer pulzu a doba letu pulzu. Avšak nejedná sa len o jeden odraz od povrchu korún. Svetelné pulzy často produkujú viacnásobné ozveny, pretože nie všetky fotóny sú odrazené od prvého povrchu kontaktu. Niektoré prechádzajú ďalej, až pokiaľ sa neodrazia od ďalšieho povrchu. Prvá ozvena pochádza od nevyššieho povrchu zatiaľ čo posledná pochádza od terénu. V hustých tropických lesoch môže byť posledná ozvena taktiež vnútra koruny. Zariadenie okrem polohy zaznamenáva aj intenzitu navráteného pulzu. Moderné lidarové systémy dokážu emitovať až 800 000 pulzov za sekundu. Každý pulz môže mať viacero ozvien a pre každú ozvenu je zaznamenaná poloha. Ako už bolo spomenuté, výsledkom je mračno bodov s X, Y, Z súradnicami (Lundemo et al., 2017).

Hustota bodových mračien z leteckého laserového skenovania závisí od:

1. Rýchlosti merania skenera a skenovacieho mechanizmu
2. Výšky letu a rýchlosti
3. Šírky a prekryvu letových línií

### 4.3 Konštrukcia laserového skeneru


Laserové skener sa skladá z laserovej diaľkomernej a skenovacej jednotky, polohového a orientačného systému (POS), ktorý pozostáva z integrovaného diferenciálneho globálneho polohovacieho systému GPS (DGPS) a inerciálnej meracej jednotky (IMU) (Habib et al., 2010, Sopchaki & Sampaio, 2016, Wehr & Lohr, 1999).

#### 4.3.1 Laserová jednotka


Medzi hlavné súčasti laserovej jednotky patrí laser, vysielač a prijímač optika, detektor signálu, zosilňovač, počítač času a potrebné elektronické komponenty (Baltsavias, 1999).

#### 4.3.2 Skener

Letecké laserové skenovanie sa vykonáva v dvoch dimenziách, bez ohľadu na platformu, ktorá je použitá k získaniu dát. Prvý rozmer je v smere letu lietadla a je dosiahnutý pohybom lietadla smerom dopredu. Druhý rozmer, všeobecne kolmý ku smeru letu, sa získava pomocou skenovacieho mechanizmu, zvyčajne oscilačným zrkadlom, rotačným zrkadlom, Palmerovým (eliptickým) skenerom alebo skenerom s optickými vláknami (Obrázok 7). Celkový uhol záberu v priečnom smere potom určuje šírku záberu, čiže, zorné pole (FOV). V praxi býva zorné pole zvyčajne v rozsahu 20-30°, avšak existujú aj systémy s FOV 70° (Dolanský, 2004) (Obrázok 8).



Obrázok 7: Druhy skenovacieho mechanizmu (Wujanz, 2016)




Obrázok 8: Schéma znázorňujúca základné princípy fungovania a hlavné systémové komponenty technológie ALS (Fernandez-Diaz et al., 2014)

Druhy skenovacieho mechanizmu (Wujanz, 2016)

Lidarové skenery, ktoré sa v súčasnosti používajú môžeme rozdeliť na druhy a to: Discrete Return alebo tzv. full-waveform (Obrázok 9). Z hľadiska aplikácie to vedie odlišnému počtu dosahov zaznamenaných pre každý emitovaný laserový impulz a následným podstatným rozdielom v spracovaní a analýze (Ussyshkin & Theriault, 2011).


Prvé Discrete Return senzory umožňovali zaznamenávať zvyčajne jeden diskretný návrat buď prvý alebo posledný, alebo dva návraty prvý a posledný. To sa zmenilo v roku 2000, keď sa zaviedli viacnásobné návraty, zvyčajne 3-5 na jeden impulz (Salas, 2021).

Senzory full-waveform, zaznamenávajú celý profil odrazeného signálu v pevne stanovených časových intervaloch typicky 1 ns (odpovedá 15 cm vzdálenosti) (Ussyshkin a Theriault, 2011).



Obrázok 9: LiDAR s diskretným návratom a plným priebehom vlny (Daly, 2011)

Kombinácia pohybu lietadla a typu skenovacieho mechanizmu s zanecháva na zemi rôzne typy stop. Obrázok 10a znázorňuje príklad pozemnej dráhy skeneru s oscilačným zrkadlom, obrázok 10b znázorňuje príklad pozemnej dráhy skeneru s rotačným zrkadlom, obrázok 10c znázorňuje príklad pozemnej dráhy eliptického skeneru a obrázok 10d skener s optickým vláknom. (Fernandez-Diaz et al., 2014).



Obrázok 10: Druhy stop podľa typu skeneru (Fernandez-Diaz et al., 2014)

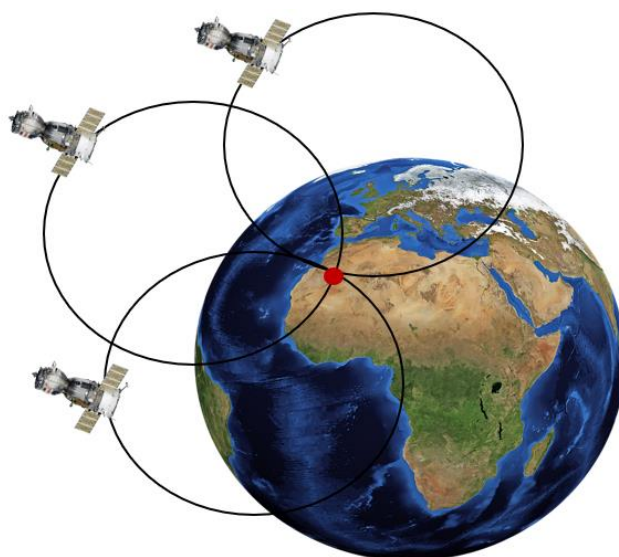
### 4.3.3 Kontrolná jednotka

Skener a laserová jednotka navzájom komunikujú prostredníctvom (riadiacej) jednotky. Vnútorne hodiny tejto jednotky sa periodicky synchronizujú s hodinami prístroja GPS

pomocou signálu PPS (puls per second) generovaného vnútornými hodinami prijímača GPS. Všetky namerané údaje (uhol a dĺžka) sú spojené s časom interných hodín a ďalej sa synchronizujú pomocou PPS s časom GPS (Dolanský, 2004).

#### 4.3.4 GPS

GPS je navigačný systém, ktorý využíva 32 funkčných satelitov na obežnej dráhe okolo Zeme. Každý satelit je vybavený atómovými hodinami. Satelity najskôr nastaví hodiny v prijímači GPS synchronizáciou s atómovými hodinami v satelite. Satelity potom neustále posielajú informácie (rýchlosťou svetla) o presnom čase do prijímača GPS. Porovnaním času daného satelitom a času v prijímači GPS sa vypočíta čas prenosu signálu. Vzdialenosť k satelitu sa potom vypočíta vynásobením času prenosu signálu rýchlosťou svetla., Presnú polohu možno určiť trigonometricky (Obrázok 11). Pri meraniach zo štyroch satelitov sa robí aj odhad nadmorskej výšky. Signál z družíc je ovplyvnený atmosférou a odrazom od rôznych prekážok pred dosiahnutím prijímača. Tak vzniká chyba vo vypočítanej vzdialenosti k satelitu, a tým aj vo vypočítanej polohe. Túto chybu je možné znížiť použitím diferenciálneho GPS (dGPS). Na dosiahnutie dGPS, porovnávajú stacionárne prijímače umiestnené na známych miestach na Zemi svoju fixnú polohu s polohou danou satelitmi. Korekčné signály sú odosielané prostredníctvom rádiových vln z týchto fixných prijímačov cez diferenciálny prijímač k prijímaču GPS (Larsson, 2003).



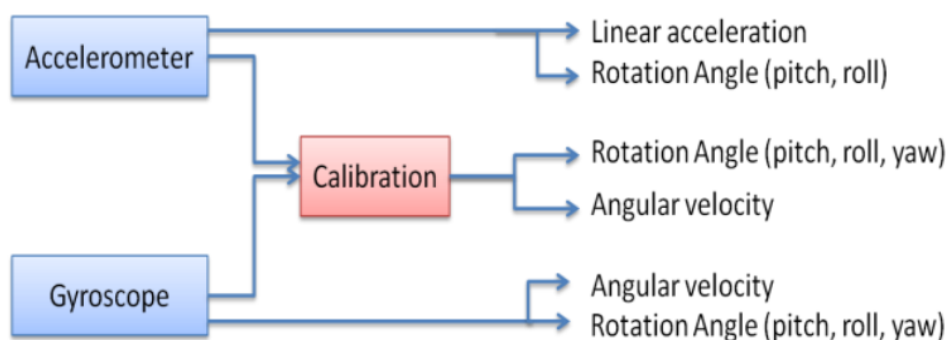
Obrázok 11: Princíp určovania polohy pomocou globálneho systému určovania polohy (GPS)

### 4.3.5 Navigačná jednotka

IMU ( Inertial Measurement Unit) technológia sa používa na meranie rýchlosti, orientácie a gravitačnej sily. Staršia technológia pozostáva z dvoch typov senzorov, akcelerometrov a gyroskopov. Akcelerometer sa používa na meranie zotrvačného zrýchlenia. Zatiaľ čo gyroskop meria uhlové pootočenie. Neskôr sa technológia IMU rozvinula o ďalší typ snímača – magnetometer. Magnetometer meria magnetický smer ložiska, takže môže zlepšiť údaje gyroskopu (Ahmad et al., 2013).

#### 4.3.5.1 IMU s dvoma typmi senzorov

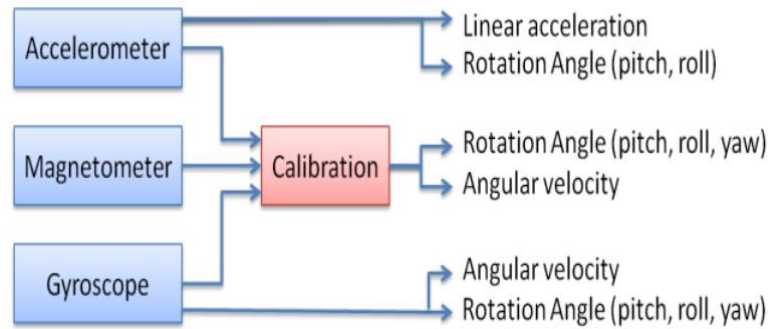
Tento typ pozostáva z gyroskopu a akcelerometra. Každý snímač má zvyčajne dva až tri stupne voľnosti definované pre osi x, y a z. Hodnoty zrýchlenia získané z akcelerometra a uhlová rýchlosť z gyroskopu sú uchovávané oddelene. Uhly je možné merať z oboch snímačov, takže obe dáta môžu byť kalibrované na získanie presnejších údajov (Ahmad et al., 2013).



Obrázok 12: IMU s 2 typmi senzorov

#### 4.3.5.2 IMU s tromi typmi senzorov

Tento typ IMU sa skladá z akcelerometra, gyroskopu a magnetometra . Magnetometer sa používa na meranie uhla natočenia, takže môže byť kalibrovaný na dáta gyroskopu. Tento typ snímača je vhodný pre výpočet dynamickej orientácie v krátkom a dlhom období. Nevýhodou používania magnetometra je, že pokiaľ sa IMU používa v prostredí, ktoré je obklopené feromagnetickým kovom, môže byť meranie ovplyvnené narušením magnetického poľa (Ahmad et al., 2013).



Obrázok 13: IMU s 3 typmi senzorov

#### 4.4 Výstup z leteckého laserového skenovania

Výstupom z laserového skenovania je bodové mračno, ktorého každý bod obsahuje 3D súradnice X,Y,Z a intenzitu (Obrázok 14). Bodové mračno v takomto stave je potrebné vyfiltrovať tj. zbaviť chybných bodov a klasifikovať, to znamená body zaradiť do jednotlivých tried ako zem, vegetácia, cesty a podobne (Roberts et al., 2019). Po týchto krokoch z neho môžeme počítať digitálne modely. V lidarových dátach sú pozemnými bodmi (ground) merania z holého zemskeho terénu a sú najnižšími povrchovými prvkami v danej oblasti. Non- ground body sú merania z objektov nad terénom ako sú napríklad budovy, stromy, kroviny atď. Na ich oddelenie existuje široká škála filtrov a klasifikačných algoritmov. Dôležitá hľadiska pri výbere pozemného filtra zahŕňujú počet a typ návratu, ktoré sa majú použiť pre pozemné filtrovanie, kroky preprocessingu, formát vstupných dát, iteračné charakteristiky a ďalšie (Meng et al., 2010):

Pozemné filtre môžeme rozdeliť do niekoľkých kategórii:


1. Segmentation- and Cluster-based Filters
2. Morphological Filters
3. Directional Scanning Filters
4. Contour-Based Filters
5. TIN-Based Filters

Pre správnu identifikáciu pozemných bodov je dôležité porozumieť ich fyzikálnym charakteristikám, ktoré ich odlišujú od tých non-ground. Zemský povrch môže byť



rozdelený do štyroch kategórii na základe ich fyzikálnych charakteristík (Meng et al., 2010):

1. Najnižšia nadmorská výška
2. Strmosť zemskeho povrchu
3. Rozdiel nadmorskej výšky zemskeho povrchu
4. Homogenita zemskeho povrchu



Obrázok 14: Mračno bodov z leteckého laserového skenovania

Ako už bolo spomenuté, niektoré impulzy z leteckého laserového skenovania sa odrazia od korunovej vrstvy a niektoré prenikajú nižšie (Stereńczak, 2011). Digitálny model terénu (DTM) je reprezentácia povrchu terénu (Forkuo, 2008). Digitálny model povrchu (DSM) predstavuje digitálny model terénu obohatený o prírodné a umelé objekty. Rozdielom medzi tými dvomi digitálnymi modelmi dostaneme výškový model korún (CHM) (Morsdorf et al., 2009).

#### 4.5 Využitie LiDARU v lesníctve

Prvé začiatky využívania dát z leteckého laserového skenovania v lesníctve sa datujú do roku 1976, kedy v Rusku (Solodukhin et al., 1979) na zoľatej breze a smreku vytvárali jednoduché laserové profily. Neskôr dospeli k záveru, že takýto prístroj zo zvýšeným



výkonom by mohol byť využiteľný na meranie lesných zápojov (Nelson, 2013). V osemdesiatych rokoch potom začali pokusy s implementáciou laserového skenovania pri inventarizácii lesa, kedy sa už nemerala len výška stromu ale boli prvé pokusy o odhad zásoby porastu, kruhovej základne alebo biomasy (Næsset, 2002, Nilsson, 1996, Næsset, 1997). V tomto období nastal aj komerčný rozvoj lidarového merania vďaka integrácii Globálneho Pozičného Systému (GPS) a Inerciálneho Navigačného Systému (INS) v deväťdesiatych rokoch a tým sa uľahčilo presné pozícionie skenera (Steinvall et al., 2001).

Postupne sa LiDAR začal častejšie používať pri meraní lesa a vegetačnej štruktúry na ekologické účely, pri rozlišovaní druhov drevín až po používanie pri inventarizácii lesa (Lundemo et al., 2017).

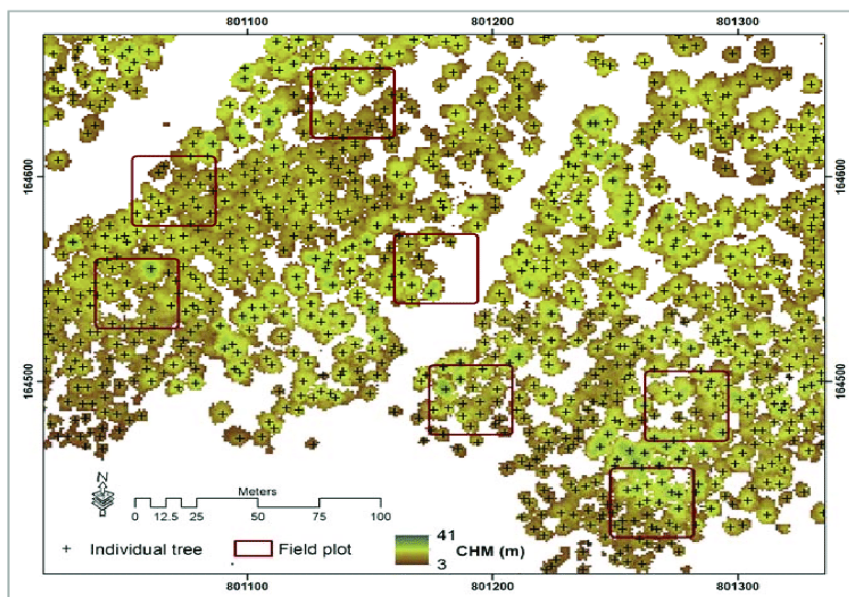
Na odvodenie informácií o lesoch sa najbežnejšie používajú dva prístupy: the Area-based approach (ABA) a individual tree detection (ITD) (Xiaowei Yu et al., 2010). Metóda ITD vyžaduje lokalizovanie vrcholu stromu a vymedzenie koruny. Následne sú atribúty odvodené z vlastností bodového mračna v každej vymedzenej korune. Nevýhodou tejto metódy je, že je náchylná na chyby spôsobené nepresnosťou pri identifikácii stromov a následnej nad alebo pod segmentácii korún. Pri Area-Based Approach porastové atribúty sú odhadované pre bunku mriežky, založené na metrikách sumarizujúcich rozdelenie bodového mračna vo vnútri bunky. Bunka mriežky je teda základnou jednotkou a ponúka viac priestorových detailov ako inventarizácia založená na polygóne. Taktiež sa vyhýba systematickým chybám často zavádzaným pri ITD ako opísali (Tompalski et al., 2018).

#### **4.5.1 INDIVIDUAL TREE DETECTION**

Hlavným problémom ITD je segmentácia stromov, krok k rozdeleniu celkových bodov do zoskupení, ktoré predstavujú jednotlivé stromy. Existujú dve hlavné stratégie segmentácie stromov a to rastrové a bodové. Pri rastrovej stratégii sa kovertuje 3D model na Canopy Height Model (CHMs), a potom sa detekujú vrcholy stromov pomocou 2D image processing zobrazovacích techník ako sú local maxima, region growing a watershed alebo inverse watershed. Pri druhej stratégii sa segmentujú stromy priamo na základe 3D bodov technikami ako rule-based distance a height thresholding, voxel-based, graph-based a kernel-based method (Xiao et al. 2019).

Pri používaní Individual Tree Detection (ITD) (Obrázok 15) prístup je dôležitý krok už spomínaná segmentácia, pri ktorej boli skúmané rôzne metodiky. Autori (Xiao et al., 2019)

vo svojom článku hodnotili algoritmus stredného posunu pre segmentáciu leteckých lidarových dat a detekciu vrcholu stromu na validáciu výsledkov segmentácia. Implementovali algoritmus z hľadiska Kernel shape, adaptability a váhy. Výsledky z troch rôznych datasetov ukázali, že crown- shaped kernel neustále ukazuje o 7% lepšie výsledky ako ostatné varianty.



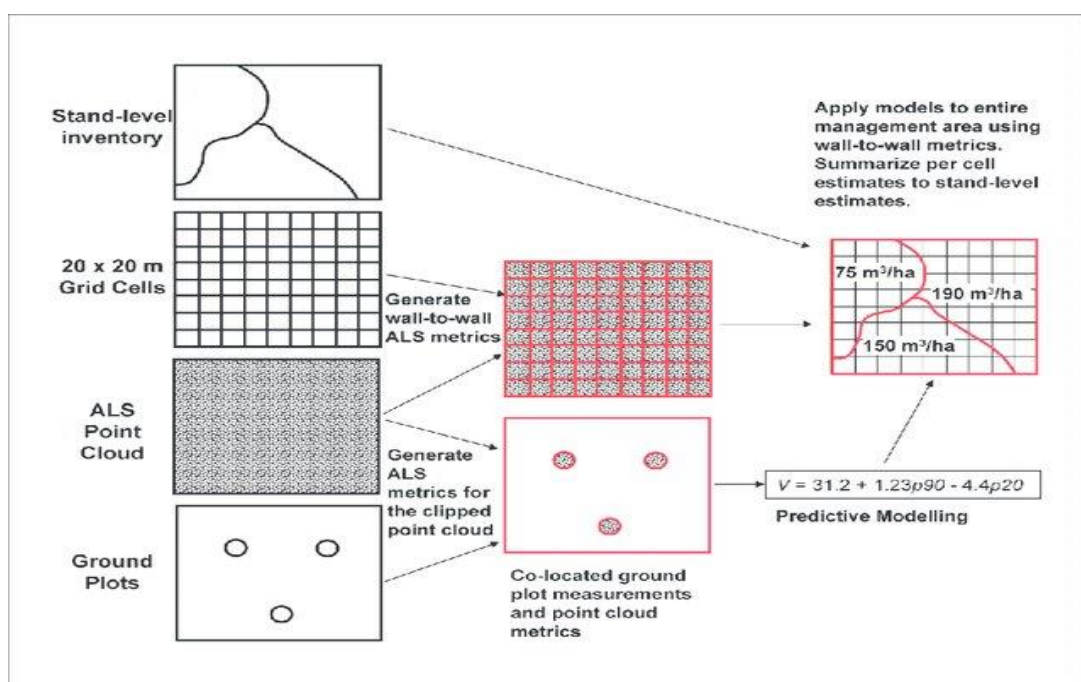
Obrázok 15: Výsledok detekcie individuálnych stromov (ITD) založený na údajoch ALS v kombinácii s prístupom local maxima. Čierne kríže označujú jednotlivé stromy.(Fatehi et al., 2017).

#### 4.5.2 AREA-BASED APPROACH

Area-Based Approach sa vykonáva dvoma krokmi:

1. V prvom kroku sa údaje ALS získavajú pre celú záujmovú oblasť, merané stromové veličiny sa získavajú na skusných plochách a sú vyvinuté prediktívne modely ako je regresia a neparametrické metódy. Na vývoj modelu sa ALS mračno bodov pripne na zodpovedajúcu oblasť skusných plôch. Metriky, čo je popisná štatistika, sa vypočítajú z pripnutého normalizovaného ALS bodového mračna a zahŕňajú odvodenie výšky, výškové percentily, a zápoj. Atribúty, ktoré nás zaujímajú sa merajú na skusných plochách ako výška a hrúbka alebo sú modelované ako objem alebo biomasa. Pre každú skusnú plochu. Pozemné skusné plochy by mali reprezentovať celú populáciu a obsahovať celý rozsah variability.

2. V druhom kroku je model aplikovaný na celú oblasť záujmu na generovanie wall-to-wall odhadov a máp konkrétneho atribútu inventarizácie lesa. Rovnaké metriky, ktoré sú vypočítané pre pripnuté ALS bodové mračno, sú generované pre wall-to-wall ALS data. Prediktívne rovnice vyvinuté v prvom kroku sú potom aplikované do celej záujmovej oblasti pomocou wall-to-wall metrík. Vzorková jednotka je bunka mriežky, ktorej veľkosť závisí na veľkosti pozemných plôch. Akonáhle sa aplikujú prediktívne rovnice, každá bunka mriežky bude mať odhad pre atribút záujmu (White et al. 2013) (Obrázok 16).



Obrázok 16: Schéma The Area-Based Approach (White et al. 2013)

## 5 Metodika

V tejto kapitole bude predstavená oblasť výskumu, použité senzory a popísaný postup spracovania dát.

### 5.1 Národný park České Švýcarsko

Študijnou oblasťou bol Národný park český Švýcarsko (Obrázok 17).




Obrázok 17: Národný park České Švýcarsko (<https://www.region-ceskesvycarsko.cz/oblasti/ceske-svycarsko/>)

Národní park České Švýcarsko sa nachádza v okrese Děčín a leží medzi obcami Hřensko, Chřibská a Brtníky. Táto oblasť sa nachádza v blízkosti štátnej hranice s Nemeckom a oddeľuje ju od Národného parku Saské Švýcarsko. Národný park České Švýcarsko bol založený v roku 2000. Od 1.6.2017 bola Správa národného NP České Švýcarsko taktiež poverená výkonom štátnej správy na území chránenej krajinnej oblasti Labské pískovce (CHKO). Rozloha NP České Švýcarsko je 7933 ha a rozloha CHKO je 24372 ha.

Podnebie v tejto oblasti sa vyznačuje skôr oceánskym typom (s menšími teplotnými rozdielmi medzi ročnými obdobiami a väčším množstvom zrážok).

Priemerný ročný úhrn zrážok sa pohybuje okolo 800 mm (Graf 1). S postupom regiónu od západu na východ sa celkový úhrn zrážok zvyšuje (napríklad v roku 2022 dosiahol na stanici Na Tokání 718,6 mm).

Teplotné podmienky v oblasti sa líšia v závislosti od lokality: Najvyššia priemerná teplota sa pohybuje okolo 9 °C v údolí Labe, zatiaľ čo severná časť parku a CHKO dosahuje priemernú teplotu okolo 7 °C, rovnako ako vrcholy Vysokého Sněžníka. V roku 2021 bola zaznamenaná priemerná ročná teplota vzduchu vo výške 2 m nad zemou okolo 7,6 °C (stanica Na Tokání). Vzhľadom na rozmanitý reliéf majú mikro- a mezoklimatické pomery významný vplyv na NP a CHKO a prejavujú sa v hlboko zarezaných údoliach vodných tokov, kde dochádza k tzv. klimatickej inverzii, ktorá vedie k zvratu vegetačných stupňov (vegetačná inverzia).



Graf 1: Zobrazujúci úhrn zrážok v NPČŠ

(([https://www.npcs.cz/sites/default/files/rozbory\\_kap2.pdf](https://www.npcs.cz/sites/default/files/rozbory_kap2.pdf))).

## 5.2 Zonácia Národného parku

Územie NP je rozdelené do štyroch zón s popisom cieľa, ktorý majú plniť.

ZÓNA A JEJ CIEĽ	PERCENTUÁLNE ZASTÚPENIE
1 - prírodná - cieľom je zabezpečiť nerušený priebeh dejov	15,6 %
2 - prírode blízka - cieľom je zabezpečiť nerušený priebeh dejov	18,9 %
3a - sústredenej starostlivosti o prírodu – cieľom je “trvalá starostlivosť“	10,5 %
3b - sústredenej starostlivosti o prírodu – cieľom je “zaistenie nerušeného priebehu dejov“	54,7 %
4 – kultúrnej krajiny- cieľ nie je stanovený	0,3 %

Tabuľka 1: Zonácia NPČŠ ([https://www.npcs.cz/sites/default/files/rozbory\\_kap2.pdf](https://www.npcs.cz/sites/default/files/rozbory_kap2.pdf)).

### 5.3 Geomorfologické členenie

Národný park České Švýcarsko patrí podľa geomorfologického členenia do Děčínskej vrchoviny, konkrétne k Děčínským a Jetřichovickým stenám. Toto územie tvorí východný okraj Krušnohorskej sústavy a na západe hraničí s Krušnými horami, na juhu s Českým stredohorím a na severe so Šluknovskou pahorkatinou.

Reliéf územia sa začal formovať už od obdobia po ústupe kriedového mora, ale výrazné zmeny nastali až koncom treťohôr a najmä počas štvrtohôr. Významný vplyv na krajinu mali tektonické pohyby, alpínske horotvorné procesy a striedanie ľadových a medziľadových dôb. Tento proces viedol k intenzívnej riečnej erózii hornín a postupnému odstráneniu menej spevnených partií a polôh v pieskovcoch, ktoré vytvorili jedinečný reliéf v porovnaní s inými pieskovcovými oblasťami v Európe.

Národný park sa vyznačuje pieskovcovým povrchom s mnohými priesekmi neovulkanických bazaltových hornín. Nachádzajú sa tu rozsiahle plošiny s hustou sieťou údolí, často lemovaných výraznými kaňonmi a roklinami. Juhozápadnou časťou NP prechádza hlboko zarezaná roklina rieky Kamenice a najvyšším bodom je kužel Růžovského vrchu (619 m n. m.), na ktorom sa rozkladá Národná prírodná rezervácia Růžák.

K významným krajinným útvarom patria skalné steny, mestá a bludiská, ale aj najväčší pieskovcový skalný most v Európe - Pravčická brána. V národnom parku možno pozorovať aj ďalšie útvary, ako sú skalné veže, previsy, rímsy a skalné okná. Prírodné procesy, ako sú erózia skalného podkladu a akumulácia sedimentov, stále formujú túto oblasť ([https://www.npcs.cz/sites/default/files/rozbory\\_kap2.pdf](https://www.npcs.cz/sites/default/files/rozbory_kap2.pdf)).

Stabilitu horninového podložia ovplyvňuje geologická stavba, morfológické pomery a klimatické zmeny, ktoré môžu viesť ku geodynamickým pohybom.

### 5.4 Pedologické charakteristika územia

Pôdne podmienky v Národnom parku České Švýcarsko úzko súvisia s geologickou stavbou územia. Väčšinu hornín (85,5 %) tvoria zvetrané kvádrové pieskovce. Tieto pôdy sú ľahké, piesočnaté alebo hlinitopiesočnaté, silne kyslé, v humusovej vrstve až veľmi silne kyslé a majú nízku zásobu prístupných živín.

Pôdy vytvorené na pieskovcoch (dystrické kambizeme) sú piesočnaté až hlinitopiesočnaté, silne kyslé a majú málo prístupných živín. Pôdy na bazaltoch (2,5 % územia) sú dobre zásobené vápnikom, horčíkom a fosforom ale majú nízky obsah draslíka. Tieto pôdy sú stredne až mierne kyslé. Na sprašových hlinách (5,5 % územia) sú pôdy piesočnato-hlinité až ílovito-hlinité, tiež silne kyslé, s nízkou zásobou živín a vyskytujú sa tu typy ako kambizeme a luvizeme.

V úzkych dnách údolí sa nachádzajú deluviálne a aluviálne sedimenty (6,5 % územia). Na týchto pôdach sa nachádzajú kambizeme oglejené, gleje, fluvizeme a rašeliniská. Tieto pôdy sa môžu líšiť zložením a obsahom živín, ale vplyv vysokej hladiny podzemnej vody môže nepriaznivo ovplyvniť rast stromov([https://www.npcs.cz/sites/default/files/rozbory\\_kap2.pdf](https://www.npcs.cz/sites/default/files/rozbory_kap2.pdf)).

## 5.5 Hydrológia

Celá oblasť Labských pieskovcov vrátane Národného parku České Švýcarsko podľa geologického vymedzenia patrí k Severnému moru.

Charakteristickým znakom Českého Švýcarska (Labských pískovcov) je nedostatok vodných tokov v porovnaní s okolitými oblasťami, čo je dôsledkom vysokej priepustnosti geologického podložia. Väčšina významných tokov, ako napríklad Kamenice v Lužických horách, Křinice vo Šluknovskej pahorkatine a mnohé menšie toky, napríklad Doubický potok a Bílý potok vo Šluknovskej pahorkatine pramenia mimo územia Labských pískovcov. To isté platí aj o Brtnickom potoku, ktorý pramení pri obci Brtníky.

Hlavnou hydrografickou osou tejto oblasti je rieka Labe, podľa ktorej dostali názov Labské pískovce. Rieka Labe preteká Labskými pískovcami v úseku medzi Děčínom a Hřenskom v dĺžke približne 12 km, kde vytvorila jedinečný pieskovcový kaňon.

Na území národného parku tečú dva hlavné vodné toky, Kamenice a Křinice, spolu so svojimi prítokmi. Oba tieto vodné toky sú prítokmi Labe (Obrázok 18) ([https://www.npcs.cz/sites/default/files/rozbory\\_kap2.pdf](https://www.npcs.cz/sites/default/files/rozbory_kap2.pdf)).





Obrázok 18: Hydrologická sieť NPČŠ

## 5.6 Floristicko-fytogeografická charakteristika

Z fytogeografického hľadiska je pre České Švýcarsko důležitá poloha na rozhraní hercýnskej a sudetskej oblasti, ktorá sa vyznačuje silným vplyvom oceánskeho podnebia s výskytom mnohých subatlantických druhov. Špecifický mikroklimatický a edafický charakter umožňuje výskyt boreálnych a subboreálnych druhov na zatienených skalných expozíciách a na dne údolí, prípadne na malých rašelinickách.

V Českom Švýcarsku je podstatne menšie zastúpenie kvetinových prvkov mediteránneho a ponticko-juhosibírskeho charakteru. Vyskytujú sa tu len jednotlivé lokality subpontických druhov, napríklad na Růžovskom vrchu.

Podľa Skalického fytogeografické členenie Labských pískovcov rozdeľuje oblasť na štyri podokresy. Väčšina územia NP České Švýcarskoko spadá pod Jetřichovické skalné mesto, kde sa vyskytujú druhy (sub)montánneho charakteru. Růžovská planina a kaňon Labe zasahujú do parku len čiastočne. Podokres Děčínsky Sněžník do národného parku nezasahuje ([https://www.npcs.cz/sites/default/files/rozborny\\_kap2.pdf](https://www.npcs.cz/sites/default/files/rozborny_kap2.pdf)).



## 6 Charakteristika prirodzenej lesnej vegetácie

Národný park je z väčšej časti pokrytý lesmi, ktoré zaberajú viac ako 97 % jeho rozlohy. Základné jednotky prirodzenej lesnej vegetácie na úrovni skupiny:

Na pieskovcovom podklade dominujú acidofilné bučiny skupiny *Luzulo-Fagion*, ktoré však v súčasnosti boli čiastočne prevedené na smrekové alebo borové monokultúry. V týchto lesoch prevláda buk lesný (*Fagus sylvatica*), v roklinách k nim pristupuje platan (*Acer pseudoplatanus*), smrek obyčajný (*Picea abies*) a zriedkavo jedľa biela (*Abies alba*). Bylinný podrast je zvyčajne chudobný.

Acidofilné duby skupiny *Genisto germanicae-Quercion* sa vyskytujú vo fragmentoch na plošinách. Stromové poschodie tvorí dub letný (*Quercus robur*), dub zimný (*Q. petraea*), borovica lesná (*Pinus sylvestris*) a jarabina obyčajná (*Sorbus aucuparia*). V krovinovej úrovni dominuje krušina jelšová (*Frangula alnus*). Stále dobre zachované (ale väčšinou bez dubu) sú porasty borovicových dúbav na horných plošinách Jetřichovického skalného mesta s typickými krovitými porastmi brusnic (*Vaccinium vitis-idaea*) a čučoriedok (*Vaccinium myrtillus*).

Acidofilné bory skupiny *Dicrano-Pinion* sú viazané na extrémne polohy na vrcholoch pieskovcových skál. V týchto porastoch dominuje borovica lesná (*Pinus sylvestris*) a breza biela (*Betula pendula*), ale v posledných desaťročiach sú tieto reliktné bory ohrozené inváziou borovice hladkej (*Pinus strobus*).

Lužné lesy skupiny *Alnion incanae* sú rozšírené len riedko pozdĺž väčších tokov a v prameništých polohách. V stromovej vrstve sa vyskytuje jelša lepkavá (*Alnus glutinosa*), jaseň štíhly (*Fraxinus excelsior*) a v smrekovo-jelšových porastoch aj smrek obyčajný (*Picea abies*).

Kvetnaté bučiny skupiny *Fagion* sú obmedzené na čadičové horniny. Tu prevláda buk lesný (*Fagus sylvatica*) a bohatá bylinná vrstva.

Sutinové lesy skupiny *Tilio-Acerion* sú väčšinou viazané na iné ako pieskovcové substráty. Najhodnotnejšie porasty sa nachádzajú na čadičovom Růžovskom vrchu.

V malom rozsahu sú zastúpené aj podmáčané smrečiny v inverzných roklinách patriacich do skupiny *Piceion excelsae* ([https://www.npcs.cz/sites/default/files/rozbory\\_kap2.pdf](https://www.npcs.cz/sites/default/files/rozbory_kap2.pdf)).


V práci sú použité bi-temporálne dáta z Národného parku České Švýcarsko. Prvé laserové letecké skenovanie bolo vyhotovené v roku 2005 spoločnosťou TopoSys Topographische Systemdaten GmbH, Biberach v rámci projektu GeNeSiS Technickej univerzity v Drážďanoch (TU Dresden). Hustota bodov pri laserovom skenovaní bola v priemere 4 body/m<sup>2</sup>. Druhé laserové dáta boli z roku 2019 vyhotovené komerčnou spoločnosťou Primis. Hustota bodov počas laserového skenovania bola v priemere 15 bodov/m<sup>2</sup>.

### 6.1 Letecké laserové dáta z roku 2005

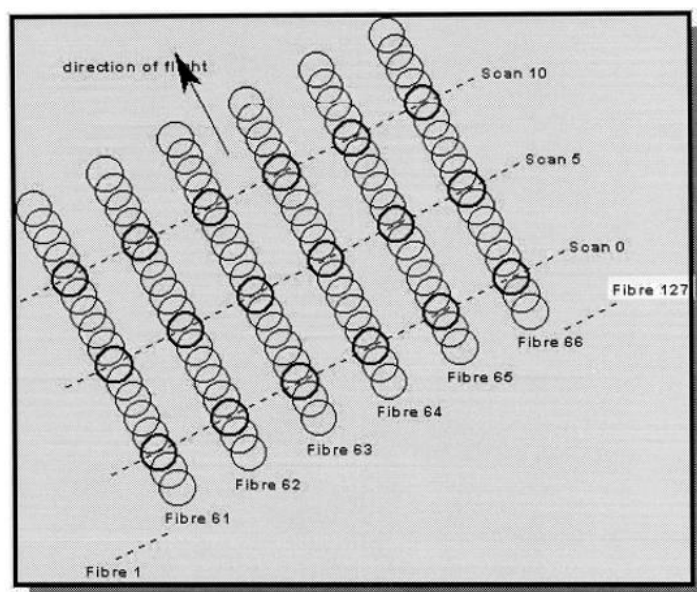
Letecké laserové skenovanie z roku 2005 bolo vyhotovené spoločnosťou TopoSys Topographische Systemdaten GmbH, Biberach. Ako skenovací systém bol použitý skener Falcon II (Obrázok 20). Tento typ skeneru používa optické vlákna, ktoré za pomoci malého zrkadla sú nasmerované do lineárneho zväzku optických vlákien (Obrázok 19). Laserový pulz je vysielaný vždy pod rovnakým uhlom. Problémom tohto skeneru je úzky uhol záberu a pevnom počte bodov v priamom smere vrátane ich uhlovej vzdialenosti (Dolanský 2004).



Obrázok 20: TopoSys Falcon II (Dolanský, 2004)



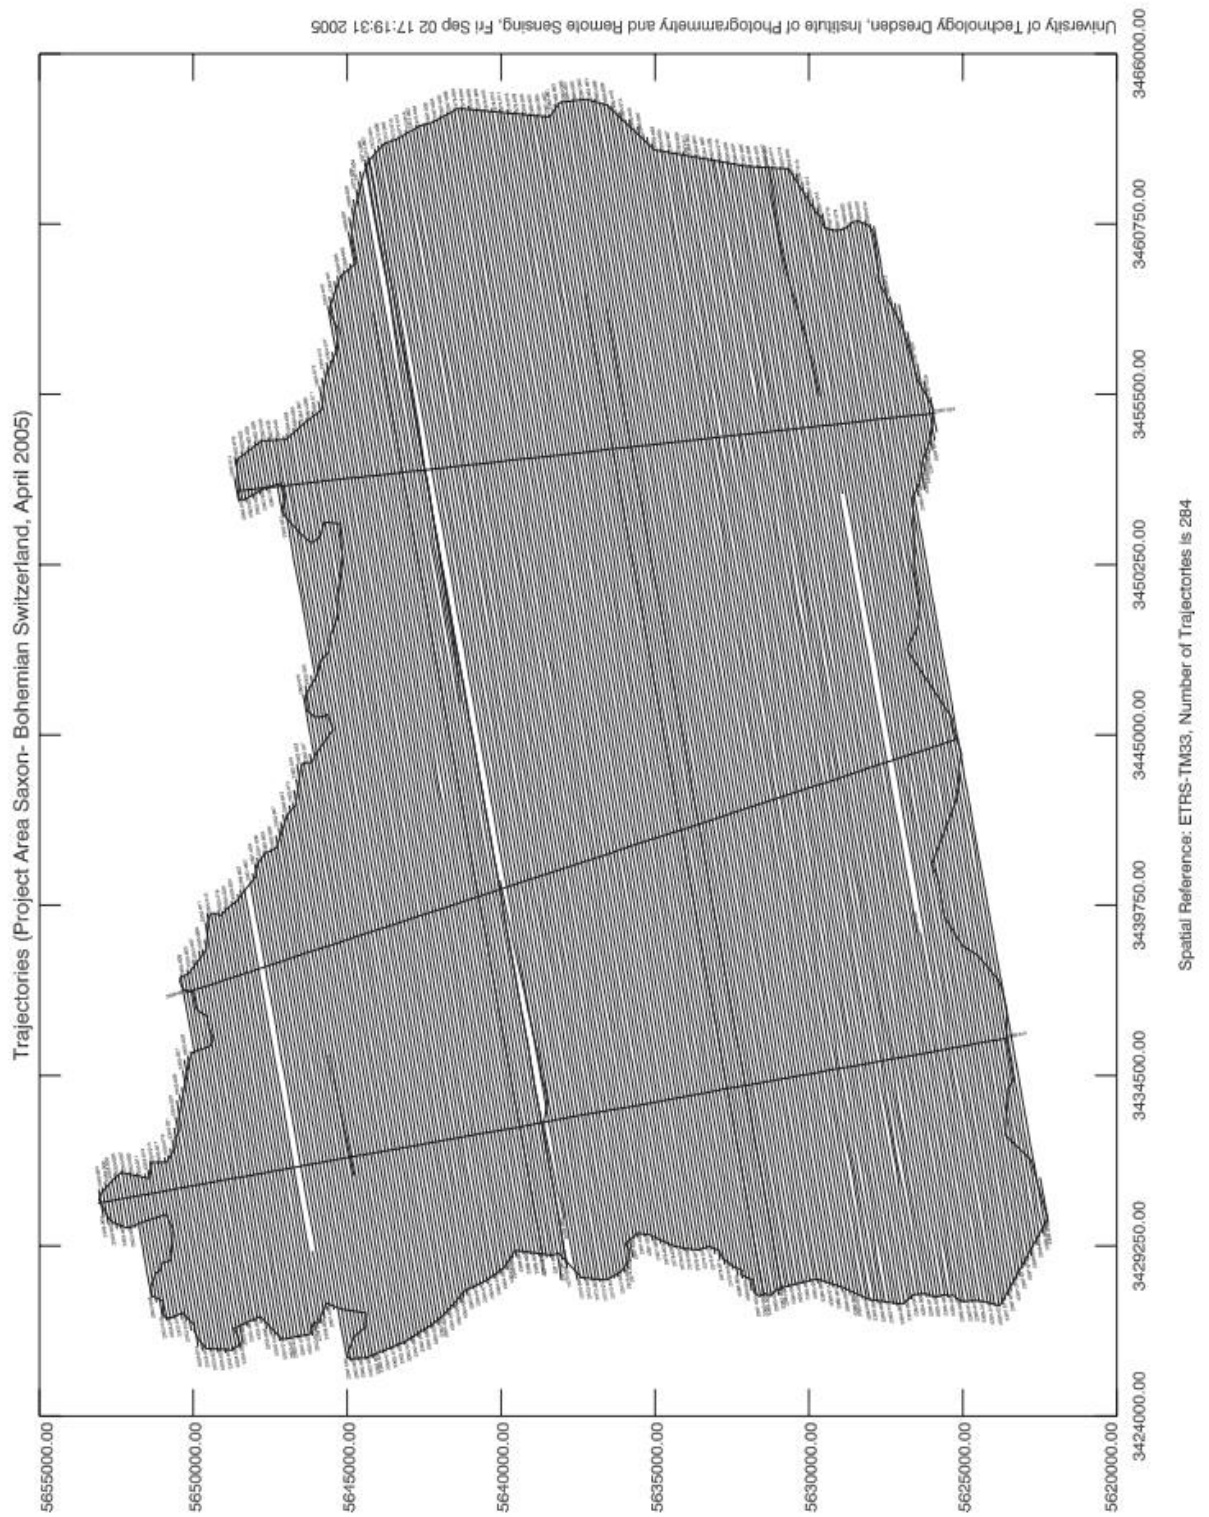
Obrázok 19: TopoSys, ukážka konštrukcie skeneru s optickými vláknami (Wehr & Lohr, 1999)



Obrázok 21: Vzor skenovania systému TopoSys ALS (Wehr & Lohr, 1999)

Špecifikácia zberu údajov	
Zodpovedná spoločnosť	Toposys Topographische Systemdaten GmbH, Biberach
Počet letov	16
Časový rozsah letov	14.4.-01.05.2005
Priemerná výška letu nad zemským povrchom	1200 m
Rozlíšenie výšok laserových meracích bodov	0,01 m
Počet dátových pásov	281 plus 3 pruhy naprieč
Veľkosť pixelu ortofotomapy (L1_DAT)	0,50 m
Rozmer dlaždíc ortofotomapy (L1_DAT)	2000x2000 m <sup>2</sup>
Počet dlaždíc (L1_DAT)	238
Primárny referenčný systém	ETRS-TM 33, elipsoidné výšky
Typ senzoru	Falcon II
Špecifikácia laserové jednotky	
Rozsah	1600 m
Šírka skenovania	14,3°
Efektívna rýchlosť merania	83000 za sekundu
Vlnová dĺžka	1560 nm
Záznam dát	prvé odraz, posledný odraz a intenzita

Tabuľka 2: Špecifikácia zberu údajov z roku 2005



Obrázok 22: Trajektória letu v NPČŠ v roku 2005 (Trommler, 2007)




## 6.2 Letecké laserové dáta z roku 2019

Letecké laserové skenovanie z roku 2019 bolo vyhotovené spoločnosťou Primis. Ako skenovací systém bol použitý skener Leica ALS70-CM (Obrázok 23). Tento typ skeneru používa oscilujúce zrkadlo (Obrázok 24), kde je vysielaný signál vychýlený kmitajúcim zrkadlom, ktoré sa otáča v rámci určitého rozsahu. Zrkadlo sa zrýchľuje a spomaľuje pred a po dosiahnutí bodov otáčania. Výsledkom je meniaci sa hustota bodov. Kombinácia dvoch ortogónne umiestnených zrkadiel, ktoré kmitajú kolmo na seba vedie k tzv. kamerovým skenerom, ktoré dokážu zachytiť dáta len v rámci určitého zorného poľa (Wujanz, 2016).



Obrázok 23: Skener Leica ALS70-CM



Obrázok 24: Povrchová stopa skenovacieho systému Leica ALS70 (Leica ALS70-CM)

Špecifikácia zberu údajov	
Zodpovedná spoločnosť	PRIMIS spol. s r. o.
Multispektrálna kamera	Leica RCD30
Priemerná výška letu nad zemským povrchom	Od 579 to 1069 m
Časový rozsah letov	Apríl 2019
Primárny referenčný systém	
Typ senzoru	Leica ALS70-CM
Špecifikácia laserové jednotky	
Šírka skenovania	50°
Efektívna rýchlosť merania	231 kHz
Vlnová dĺžka	1064 nm
Záznam dát	prvé odraz, posledný odraz a intenzita

Tabuľka 3: Špecifikácia zberu údajov z roku 2019

### 6.3 Softwarové spracovanie dát

Laserová dáta z roku 2005 boli v binárnom dátovom formáte 3d3 a 3d3i (formát od spoločnosti TopoSys) a majú štruktúru podľa typu použitého skeneru. Pre ďalšie spracovanie bolo potrebné v prvom rade previesť dáta do textového formátu pomocou nástroja TopoSys Converter V.2.2.0. Pretože sa jednalo o veľký objem dát, bolo potrebné územia rozdeliť na menšie časti a konvertovať ho postupne. Týmto softwarom boli dáta exportované do základného textového súboru so záznamami ku každému bodu v tvare X,Y, Z, T (čas), I (intenzita, u dát posledného odrazu) (Bruna et al., 2012).

Metadáta údajov konvertované systémom TopoSys

	dat2349003f.3d3 dat2349003f.txt	dat2349003i.3d3i dat2349003i.txt
Metóda	TSC 2.2.0	TSC 2.2.0
počet mŕčících bodů	340565	339260
Xmin	3.430.146.4	3.430.146.4
Xmax	3.430.974,1	3.430.974,1
Ymin	5.652.762,9	5.652.762,9
Ymax	5.653.056,8	5.653.056.8
Zmin	279,7	279,7
Zmax		509,9

Tabuľka 4: Ukážka metadát prekonvertovaných pomocou TopoSys Converter V.2.2.0

Neusporiadané mračno, ktoré má okolo 12 miliárd bodov bolo potrebné vyfiltrovať a klasifikovať. V tejto dobe existuje množstvo softwarových riešení na spracovanie laserových mračien bodov, ale treba si uvedomiť, že tie, čo sú vhodné na spracovanie pozemných laserových skenov nemusia byť vhodné na spracovanie leteckých. V našom výskumne sme doteraz vyskúšali štyri softwarové riešenia:

1. Trimble RealWorks: Tento software importuje a spracováva rozsiahle 3D dáta prevažne z pozemných skenerov od tejto spoločnosti. Otvorí aj dáta z leteckého laserového skdenovania, ale v dôsledku veľkého počtu bodov je to časovo náročné a software s tým má značné problémy.
2. ArcGIS LAsTools Toolbox: Spravovanie LiDARových dát v programe ArcGIS si vyžaduje pokročilú 3D Analyst licenciu. Toolbox poskytuje niekoľko funkcionalít od editácie a práce s laserovým mračnom, cez pokročilejšie techniky klasifikácie až po detekciu jednotlivých stromov. Nevýhodou je cena licencie a taktiež doba spracovania.
3. CloudCompare: CloudCompare je software na spracovanie 3D bodového mračna. Pôvodne bol navrhnutý na porovnávaní dvoch hustých bodových mračien. Následne bol rozšírený na všeobecnejší software na spracovanie bodových mračien. Software je zdarma, ale nevýhodou je rýchlosť spracovania, pretože software nevie spracovávať dáta na pozadí, čo má za následok neschopnosť i po otvorení tak veľkého mračna čokoľvek s ním robiť.
4. PDAL: PDAL je Point Data Abstraction Library. Jedná sa o C / C ++ knihovňu a aplikácie pre preklad a spracovanie dát mračien bodov. Neomeďuje sa iba na dáta LiDAR, avšak mnoho nástrojov v knihovne majú svoj pôvod v LiDAR. Balíčky sme spúšťali pomocou príkazového riadku v programe Anaconda Navigator. Toto riešenie je s otvoreným zdrojovým kódom a zároveň schopné spracovať veľký objem dát.

### **6.3.1 PDAL - Knižnica abstrakcie bodových dát**

PDAL je knižnica C ++ na kódovanie a manipuláciu s bodovými mračnami. Okrem knižnice s kódmi poskytuje PDAL aj sadu aplikácií, ktoré môžu používatelia pohodlne

používať na spracovanie, filtrovanie, kódovanie a dotazovanie sa na dáta bodových mračen. V našom prípade sme knižnicu použili na filtrovanie, klasifikovanie, rasterizáciu bodového mrača a generovanie DTM.

PDAL knižnicu sme spúšťali cez desktopové grafické užívateľské rozhranie Anaconda Navigator.

### **6.3.2 Filtrovanie, klasifikácia, rasterizácia bodového mrača a generovanie DTM**

Filtrovanie a klasifikácia sa uskutočnili za pomoci knižnice PDAL, ktorá bola spustená v prostredí Anaconda Navigator. PDAL bol použitý na klasifikáciu pozemných bodov technikou jednoduchého morfológického filtra (SMRF), ktorá je založená na hľadaní minimálnej z-tovej hodnoty vo zvolenom bufferi a uhlovom spojení s najbližším bodom. Algoritmus rozlišuje body do dvoch skupín na pozemné a nepozemné. Filter odľahlých hodnôt najprv iba klasifikuje odľahlé hodnoty s hodnotou klasifikácie 7. Tieto odľahlé hodnoty sa potom pri spracovaní SMRF ignorujú pomocou možnosti ignorovať. Nakoniec pridáme filter rozsahu, aby sme vyčlenili len pozemné body (t. j. hodnota klasifikácie 2) (PDAL, 2022a).

Pomocou PDAL sme vygenerovali rastrový povrch s použitím plne klasifikovaného mrača bodov pomocou PDAL writers.gdal. Schopnosť PDAL generovať rastrový výstup poskytuje modul writers.gdal (PDAL, 2022b).


PDAL bol použitý k vytvoreniu povrchu výškového modelu s využitím výstupu z filtrovania. PDAL operácia writers.gdal a GDAL k vygenerovaniu výškového a kopcovitého povrchu z bodového mrača (PDAL, 2022c).

## **6.4 Detekcia holín**

V prípade, že chceme odhadovať prírastky v lesných ekosystémoch, je v prvom rade potrebné odhadnúť úbytok stromov, či už sa jedná o prirodzené odumieranie alebo je úbytok spôsobený ľudskou činnosťou. Technológia diaľkového prieskumu Zeme poskytuje nástroje na mapovanie medzier v poraste (Zielewska-Büttner et al., 2016) a umožňuje tvorbu digitálneho modelu povrchu a digitálneho modelu terénu (Xiaowei Yu & Maltamo, 2006). Tieto modely sa následne môžu využiť na generovanie normalizovaného modelu výšok (Canopy Height Model), ktoré slúžia ako základ pre analýzy v lesníctve (Maltamo et al., 2004). Ako validačné dáta k leteckým laserovým skenom boli v našom prípade použité holiny zakreslené v lesnom hospodárskom pláne.



Na tvorbu Normalizovaných modelov výšok (CHM) sme v našom prípade použili software ArcGIS Pro Esri ® a nástroj *Minus*. Týmto nástrojom sa odpočíta hodnota druhého vstupného rastra od hodnoty prvého vstupného rastra po jednotlivých bunkách.

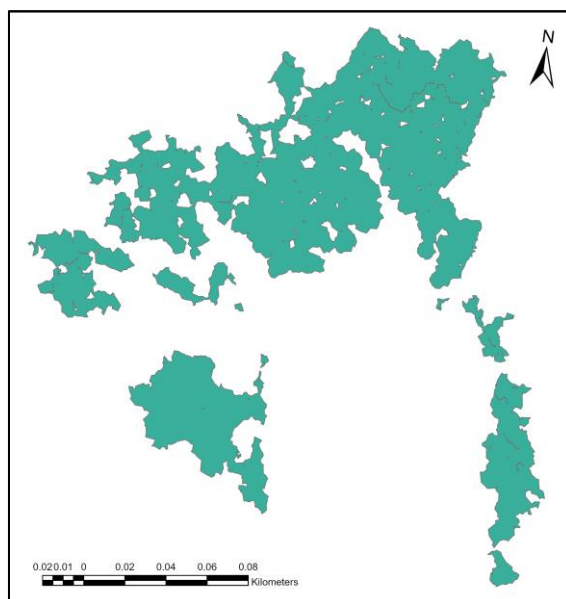


$$OutRas = Minus (InRas1, InRas2)$$

Obrázok 25: Zobrazenie ako pracuje nástroj Minus (Minus (Spatial Analyst), ArcGIS Pro 3.2)

Keďže sa jednalo v tomto prípade o multitemporárne laserové skeny z rokov 2021, 2020 a 2019, tak sme odčítali data z roku 2021 a 2020, aby sme vytvorili holiny z roku 2021, a to isté sme urobili pre laserové súbory údajov z rokov 2020 a 2019, aby sme vytvorili holiny z roku 2020. Následne sme pomocou nástroja *Erase* odstránili prekryv polygónov ALS z rokov 2020 a 2021 a potom sme ich spojili pomocou nástroja *Merge*. Rok 2021 a 2020 sa nevyhodnocoval samostatne pretože v lesnom hospodárskom pláne na rok 2021 bola zahrnutá aj plocha holín na rok 2020.

Odčítaný raster (Obrázok 26) zobrazujúci holiny je geograficky aj polohovo správne, avšak je pre pozorovateľa môže byť nečitateľný, preto by bolo vhodné jeho tvar upraviť. Okrem tohoto problému obsahujú polygóny aj diery, ktoré predstavovali jednotlivé stojace stromy.



Obrázok 26: Polygón holiny klasifikovaný za pomoci LLS

Pre uzavretie dier vo vnútri polygónu sme použili nástroj *Eliminated Polygons Part*. Ako "podmienku" sme vybrali plochu, ktorá odstrániť časti menšie ako stanovená hodnota; v našom prípade bola prahová hodnota 4000 m<sup>2</sup> a bola zvolená na základe pravidla, že jednotky menšie ako 0,4 ha sa nevylišujú.

Tvary polygónov sme upravili pomocou nástroja *Simplify Polygons*, pri ktorom sme otestovali všetky 4 zjednodušovanie algoritmy, ktoré tento nástroj ponúka aj ich toleranciu zjednodušenia.

## 6.5 Využitia metód strojového učenia a pokročilých štatistických metód pre odhad zásob lesných porastov

Ako študijné dáta sú v tomto prípade použité pozemné dáta z rôzne veľkých plôch, ktoré sú v tomto prípade definované ako kompaktná jednotka lesa viditeľná na rastovej vrstve s rozlíšením 1 m vytvorenej za pomoci LiDARových dát. Na rovnakej dátovej sade boli následne skúšané štatistické techniky a to Partial Least Squares Regression, Stepwise Linear Regression a Random Forest. Hlavným dôvodom použitia tých štatistických metód, ktoré budú podrobnejšie opísané nižšie je testovanie všetkých dostupných prediktorov a buď konštrukcia modelu, alebo výber tých pramenných, ktoré sú pre model najdôležitejšie.

Software na spracovanie používame R studio a nasledujúce balíčky: (<https://CRAN.R-project.org/package=pls>), caret balíček (<https://CRAN.R-project.org/package=caret>) a balíček Random Forest (<https://cran.r-project.org/package=randomForest>).

Predtým ako sme hodnotili jednotlivé štatistické metódy v R Studiu, boli pre polygóny pozemne meraných plôch získané rastrové charakteristiky: MIN, MAX, RANGE, MEAN, STD, SUM, MEDIAN, PCT90 v software ArcGIS Pro Esri® za pomoci nástroja *Zonal Statistics a Table*.

Hodnoty MIN, MAX, RANGE predstavujú minimum, maximum a rozsah hodnôt výšky v danom polygóne a vzťahujú sa k extrémnym hodnotám v oblasti, obvykle MIN predstavuje zem, v prípade, že zem nie je, tak predstavuje najnižšiu vegetáciu. MEAN, MEDIAN a PCT90 sú bodové odhady výšok jednotlivých buniek v rámci polygónu. V prípade, pokiaľ ide o les tak sa odhady nevzťahujú k priemernej výške stromov, ale sa vzťahujú k priemernej výške buniek v danom polygóne, čo znamená, že pokiaľ má polygón nižšiu hustotu stromov a to sa odrazí v charakteristikách rastru (viac buniek s nulovou výškou), bude hodnota MEAN nižšia. Môže nastať extrémny prípad kedy, polygón o rozlohe jedného hektáru bude obsahovať len jeden soliterný strom s výškou 30 m, bude mať hodnotu MEAN blízko nule alebo pravdepodobne menej ako jeden meter, pretože MEAN predstavuje priemernú hodnotu buniek. Pre MEDIAN a PCT90 to platí tiež ale sú menej citlivé na problém spojené s plochou. SUM je súhrnná hodnota všetkých výšok v polygóne, v podstate ide o vynásobení priemeru plochou, takže zohľadňuje veľkosť polygónu a výšky jednotlivých buniek. STD je smerodajná odchýlka a má popisovať variabilitu výšok jednotlivých buniek, ktorá obvykle súvisí s hustotou porastu alebo zásobou. Väčšia odchýlka môže znamenať redšie postavenie stromov, menšia odchýlka potom predstavuje uzavretejší zápoj.

## 6.6 Detekcia prírastku

Pre účely odhadu rozšírenia čistej biomasy sme vylúčili údaje, kde bol prírastok väčší ako 15 m, čo zodpovedá najväčším prírastkom zisteným v českých rastových a výnosových tabuľkách (Černý, M., Pařez, J., Malík, 1993). Taktiež sme vylúčili záporný prírastok, ktorý možno chápať buď ako ťaženie plochu, alebo ako vplyv nejakého narušenia spôsobujúceho zníženie výšky (zlom vrcholu stromu, poškodenie snehom a pod.).

Na detekciu zmien sme v tomto prípade použili nástroj *Change Detection* v ArcGIS Pro Esri®, ktorý umožňuje vykonávať analýzu zmien medzi rastrovými dátovými súborami.

Geoprocessingové nástroje v rámci sady nástrojov Change Detection umožňujú vykonávať základné analýzy detekcie zmien medzi rastrovými dátovými súborami. Okrem toho je možné použiť funkciu Compute Change raster (Výpočet zmeny rastra) na detekciu zmien medzi dvoma sadami rastrových údajov v reálnom čase .

Na zisťovanie zmien v časovom rade rastrových snímok máme možnosť použiť buď nástroj Analýza zmien pomocou CCDC, alebo nástroj Analýza zmien pomocou LandTrendr. Každý z týchto nástrojov možno prepojiť s nástrojom Detect Change Using Change Analysis Raster (Zistiť zmeny pomocou nástroja Analýza zmien rastra), aby ste zistili podrobnosti o čase a rozsahu zmien pre každý časový rad pixelov (Detekcia zmien v programe ArcGIS Pro, ArcGIS Pro 3.2).

Na číselný popis zmien v oboch obdobiach využívame zonálnu štatistiku ako zdroj dát. Nižšie uvedené premenné sú získavané automaticky ako potencionálne prediktory:

1. MEAN - priemer všetkých buniek v rastri hodnôt, ktoré patria do rovnakej zóny ako výstupná bunka;
2. MAXIMUM - najväčšia hodnota všetkých buniek v rastri hodnôt, ktoré patria do rovnakej zóny ako výstupná bunka,
3. MEDIAN - mediánová hodnota všetkých buniek v rastri hodnôt, ktoré patria do rovnakej zóny ako výstupná bunka,
4. MINIMUM - najmenšia hodnota všetkých buniek v rastri hodnôt, ktoré patria do rovnakej zóny ako výstupná bunka,
5. PERCENTIL 90 - percentil všetkých buniek v rastri hodnôt, ktoré patria do rovnakej zóny ako výstupná bunka,
6. RANGE - rozdiel medzi najväčšou a najmenšou hodnotou všetkých buniek v rastri hodnôt, ktoré patria do rovnakej zóny ako výstupná bunka,
7. SMERODAJNÁ ODCHÝLKA – smerodajná odchýlka všetkých buniek v rastri hodnôt, ktoré patria do rovnakej zóny ako výstupná bunka,
8. SÚČET - celková hodnota všetkých buniek v rastri hodnôt, ktoré patria do rovnakej zóny ako výstupná bunka,
9. VARIABILITA - počet jedinečných hodnôt pre všetky bunky v rastri hodnôt, ktoré patria do rovnakej zóny ako výstupná bunka (Zonal Statistics as Table (Spatial Analyst, ArcGIS Pro 3.2))

Ako verifikačné dáta bola použitá bonita v danom území, z lesného hospodárskeho plánu z roku 2017.

### **6.6.1 Štatistické modelovanie a tvorba modelov na základe strojového učenia**

Štatistická analýza bola vykonaná pomocou softvéru R vo verzii 4.2.3 (R Core Team, 2023). V prvom kroku boli prírastky modelované nad vekom respektíve nad priemernou výškou. K fitovaniu prírastkového tvaru Chapmanovej-Richardsonovej funkcie bol použitý nelineárny balík (nls2).

V druhom kroku sa pre vytvorenie modelu použila Stepwise Regression, kedy všetky východzie premenné boli dostupné z dát diaľkového prieskumu Zeme: prvá sada z roku 2005 a druhá z rozdielu medzi rokmi 2005 a 2019. Použité premenné boli štandardné premenné Zonal Statistic z ArcGIS Pro.

V treťom kroku bol zaradený prístup strojového určenia pre tvorbu modelu použitím balíčka RandomForest. Pomocou matice zámeny a podľa presnosti poskytnutej z modelu bola odhadnutá presnosť modelu. Pri absolútnej aj relatívnej bonite boli hodnoty transformované na faktory a modelované ako diskkrétne triedy.


## **6.7 Odhad hrúbky stromu za pomoci terestriálnych laserových skenerov**

V prvom kroku boli normalizované všetky bodové mračná a vytvorený 4 cm rez vo výške 1,3 m nad zemou. Pomocou nástroja CloudCompare (<https://www.danielgm.net/cc/>) boli z týchto rezov extrahované všetky sekcie prináležiace stromom, okrem tých poškodených, čo vo výsledku bolo 60 sekcií.

V druhom kroku bol počet bodov v sekciách redukovaný na 600, za pomoci algoritmu náhodného podvýberu v programe CloudCompare, kvôli výpočetnej limitácii implementovaného Random Sample Consensus.

Ransac funguje na základe hlasovania o najčastejší nájdený polomer z tzv. náhodnej vzorky bodov v rámci daného súboru dát. Body sa môžu vyberať náhodne zo súboru dát alebo sa môžu testovať pre každú kombináciu bodov (tzv. brute force approach). Naša implementácia je závislá od druhého z uvedených spôsobov, a preto je schopná pracovať len so súbormi údajov s menej ako 600 bodmi, inak by výsledkom boli miliardy iterácií s príslušným množstvom údajov potrebných na uloženie a vyhodnotenie výsledkov. Pre väčšinu stromov stačí 600 bodov. Algoritmus potom pre každú trojicu bodov uloží veľkosť

a polohu kruhu a najčastejšie sa vyskytujúca trojica sa potom považuje za správnu (Obrázok 27 hore).



Obrázok 27: Príklady použitia algoritmu RANSAC v rôznych situáciách. Horný riadok ukazuje použitie RANSAC pri neúplnom skenovaní kmeňa; dolný riadok ukazuje použitie RANSAC pri rôznych metódach skenovania.

Algoritmus funguje dobre pre akúkoľvek sadu údajov a jeho výsledky sú najlepšie pre statický LiDAR (TLS), najmä preto, že počet správnych bodov na povrchu je najvyšší. Na obrázku 27 dole je znázornený príklad algoritmu v praxi. Vľavo je sken TLS analyzovaný algoritmom RANSAC, ktorý je schopný dosiahnuť chybu 2 cm v porovnaní s pozemným meraním; v strede je viacnásobný sken Livox, ktorého výsledkom je komplexný sken (hoci zvonku vizuálne v poriadku), ale pomerne komplexný pre automatickú analýzu, čo má za následok chybu 5 cm v odhade priemeru. Na úplne pravej pozícii je jeden priechod Livox s chybou odhadu priemeru 0,7 cm.

Okrem metódy Ransac boli dáta analyzované pomocou balíka R FORTLS (Molina-Valero et al., 2022). Balík FORTLS implementuje automatizovaný prístup, v ktorom sa sice niektoré parametre môžu definovať pred spracovaním, ale výstupy (v tomto prípade DBH) sa získajú ako konečný súbor údajov. Pokiaľ ide o odhady DBH, uvažuje sa o dvoch prístupoch: 1) jeden patrí algoritmu RANSAC implementovanému vo funkcii

"circleRANSAC" a 2) druhý je založený na prekryve pravidelných štvorcových sietí na stromových sekciách, pričom za stred stromovej sekcie sa považuje bod v sieti, v ktorom je minimalizovaný rozptyl vzdialeností medzi ním a všetkými bodmi v zhluku. Týmto spôsobom je priemer vzdialeností odhadom polomeru. Nakoniec sa za odhad DBH považuje najlepší z týchto dvoch prístupov z hľadiska rozptylu polomeru (a preferencie RANSAC).

## 7 Výsledky

Výsledky výzkumu sú podrobne rozpísané v publikovaných článkoch. Prvý článok sa zaoberá na automatickou detekciou holín odvodenú z lidarových dát. V druhom článku sa za pomoci lidarových dát odhadujú zásoby lesných porastov ABA prístupom. Tretia publikácia sa zameriava na odhad prírastku a bonity pomocou bitemporálnych laserových dát a štvrtá publikácia je zameraná na odhad hrúbky stromov za pomoci terestriálneho a mobilného laserového skeneru.

### 7.1 Automatická detekcia holín odvodená z lidarových dát

#### **Benchmark for Automatic Clear-Cut Morphology Detection Methods Derived from Airborne Lidar Data.**

V článku sa skúmal vplyv štyroch algoritmov na zjednodušenie tvarov detegovaných holín na základe údajov z leteckého laserového skenovania (ALS). Význam detekcie holín spočíva v presnom určení rozsahu týchto oblastí. Využitie ALS pre detekciu holín predstavuje presnú metódu, avšak ich tvar má nepravidelné okraje, ktoré môžu byť ťažko čitateľné. Pre lepšiu čitateľnosť bolo nevyhnutné zjednodušiť tieto tvary.

V článku boli testované štyri algoritmy pomocou softvéru ArcGIS Pro na zjednodušenie tvarov holín: algoritmus na zachovanie kritických bodov (Douglas–Peucker), algoritmus na zachovanie kritických ohybov (Wang–Müller), algoritmus na zachovanie váženej plochy (Zhou–Jones) a algoritmus na zachovanie účinnej plochy (Visvalingam–Whyatt). Údaje o skutočných plochách holín pochádzali z lesného hospodárskeho plánu.

Výsledky ukázali, že algoritmus Wang–Müller bol najlepší z testovaných štyroch algoritmov pri zjednodušovaní tvarov detekovaných holín. Využitie tohto algoritmu viedlo k výraznému zníženiu času potrebného na úpravu polygónov na menej ako 1 % času potrebného na manuálne vytvorenie týchto oblastí.

*Publikované ako:*

Melichová, Z., Pekár, S., & Surový, P. (2023). Benchmark for Automatic Clear-Cut Morphology Detection Methods Derived from Airborne Lidar Data. *Forests*, 14(12). <https://doi.org/10.3390/f14122408>

*Prínosy autorov*



Konceptualizácia, Z.M. a P.S.; metodika, Z.M., S.P. a P.S.; softvér, Z.M. a P.S.; validácia, Z.M., S.P. a P.S.; formálna analýza, Z.M.; výskum, Z.M.; zdroje, P.S.; príprava pôvodného návrhu, Z.M. a P.S.; text - recenzia a úprava, Z.M. a P.S.; vizualizácia, Z.M.; dohľad, P.S.; administrácia projektu, P.S.; získavanie finančných prostriedkov, P.S. Všetci autori si prečítali a súhlasia s publikovanou verziou rukopisu.

Article

# Benchmark for Automatic Clear-Cut Morphology Detection Methods Derived from Airborne Lidar Data

Zlatica Melichová <sup>1,\*</sup>, Stano Pekár <sup>2</sup> and Peter Surový <sup>1</sup>

<sup>1</sup> Department of Forest Management, Faculty of Forestry and Wood Sciences, Czech University of Life Sciences Prague, Kamýcká 129, 16500 Prague, Czech Republic

<sup>2</sup> Department of Botany and Zoology, Faculty of Science, Masaryk University, Kotlářská 2, 61137 Brno, Czech Republic

\* Correspondence: melichovaz@fld.czu.cz

**Abstract:** Forest harvest detection techniques have recently gained increased attention due to the varied results they provide. Correctly determining the acreage of clear-cut areas is crucial for carbon sequestration. Detecting clear-cut areas using airborne laser scanning (ALS) could be an accurate method for determining the extent of clear-cut areas and their subsequent map display in forest management plans. The shapes of ALS-detected clear-cut areas have uneven edges with protrusions that might not be readable when displayed correctly. Therefore, it is necessary to simplify these shapes for better comprehension. To simplify the shapes of ALS-scanned clear-cut areas, we tested four simplification algorithms using ArcGIS Pro 3.0.0 software: the retain critical points (Douglas–Peucker), retain critical bends (Wang–Müller), retain weighted effective areas (Zhou–Jones), and retain effective areas (Visvalingam–Whyatt) algorithms. Ground-truth data were obtained from clear-cut areas plotted in the forest management plan. Results showed that the Wang–Müller algorithm was the best of the four ALS algorithms at simplifying the shapes of detected clear-cut areas. Using the simplification algorithm reduced the time required to edit polygons to less than 1% of the time required for manual delineation.

**Keywords:** multitemporal laser scanning data; harvest detection; simplification polygons; clear-cut areas



**Citation:** Melichová, Z.; Pekár, S.; Surový, P. Benchmark for Automatic Clear-Cut Morphology Detection Methods Derived from Airborne Lidar Data. *Forests* **2023**, *14*, 2408. <https://doi.org/10.3390/f14122408>

Academic Editor: Qiaolin Ye

Received: 13 October 2023

Revised: 21 November 2023

Accepted: 6 December 2023

Published: 11 December 2023



**Copyright:** © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

## 1. Introduction

In Europe, sustainable forest management has become a prominent topic, as management decisions impact forest growth, composition, and structure, as well as wood production, carbon sequestration, and nature conservation in both temporal and spatial contexts [1]. Forestry has been recognized as an important way to reduce CO<sub>2</sub> emissions and combat global warming, as highlighted in the Paris Agreement [2]. Nevertheless, forestry harvesting practices may adversely affect the benefits of forest CO<sub>2</sub> capture. Research comparing the impact of reducing carbon sequestration through harvesting versus natural disturbances has shown that harvesting has a greater impact. Notably, incidental harvesting, in which the effects of harvesting cannot be easily distinguished from those of natural disturbances, must also be considered [3].

Various techniques and methods for detecting harvests and clear-cuts deserve attention, as their accurate evaluation is crucial. Incorrect use of techniques or reference data can result in erroneous conclusions. Ceccherini et al. (2020) [4] focused on harvest detection in Europe using satellite data. They tracked the increase in harvested forests and biomass losses for 2016–2018 and compared them to those for 2011–2015. Their findings indicated that harvesting had increased by 34% on average, potentially impacting biodiversity, soil erosion, and water regulation. Their study suggested that the expansion of the timber market, wood-based bioenergy, and international trade had led to an increase in harvesting speed. The authors warned that continued high harvesting rates could impede forest-based

efforts to mitigate climate change impacts. Picard et al. (2021) [5] investigated claims regarding increased harvesting in European countries and re-examined France using original data reported in [4]. They found that the rate of change in harvested area depended on the comparison period used, and that data regarding extraction volumes from different sources produced varied results. Responding to an investigation in Finland and Sweden, which found only marginal or no harvesting increase after 2015 [6], the authors suggested that sensitivity and detection of harvesting areas and overburden were increasing [4]. Ceccherini et al.'s (2020) [4] study highlighted the potential for inaccurate results when inappropriate estimates and reference data are used in satellite data analysis.

Remote sensing technologies and three-dimensional data offer increasingly accurate options for estimating growth rates and forest information. Lidar, satellites, and unmanned aerial vehicles (UAVs) are remote sensing methods used for gap mapping, including size and spatial distribution parameters [7]. ALS technology enables 3D characterization of forest canopies, allowing digital terrain model (DTM) and digital surface model (DSM) calculations to describe treetops from the original point cloud [8]. An advantage of using lidar data is the resulting accuracy of DTMs, which are often available for public use [9]. Subtracting an area's digital surface model from its digital terrain model produces a canopy height model (CHM), which is widely used as the basis for various forestry analyses [10].

Forest metrics can be computed using lidar directly from the point cloud or rasterized point cloud data (a rasterized point cloud is a raster in which each cell is described by height value) [11]. Rasterized clouds are usually faster and easier to process [12]; however, they offer less information (metrics) than point clouds. Therefore, rasterized clouds are more suitable for clear-cut detection.

Two approaches are generally used to derive forest information: the area-based approach (ABA) and individual tree detection (IDT) [13]. These methods are typically used to estimate forest characteristics, stand-level biomass, volume, or basal area. For estimation purposes, these variables mostly use the plot-level method, which involves calculating various descriptive statistics, such as mean, maximum, standard deviation, and height metrics, counting height percentiles. These statistics can be used to characterize different aspects of the point cloud's structure, such as density or point distribution [14]. In comparing point clouds from different time steps, it is possible to measure changes in vegetation variables such as growth, increment, and site index [15].

An important aspect of map creation using lidar sources (either point clouds or rasterized clouds) is map readability and the balance between the amount of detail and readability. A higher level of detail includes more information, but such maps are not easily readable, which can lead to erroneous conclusions, as noted in [4]. Therefore, there is a need for standardized and objective simplification of map products (usually called feature generalization or simplification).

Generalizing a map involves simplifying, removing details from, enlarging, or modifying a map so that its final form is as legible and understandable as possible, while preserving source data and essential map attributes [16]. In this study, we evaluated four algorithms for polygon simplification created by the automatic subtraction of two consecutive lidar scans: the Douglas–Peucker, Visvalingam–Whyatt, Zhou–Jones, and Wang–Müller algorithms.

The Douglas–Peucker algorithm reduces the number of points in a curve that is approximated by a series of points, depending on the maximum distance between the original curve and the simplified curve. The algorithm recursively eliminates points that are closer to the line connecting the two endpoints of the curve than the specified tolerance [17]. This algorithm is also known as the Ramer–Douglas–Peucker algorithm, after Urs Ramer in addition to David Douglas and Thomas Peucker, who independently developed it in 1972 and 1973, respectively. The algorithm is widely used in computer graphics, cartography, and GIS applications. Despite the fact that the Douglas–Peucker algorithm was developed to simplify watercourse lines so that redundant points could be removed while preserving information, it also has applications in digital cartography [18]. It is a vertex

subsampling algorithm that independently alters individual polylines using a simplification process that considers only the sequence of vertices within the polyline itself, without considering surrounding features. The algorithm's output consists of a subsequence of the original polyline's vertices that represents the simplified output polyline's vertices in their original order [19]. The Douglas–Peucker algorithm and the Visvalingam–Whyatt algorithm are prone to remove small bends, resulting in less accurate representations of small watercourses [20]. Unlike these algorithms, the Wang–Müller algorithm preserves the characteristic properties of natural features [21]. In addition to line simplification, the Douglas–Peucker and Visvalingam–Whyatt algorithms are also suitable for line segmentation [21] or generalization [22]. The Visvalingam–Whyatt algorithm also preserves the geometry of an area while smoothing its contours [23].

To evaluate the accuracy of these algorithms, one can interpret their results as a raster classification result. The classification process is widely used to transform image data into map products; each pixel is categorized into one of multiple categories: typically two or more [24]. A confusion matrix is commonly used to describe thematic map accuracy and to compare accuracies. However, it can also be used to derive more useful information, such as refining estimates of the areal extent of classes in a region and optimizing a thematic map for a particular user. This can be accomplished by using the matrix together with information regarding actual error costs of the map's value. The reliability of the confusion matrix is important, as issues such as sample design and ground data accuracy can affect its accuracy [25].

In this study, we identified and estimated clear-cuts using ALS data and compared them to clear-cuts indicated on a forest management plan created by a human operator. Four polygon simplification algorithms were compared with each other, and their accuracies were assessed using the forest management plan, which served as ground-truth data. The automatic map creation method provides consistency and repeatability, and it can significantly decrease the time required for manual delineation.

## 2. Materials and Methods

### 2.1. Study Site

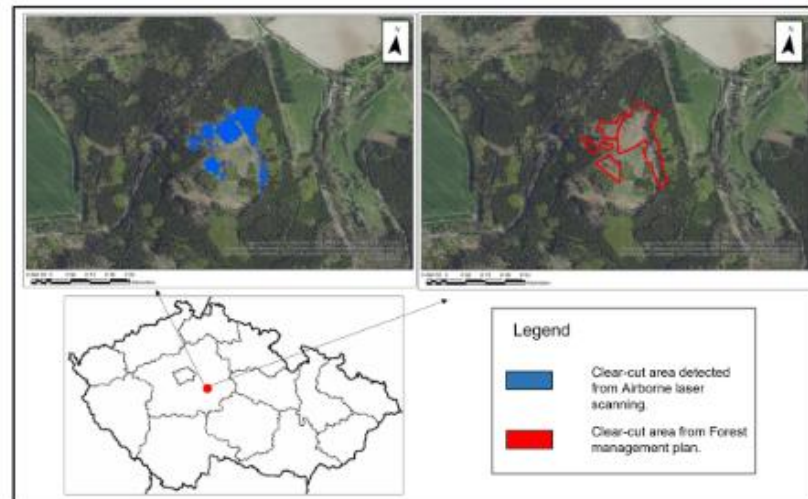
Our research area of interest was the School Forest Enterprise in Kostelec nad Černými lesy. ŠLP Kostelec nad Černými lesy is a university forestry estate of the Czech University of Agriculture in Prague. It is located 25–50 km southeast of Prague (Figure 1). The area's altitude varies from 210 to 528 m, its average annual temperature is 8.14 °C, and its average annual precipitation is 663 mm [26]. The area is approximately 6000 ha, and it is actively managed. The area is in beech–oak (21%), oak–beech (53.8%), and beech (25.2%) vegetation stages. Its tree species composition includes Norway spruce (*Picea abies* (L.) H. Karst.) (55%), Scots pine (*Pinus sylvestris* L.) (18%), European beech (*Fagus sylvatica* L.) (12%), Sessile oak (*Quercus petraea* (Matt.) Liebl.) (9%), European silver fir (*Abies alba* Mill.) (2%), hornbeam (*Carpinus betulus* L.) (1%), and other woods (3%). There are also several protected areas within the ŠLP territory, of which the Voděradské Bučiny National Nature Reserve, with an area of 683 ha, is one of the most important.

### 2.2. Data Processing

Data from airborne laser scanning (ALS) were processed in the Anaconda programming environment (Anaconda, Inc., Austin, TX, USA), using the Python programming language, version 3.11.1 (Python Software Foundation, Beaverton, OR, USA). The Point Data Abstraction Library (PDAL), version 2.6.0 (Hobu, Inc., Iowa City, IA, USA), a library equipped with prebuilt commands for various analyses, was employed to interpret laser data. With the help of this library, data were filtered, classified, and converted from laser point clouds to raster data; the PDAL was used to classify ground returns using the simple morphological filter (SMRF) technique, version 2.6.0 (Hobu, Inc., Iowa City, IA, USA). This algorithm effectively discriminated points into two distinct groups: ground and nonground. Initially, an outlier filter was applied to classify outliers with a classification value of 7.



These outliers were subsequently excluded during SMRF processing using the “ignore” option. Finally, a range filter was implemented to extract the ground returns, identified by a classification value of 2 [27].



**Figure 1.** The study area.

#### Rasterization

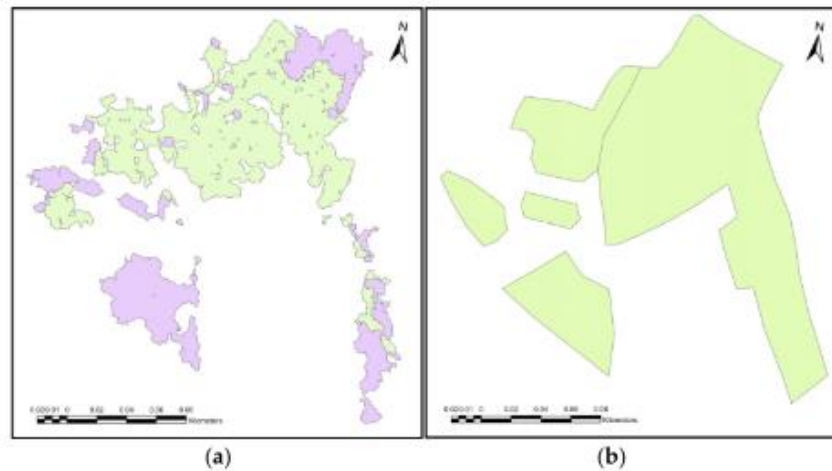
We used the PDAL to create a raster surface utilizing a fully classified point cloud via PDAL's `writers.gdal` functionality [28]. ArcGIS Pro 3.0.0 software (Environmental Systems Research Institute (ESRI), Redlands, CA, USA) was used for subsequent data processing.

The readability problem originates in the actual shapes of detected clear-cut areas. Although the maps are geometrically and positionally correct, they appear strange to the human observer and may become illegible, for example, in larger scale contour maps. Thus, a simplification of their shape is inevitable.


Two processes were needed to simplify and smooth surfaces to solve the two problems visible in Figure 2. The first was to close the holes in the polygons. These holes represented individual standing trees around which the parent growth had already been removed. The second problem was the polygon's shape, which contained complicated curvatures. The “eliminate polygon part” tool was used to address the first problem; we used this tool to close holes created inside the polygons (Figure 2a).

A sample of polygons of clear-cut areas was selected for evaluation. The shapes of clear-cut areas in the forest management plan were used as validation data. Figure 2 shows a comparison of the shape of one clearing sample resulting from airborne laser scanning and the validated clear-cut area from the forest management plan.

In this study, we used multitemporal laser datasets from 2021, 2020, and 2019. We subtracted the 2021 and 2020 laser datasets from each other to form the 2021 clear-cut areas, and we used the same approach for the 2020 and 2019 laser datasets to form the 2020 clear-cut areas. In the first step, we removed the 2020 and 2021 ALS shape overlap using the “erase” tool and then combined them using the “merge” tool. We did not separately evaluate the clear-cut area for each year because the 2021 forest management plan plotted the clear-cut area and also included the 2020 clear-cut area. Clear-cut area classification results from the laser data contain holes (small polygons) that characterize individual trees or vegetation that are mapped at a greater resolution than the established threshold for classifying clear-cuts (Figure 3).



**Figure 2.** (a) Shape of the clear-cut area identified using ALS; (b) shape of the clear-cut area identified using the forest management plan. The green areas are the year 2020 and the purple areas are year 2021.




**Figure 3.** Clear-cut area classified using ALS data.

We closed these parts using the “eliminate polygon parts” tool and used the merged 2020 and 2021 clear-cut areas as an input layer. For the “condition”, we selected an area that removed parts smaller than the specified value; in our case, the threshold value was 4000 m<sup>2</sup> and was selected based on the rule that units below 0.4 ha are not distinguished. After these steps, the polygons were ready for simplification.

The “simplify polygons” tool was used to remove multiple polygon curvatures and simplify shapes. This tool uses four algorithms to simplify polygons as follows:


1. The retain critical points algorithm (Douglas–Peucker) functions based on the concept of reducing the number of points while preserving those that are crucial for defining the polygon’s shape. It iteratively eliminates points by dividing the line segment and repeating the process until no more points can be removed. Initially, it creates a line segment by connecting the first and last points. Next, it identifies the point on the line

segment that is farthest from the straight line connecting the endpoints. If the distance between this point and the straight line is smaller than the specified epsilon value (tolerance), the point is discarded. The algorithm then restarts the process with the remaining points between the endpoints, as proposed by Visvalingam and Whyatt in 1990 [18]. This simplified version of the Douglas–Peucker algorithm is demonstrated graphically in Figure 4.



**Figure 4.** The simplification procedure according to the Douglas–Peucker algorithm. In the first step, the first and the last points are connected by a line. In the second step, the algorithm identifies the point that is farthest from the line and then creates a new line originating from that point. In the third step, if the point’s distance from the line is less than epsilon, the point is removed. In the fourth step, a new line is created.


2. The Visvalingam–Whyatt algorithm, also known as the retain effective areas algorithm, identifies triangles with effective area and uses that information to remove vertices to simplify the polygon’s outline while preserving its overall shape characteristics. This method shares similarities with the Douglas–Peucker algorithm, but instead of a distance-based tolerance, it utilizes a triangle’s area as the tolerance criterion. The algorithm starts by identifying the smallest triangle and compares its area to a predefined value also called epsilon [29]. The areas of triangles are continuously compared to the tolerance value. The algorithm removes triangles whose areas are smaller than epsilon. This process is repeated until all triangles with areas smaller than the tolerance value are eliminated [18]. The simplification process using this algorithm is illustrated in Figure 5.



**Figure 5.** The polygon simplification procedure according to the Visvalingam–Whyatt algorithm. In the first step, triangles are formed between the points. In the second step, the smallest triangle is identified, and whether its area is smaller or larger than the specified epsilon is determined. In the third step, if the area is less than epsilon, the point associated with this triangle is discarded. In the fourth step, a new line is created.

3. The Zhou–Jones algorithm (Figure 6), known as the weighted effective area preservation algorithm, assesses the effective areas of triangles associated with each vertex. These effective areas are determined by considering the shape of the triangle and

various metrics, such as flatness, skewness, and convexity [30]. The computation of effective areas for triangles involves applying a weight factor to the initial effective area. This weight factor serves to capture certain aspects of the triangle's shape. Consequently, the introduction of weighted effective area values allows for the distinction between triangles that share the same area but exhibit different shape characteristics. Utilizing various weight definitions enables highlighting of different aspects of triangle shapes. In this context, the functions serve as filters. These filters designate certain triangles as "standard forms" by assigning them a weight of 1, making their effective areas equal under the filter. When examining a triangle's shape characteristics, parameters such as the base line length ( $W$ ), height ( $H$ ), and length of the middle line ( $ML$ ) are considered. These parameters allow the measurement of a triangle's flatness, skewness (deviation from an isosceles triangle with the same  $W$  and  $H$  values), and convexity (orientation relative to a predefined vertex order). There are two models that measure flatness. The first model, which constitutes a high-pass filter, gives priority to taller triangles and reduces the significance of flatter triangles. The second model, a low-pass filter, is identified as a symmetric version of the previously described high-pass filter; its purpose is to eliminate extreme points. The skewness filter is designed to retain points using effective triangles close to being isosceles. The convexity filter is characterized by a constant. If this constant is less than 1, the convexity filter tends to retain points with convex effective triangles. Otherwise, points with concave effective triangles are retained [30]. After weighted areas are calculated, the algorithm strategically eliminates vertices to achieve the maximum possible simplification of the line while still preserving its essential characteristics to the greatest extent possible [31].



**Figure 6.** The polygon simplification procedure according to the Zhou–Jones algorithm [31]. The algorithm first identifies triangles of effective area for each vertex (1). These triangles are then weighted using a set of metrics to compare the flatness, skewness, and convexity of each area (2). The weighted areas guide the removal of their corresponding vertices to simplify the line while retaining as much character as possible (3). In the last step (4), a new line is created [30].

4. The retain critical bends algorithm (Wang–Müller) aims to eliminate insignificant bends in polygons. Figures 7–9 depict the process for outline simplification. The minimum diameter for a semicircular bend is set as the tolerance and reference for bend removal. One of the operations in this algorithm is bend elimination (Figure 7); a curved segment is replaced with a straight line. As consecutive straight lines representing bends are not connected, the elimination process must be iteratively performed by removing local minimal bends in each loop. A local minimal bend refers to a bend smaller than both of its neighboring bend points, whereas at the endpoints it is assumed that bends are larger than their neighbors.



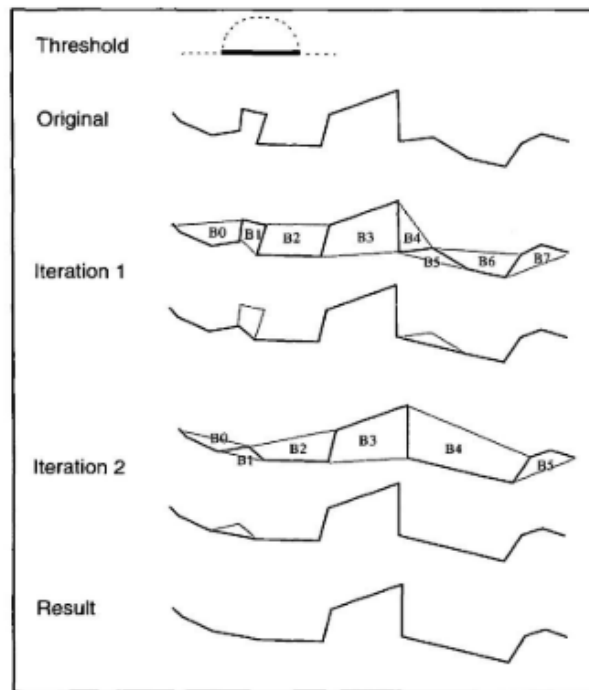


Figure 7. Bend elimination by iteration [32]. Numbers B0–B7 are line bends.




Figure 8. Combination of bends [32]. This figure shows three consecutive bends (a), and the goal of generalization is to combine the first and the third bends as one (b). There are three peaks labelled A, B, and C. Point D is the centre of line AC, and point D' is the peak of the combined bend.




Figure 9. Exaggeration using the Gaussian distribution [32].

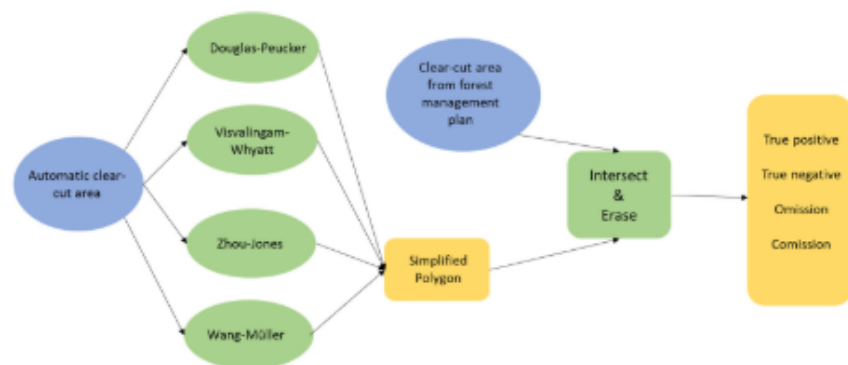
A second possible operation is bend combination (Figure 8). To determine the bend vertex, distances between the vertices and the two endpoint bend points are calculated, and the vertex with the largest sum is identified as the bend vertex. Subsequently, point D'

is created, representing the midpoint in the bend line, and becomes the new vertex. Finally, the left half of bend 1 and the right half of bend 3 are moved toward the new vertex  $D'$ .

The third operation is exaggeration (Figure 9). In this case, shape modification is achieved by enlarging and partially modifying the form. This method uses the Gaussian distribution. During the operation, a central point for translation is found, and instead of moving the endpoints farther from the center, the translation diminishes gradually from the center to the edge [32].

In the “simplify polygon” tool, in addition to establishing the simplification algorithm itself, the so-called simplification tolerance needs to be set. The simplification tolerance parameter is different for each algorithm, and it is referred to later in this text as “parameter” (occasionally it is referred to in the literature as “number”). In the retain critical points (Douglas–Peucker) algorithm, the tolerance parameter refers to the maximum perpendicular distance between each vertex and the resulting simplified line. In the retain critical bends algorithm (Wang–Müller), the tolerance parameter corresponds to the diameter of a circle that approximately represents a significant bend. In the retain weighted effective areas algorithm (Zhou–Jones algorithm), the tolerance square parameter represents the area of a significant triangle formed by three consecutive vertices. The more the triangle deviates from equilateral, the more weight it receives, so it is less likely to be removed. In the retain effective areas (Visvalingam–Whyatt) algorithm, a tolerance square parameter corresponds to the area of a significant triangle formed by three consecutive vertices [31].

Each step was automatically processed using the Python programming code within ArcGIS Pro (Figure 10).



**Figure 10.** The schematic model of data processing in ArcGIS Pro and the creation of evaluation metrics.

### 2.3. Statistical Analysis and Accuracy Assessment

We used error metrics to assess accuracy. We calculated the error of omission and the error of commission.

Classification results were used to estimate accuracy. The confusion matrix was used to evaluate correctly identified clear-cut areas; the matrix provided a summary of two types of errors [25]. Commission errors refer to areas characterized as clear-cut areas by the algorithm that are not actual clear-cut areas. Omission errors refer to actual clear-cut areas not identified as such by the algorithm [33]. Overall accuracy describes how many  $p$  pixels (of the total) are classified correctly for all classes [34].

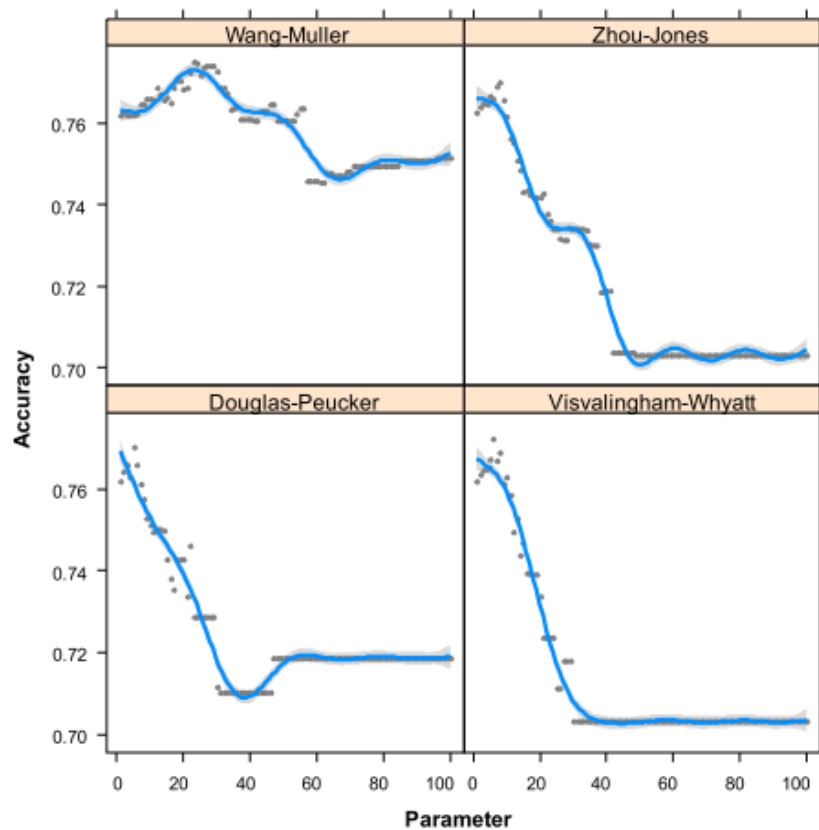
R 4.2.3 software was used to perform the statistical analysis [35]. The accuracy of each algorithm type in relation to the parameter value was compared using generalized additive models (GAMs) in the mgcv package v1.8.42 [36] (Wood, 2017) due to strong nonlinear relationships. GAMs with Gaussian errors were used because the accuracy measurements had a restricted range, and the variance was homoscedastic. We fitted an ANCOVA model with the parameter as a covariate and the algorithm type as a factor. We compared a model

with and without interaction using the AIC. Thin-plate spline was used to fit the nonlinear trend. The resulting model was plotted using the visreg package v2.7.0 [37].

### 3. Results


The analysis showed that the polygon simplification method was suitable for simplifying polygons in forest-clearing detection.

There was a significant interaction between the parameter and algorithm type. Comparison of the accuracies among the four algorithms revealed a significant difference (GAM,  $F_3 = 5507$ ,  $p < 0.0001$ ,  $R^2 = 0.98$ , Figure 11). For parameter values less than 10, the accuracies of the four algorithms were similar, but for values higher than 10, the Wang–Müller algorithm outperformed the other three algorithms. The Wang–Müller algorithm’s maximum accuracy was achieved for a parameter value of 22.



**Figure 11.** The relationship between the parameter values and accuracies for the four algorithm types. The parameters selected were the Douglas–Peucker algorithm’s new line, the Wang–Müller algorithm’s circle diameter, the Zhou–Jones algorithm’s significant triangle area, and the Visvalingham–Whyatt algorithm’s significant triangle area. Estimated curves (blue) with their 95% confidence bands (gray) are shown. The parameters were the numerical settings for each algorithm’s simplification tolerance.

When comparing commission and omission errors, matrices showed that the Wang–Müller algorithm had the highest commission error but also the smallest omission error (Figure 12).



**Figure 12.** (a) Commission and (b) omission errors in the individual methods.

#### 4. Discussion

Cartographic generalization is a crucial phase in the map production process [38]. Our study demonstrated, in a forestry application, the use of simplification algorithms in ArcGIS Pro. Previous studies focused on simplifying roof shapes when using ALS and vector maps to create 3D building models, in which the authors used the Douglas–Peucker algorithm first, followed by the partitioning method, combining step edges with footprint maps [7]. Other articles focused on the simplification of urban residential area plans using raster and vector models with mathematical morphology and pattern recognition assisted by applying a neural network [39]. Using a simplification algorithm was also found to be appropriate when diluting data and preserving the trajectory curve of acquired in-vehicle GPS data, for which the Douglas–Peucker algorithm was found to be suitable [40]. Another article described utilizing generalization algorithms in an ArcGIS environment [41]; these authors used the same algorithms as in our analysis. After using the simplification algorithm, they smoothed the polygons in the GIS environment. Their results showed that the Douglas–Peucker algorithm was suitable for data compression and the removal of redundant polygon details. The disadvantage of this algorithm is that the resulting line contains sharp angles and spikes. Compared with the Douglas–Peucker algorithm, the Wang–Müller algorithm prioritizes the input geometry to a greater extent, which requires additional processing time [42]. Their article describes the development of a new algorithm to simplify polygons and lines representing hydrographic lakes and streams. To assess their new algorithm, they compared it with the well-known Douglas–Peucker algorithm and the Wang–Müller bend simplification algorithm. Their algorithm has no user-defined parameters, and it defines an error band that does not allow the simplified line to cross it. This ensures the accuracy of the resulting line. We also used the Douglas–Peucker and Wang–Müller algorithms, and ArcGIS uses two additional algorithms, the Zhou–Jones and Visvalingam–Whyatt algorithms, as described above. Previous studies compared the Douglas–Peucker and Wang–Müller algorithms, showing that the point-remove (Douglas–Peucker) algorithm could remove more points from the line, resulting in a more streamlined and adaptable database for users. However, it also led to the loss of the original line’s topological characteristics. The bend-simplify (Wang–Müller) algorithm removed fewer points from the line, and it preserved a topology closer to that of the original line. When combined with other topological elements on a map to assess proximity and adjacency, the Wang–Müller algorithm demonstrated better adjustment [43].

Modification of the clear-cut areas created by airborne laser scanning is essential for cartographic display. Manual processing is tedious and does not provide any significant advantages in cases with a large number of clear-cut polygons. In our study, 29 polygons had, in summary, 16,649 ALS vertices that required adjustment, leading to 841 plotted vertices that were illustrated in the forest management plan. Implementing the simplification algorithm enhanced the efficiency of polygon editing; manual modification is as much as two orders of magnitude slower than using this simplification tool.

## 5. Conclusions

Most of the published literature to date addresses the simplification of polygons in cartography, focusing on simplifying lines or polygons that represent watercourses, buildings, or land-unit boundaries. In this study, we addressed the problem of excessive detail displayed in forest clear-cut areas that occurs after autodetection data are extracted from airborne laser scanning. Polygon simplification is a suitable method to simplify the shapes of clear-cut areas when creating forest base maps. We used the ArcGIS Pro “geoprocessing” tool to simplify polygons in order to estimate and compare the accuracy of individual algorithms when compared with ground-truth data from the forest management plan. This tool used four simplification algorithm parameters: retain critical points (Douglas–Peucker algorithm), retain critical bends (Wang–Müller algorithm), retain weighted effective areas (Zhou–Jones algorithm), and retain effective areas (Visvalingam–Whyatt algorithm). Our results show that the Wang–Müller algorithm performed best when using a parameter in the 20 to 25 m range.

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

**Funding:** This research was funded by the Ministry of Agriculture of the Czech Republic, grant number QK21010435.

**Data Availability Statement:** Data are available on request for research purposes.

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

## References

- Schelhaas, M.J.; Fridman, J.; Hengeveld, G.M.; Henttonen, H.M.; Lehtonen, A.; Kies, U.; Krajnc, N.; Lerink, B.; Dhubbáin, Á.N.; Polley, H.; et al. Actual European Forest Management by Region, Tree Species and Owner Based on 714,000 Re-Measured Trees in National Forest Inventories. *PLoS ONE* **2018**, *13*, e0207151. [[CrossRef](#)] [[PubMed](#)]
- Luyssaert, S.; Marie, G.; Valade, A.; Chen, Y.Y.; Njakou Djomo, S.; Ryder, J.; Otto, J.; Naudts, K.; Lansø, A.S.; Ghattas, J.; et al. Trade-Offs in Using European Forests to Meet Climate Objectives. *Nature* **2018**, *562*, 259–262. [[CrossRef](#)] [[PubMed](#)]
- Pilli, R.; Grassi, G.; Kurz, W.A.; Moris, J.V.; Viñas, R.A. Modelling Forest Carbon Stock Changes as Affected by Harvest and Natural Disturbances. II. EU-Level Analysis. *Carbon Balance Manag.* **2016**, *11*, 20. [[CrossRef](#)] [[PubMed](#)]
- Ceccherini, G.; Duveiller, G.; Grassi, G.; Lemoine, G.; Avitabile, V.; Pilli, R.; Cescatti, A. Abrupt Increase in Harvested Forest Area over Europe after 2015. *Nature* **2020**, *583*, 72–77. [[CrossRef](#)] [[PubMed](#)]
- Picard, N.; Leban, J.M.; Guehl, J.M.; Dreyer, E.; Bouriaud, O.; Bontemps, J.D.; Landmann, G.; Colin, A.; Peyron, J.L.; Marty, P. Recent Increase in European Forest Harvests as Based on Area Estimates (Ceccherini et Al. 2020a) Not Confirmed in the French Case. *Ann. For. Sci.* **2021**, *78*, 1–5. [[CrossRef](#)]
- Breidenbach, J.; Ellison, D.; Petersson, H.; Korhonen, K.; Henttonen, H.; Wallerman, J.; Fridman, J.; Gobakken, T.; Astrup, R.; Næsset, E. No “Abrupt Increase in Harvested Forest Area over Europe after 2015”—How the Misuse of a Satellite-Based Map Led to Completely Wrong Conclusions. In Proceedings of the vEGU21, The 23rd EGU General Assembly, Online, 19–30 April 2021; Volume 77, p. 13243.
- Zielewska-Büttner, K.; Adler, P.; Ehmann, M.; Braunisch, V. Automated Detection of Forest Gaps in Spruce Dominated Stands Using Canopy Height Models Derived from Stereo Aerial Imagery. *Remote Sens.* **2016**, *8*, 175. [[CrossRef](#)]
- Yu, X.; Maltamo, M. Methods of Airborne Laser Scanning for Forest Test Site and Applied Laser Scanner Data. In Proceedings of the Workshop on 3D Remote Sensing in Forestry, Vienna, Austria, 14–15 February 2006; pp. 1–16.
- Su, J.; Bork, E. Influence of Vegetation, Slope, and LiDAR Sampling Angle on DEM Accuracy. *Photogramm. Eng. Remote Sens.* **2006**, *72*, 1265–1274. [[CrossRef](#)]
- Maltamo, M.; Eerikäinen, K.; Pitkänen, J.; Hyyppä, J.; Vehmas, M. Estimation of Timber Volume and Stem Density Based on Scanning Laser Altimetry and Expected Tree Size Distribution Functions. *Remote Sens. Environ.* **2004**, *90*, 319–330. [[CrossRef](#)]
- Mielcarek, M.; Stereńczak, K.; Khosravipour, A. Testing and Evaluating Different LiDAR-Derived Canopy Height Model Generation Methods for Tree Height Estimation. *Int. J. Appl. Earth Obs. Geoinf.* **2018**, *71*, 132–143. [[CrossRef](#)]
- Stereńczak, K. Factors Influencing Individual Tree Crowns Detection Based on Airborne Laser Scanning Data. *For. Res. Pap.* **2014**, *74*, 323–333. [[CrossRef](#)]
- Räty, M.; Kankare, V.; Yu, X.; Holopainen, M.; Vastaranta, M.; Kantola, T.; Hyyppä, J.; Viitala, R. Tree Biomass Estimation Using ALS Features. In Proceedings of the SilviLaser 2011, Hobart, Australia, 16–20 October 2011; pp. 1–8.



14. Nijland, W.; Coops, N.C.; Ellen Macdonald, S.; Nielsen, S.E.; Bater, C.W.; John Stadt, J. Comparing Patterns in Forest Stand Structure Following Variable Harvests Using Airborne Laser Scanning Data. *For. Ecol. Manage.* **2015**, *354*, 272–280. [CrossRef]
15. Tompalski, P.; Coops, N.C.; White, J.C.; Goodbody, T.R.H.; Hennigar, C.R.; Wulder, M.A.; Socha, J.; Woods, M.E. Estimating Changes in Forest Attributes and Enhancing Growth Projections: A Review of Existing Approaches and Future Directions Using Airborne 3D Point Cloud Data. *Curr. For. Rep.* **2021**, *7*, 1–24, Correction in *Curr. For. Rep.* **2021**, *7*, 25–30. [CrossRef]
16. Ruas, A. Map Generalization. In *Encyclopedia of GIS*; Springer: Boston, MA, USA, 2008; pp. 631–632. [CrossRef]
17. Pfaltz, J.L.; Rosenfeld, A. Computer Representation of Planar Regions by Their Skeletons. *Commun. ACM* **1967**, *10*, 119–122. [CrossRef]
18. Visvalingam, M.; Whyatt, J.D. The Douglas-Peucker Algorithm for Line Simplification: Re-evaluation through Visualization. *Comput. Graph. Forum.* **1990**, *9*, 213–225. [CrossRef]
19. Saalfeld, A. Topologically Consistent Line Simplification with the Douglas-Peucker Algorithm. *Cartogr. Geogr. Inf. Sci.* **1999**, *26*, 7–18. [CrossRef]
20. Jakštys, M. Wang—Müller Algorithm Realization for Cartographic Line Generalization. 2021, p. 54. Available online: <https://git.jakstys.lt/motiejus/wm/raw/branch/main/mj-msc-full.pdf>. (accessed on 7 December 2023).
21. García Balboa, J.L.; Ariza López, F.J. Sinuosity Pattern Recognition of Road Features for Segmentation Purposes in Cartographic Generalization. *Pattern Recognit.* **2009**, *42*, 2150–2159. [CrossRef]
22. Blaszczyk-Bak, W.; Janowski, A.; Kamiński, W.; Rapiński, J. Optimization Algorithm and Filtration Using the Adaptive TIN Model at the Stage of Initial Processing of the ALS Point Cloud. *Can. J. Remote Sens.* **2012**, *37*, 583–589. [CrossRef]
23. Costa, R.L.C.; Miranda, E.; Dias, P.; Moreira, J. Evaluating Preprocessing and Interpolation Strategies to Create Moving Regions from Real-World Observations. *ACM SIGAPP Appl. Comput. Rev.* **2020**, *20*, 46–58. [CrossRef]
24. Shao, G.; Tang, L.; Liao, J. Overselling Overall Map Accuracy Misinforms about Research Reliability. *Landsc. Ecol.* **2019**, *34*, 2487–2492. [CrossRef]
25. Katusoko, C. Land Cover Classification Accuracy Assessment. *Springer Geogr.* **2022**, *80*, 105–118. [CrossRef]
26. Available online: <https://arboretum.czu.cz/en/r-12506-o-arboretu/r-12526-prirodni-a-klimaticke-podminky> (accessed on 7 December 2023).
27. Available online: <https://pdal.io/workshop/exercises/analysis/ground/ground.html> (accessed on 7 December 2023).
28. Available online: <https://pdal.io/en/2.4.3/workshop/exercises/analysis/dtm/dtm.html> (accessed on 7 December 2023).
29. Botto-Tobar, M.; Barzola-Monteses, J.; Santos-Baquerizo, E.; Espinoza-Andaluz, M.; Yáñez-Pazmiño, W. Preface. In *Computer and Communication Engineering, First International Conference, Proceedings of the ICCCE 2018, Guayaquil, Ecuador, 25–27 October 2018*; Springer: Berlin/Heidelberg, Germany, 2019; p. 959. [CrossRef]
30. Zhou, S.; Jones, C.B. Shape-Aware Line Generalisation With Weighted Effective Area. In *Developments in Spatial Data Handling, Proceedings of the 11th International Symposium on Spatial Data Handling, Leicester, UK, 23–25 August 2004*; Springer: Berlin/Heidelberg, Germany, 2006; pp. 369–380. [CrossRef]
31. Available online: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/cartography/simplify-line.htm> (accessed on 7 December 2023).
32. Wang, Z.; Müller, J.C. Line Generalization Based on Analysis of Shape Characteristics. *Cartogr. Geogr. Inf. Sci.* **1998**, *25*, 3–15. [CrossRef]
33. Lu, M.; Chen, B.; Liao, X.; Yue, T.; Yue, H.; Ren, S.; Li, X.; Nie, Z.; Xu, B. Forest Types Classification Based on Multi-Source Data Fusion. *Remote Sens.* **2017**, *9*, 1153. [CrossRef]
34. Shao, G.; Wu, J. On the Accuracy of Landscape Pattern Analysis Using Remote Sensing Data. *Landsc. Ecol.* **2008**, *23*, 505–511. [CrossRef]
35. R Core Team. *R: A Language and Environment for Statistical Computing*; R Foundation for Statistical Computing: Vienna, Austria, 2023; Available online: <https://www.R-project.org/> (accessed on 7 December 2023).
36. Wood, S.N. *Generalized Additive Models: An Introduction with R*, 2nd ed.; Chapman and Hall/CRC: Boca Raton, FL, USA, 2017.
37. Breheny, P.; Burchett, W. Package ‘visreg’: Visualization of Regression Models. *R J.* **2017**, *9*, 56–71. [CrossRef]
38. Allouche, M.K.; Moulin, B. Amalgamation in Cartographic Generalization Using Kohonen’s Feature Nets. *Int. J. Geogr. Inf. Sci.* **2005**, *19*, 899–914. [CrossRef]
39. Wang, H.L.; Wu, F.; Zhang, L.L.; Deng, H.Y. The Application of Mathematical Morphology and Pattern Recognition to Building Polygon Simplification. *Acta Geod. Cartogr. Sin.* **2005**, *34*, 269–276.
40. Wang, X.; Liu, S. Vehicle Trajectory Optimization Based on Limiting Average Algorithm. *IEEE Access* **2021**, *9*, 9595–9599. [CrossRef]
41. Badea, G.; Eng, P.; Bucharest, E. On the Generalization Algorithms Applied in Gis Environment. 2021, pp. 15–22. Available online: [https://www.researchgate.net/publication/342658887\\_On\\_the\\_Generalization\\_Algorithms\\_Applied\\_in\\_GIS\\_Environment](https://www.researchgate.net/publication/342658887_On_the_Generalization_Algorithms_Applied_in_GIS_Environment) (accessed on 7 December 2023).

42. Gökgöz, T.; Sen, A.; Memduhoglu, A.; Hacı, M. A New Algorithm for Cartographic Simplification of Streams and Lakes Using Deviation Angles and Error Bands. *ISPRS Int. J. Geo-Inf.* **2015**, *4*, 2185–2204. [[CrossRef](#)]
43. Alves, M.; Santo, D.; De Oliveira, F.H. Algorithms for Automated Line Generalization in GIS. In Proceedings of the Twenty-Eighth Annual ESRI User Conference, San Diego, CA, USA, 4–8 August 2008.

**Disclaimer/Publisher’s Note:** The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

## 7.2 Využitia metód strojového učenia a pokročilých štatistických metód pre odhad zásob lesných porastov

### A Note on Statistical Techniques and Biological Background in Analysis of Remote Sensed Data in Forest Inventory

V tejto práci využívame niekoľkých štatistických metód na hodnotenie lesných zdrojov v súvislosti s inventarizáciou lesov, najmä otázky veľkosti dátových sád, kde čas a zdroje potrebné na získanie údajov sú často v protiklade k veľkosti vzorky a analýze všetkých potenciálnych parametrov potenciálnych modelov. Dáta sme porovnali dvomi regresnými technikami a jednu metódu strojového učenia (RandomForest) na analýzu prediktorov pre odhad objemu dreva. Všetky hodnotené techniky poskytli podobné výsledky z hľadiska presnosti a relatívne podobné z hľadiska najdôležitejších premenných vybraných na modelovanie. Ukázalo sa, že niektoré premenné viedli k nesprávnym predpovediam pri testovaní na nezávislých údajoch a ich odstránenie z modelu zlepšilo presnosť. Preto sme dospeli k záveru, že v menších súboroch údajov by sa pri predikcii a extrapolácii údajov mohla vziať do úvahy biologická analýza prediktorov.

*Publikované ako:*

Surový, P., & Melichová, Z. (2023). A Note on Statistical Techniques and Biological Background in Analysis of Remote Sensed Data in Forest Inventory. *Formath*, 22(0), 8. <https://doi.org/10.15684/formath.22.003>

*Prínosy autorov*

Konceptualizácia: Získanie finančných prostriedkov: Výskum: PS, ZM; Metodika: PS, ZM; Projektová administrácia: PS, ZM; Dohľad: PS a ZM; PS Písanie - pôvodný návrh; ZM; Písanie - recenzia a editácia: PS; prim: ZM, PS



## **Rozšírené zhrnutie**

## A Note on Statistical Techniques and Biological Background in Analysis of Remote Sensed Data in Forest Inventory

Peter Surový<sup>1\*</sup> , Zlatica Melichová<sup>1</sup>

**Abstract:** In this work we discuss possibilities and challenges in utilization of several statistical methods for assessment of forest resources related to forest inventories, especially question of dataset size where the time and resources required for data collection are often in contrast to sample size and analysis of all potential parameters of potential models. The combination of a priori knowledge of the phenomena being studied (tree number, wood volume, etc.) and understanding of behavior of individual variables provided by remote sensing instruments (different predictor variables) is crucial for production of reliable models for forest resource assessment. Using our dataset, we compared two regression techniques and one machine learning for predictor analysis for wood volume estimation. All techniques in general provided similar results in terms of variable importance and accuracy, but in more detailed analysis differences appeared, indicating that if possible biological knowledge and understanding of variables should not be neglected.

**Keywords:** forest resources, Partial Least Square Regression, Random Forest, remote sensing, statistical techniques, Stepwise Linear Regression

### 1. Introduction

Forest resources and the knowledge of the situation of forests is of principal importance for any decision making on the landscape or state level. Assessment of the forest information is usually done by terrestrial methods coupled with extensive statistical techniques and models for extrapolation of data to the unmeasured areas or to calculate summary values for large areas. National inventories represent the most modern and accurate tool for assessment of forest resources from the ground and are being regularly executed practically in all developed countries. The National Forest Inventories (NFIs), which aim to provide actual and aggregated data on the status and development of forests, are often supported by remote sensing. Usually more as guiding data indicating whether in some place exist or not a forest in case of grid data, or are used for replacement of inventory sample plots in case of some obstacle or inaccessibility. The main advantage of the terrestrial inventory that the field specialist can measure all necessary variables directly, including those which are usually invisible from space or above air, like lying dead wood, regeneration trees under canopy, seedlings, vegetation cover etc. On the other hand, especially in natural, close to nature or very irregular forest areas the required sample density may not be sufficient for reliable and accurate summary values because the individual plot is difficult to extrapolate to neighboring areas which might (and in case of close to nature forestry) should be different.

In general, remote sensing methods can be divided into active and passive remote sensing. Active means some active sensor is placed on board of the carrier which actively emits source of some kind of radiation and measure the reflectance coming back from the surface. Probably the most famous is LiDAR but also other radio and ultrasound-based systems exists. The main advantage of active sensor is that it is nearly independent on weather conditions (apart of obstacles light clouds etc.), and can scan also shaded parts (behind rocks, hills etc.), it is possible to do scanning of required area for example during the night, what have several advantages for aviation. Disadvantage of active sensors is that they are usually more expensive, which is reflected in the price of acquired data. Advantage of passive sensors is that they are cheaper and can be usually carried on smaller airplanes which can make the final product relatively cheap, and from technical point of view the laser beam can hit only particular point on stem what does not necessarily represent a tree surface or crown peak, especially

Received Sept. 10, 2022; Accepted Jun. 5, 2023

<sup>1</sup>Czech University of Life Sciences Prague, Czech

\*Corresponding Author: psurovy@gmail.com

©2023 The Authors. Published by FORMATH Research Society.

This is an open access article under a Creative Commons [Attribution 4.0 International] licence.

(<https://creativecommons.org/licenses/by/4.0/>) 

on low density clouds, while passive sensor averages the area of the pixel making the resulting DSM more compact.

As for processing, we have individual tree detection (ITD) method and area-based approach (ABA) (Yu et al. 2010). The ITD method requires locating the top of the tree and delineating the crown. Subsequently, the attributes are derived from the properties of the point cloud in each defined crown. The disadvantage of this method is that it is prone to errors caused by inaccuracies in tree identification and subsequent over or under crown segmentation. In the area-based approach, vegetation attributes are estimated for a grid cell, based on metrics summarizing the distribution of the point cloud inside the cell. A grid cell is thus the basic unit and offers more spatial detail than a polygon-based inventory. It also avoids systematic errors often introduced in ITD as described by (Tompalski et al. 2018).

### Individual Tree Detection

The main problem of ITD is tree segmentation, a step to divide the total points into groups that represent individual trees. There are two main tree segmentation strategies: raster and point. In the raster strategy, the 3D model is converted to a Canopy Height Model (CHM), a raster, and then tree tops are detected using 2D image processing imaging techniques such as local maxima, region growing and watershed or inverse watershed. In the second strategy, trees are segmented directly on the basis of 3D points using techniques such as rule-based distance and height thresholding, voxel-based, graph-based and kernel-based methods (Xiao et al. 2019).

When using the individual tree delineation (ITD) approach, the already mentioned segmentation is an important step, during which various methodologies were investigated. In their paper, the authors (Xiao et al. 2019) evaluated the mean shift algorithm for aerial lidar data segmentation and tree top detection to validate the segmentation results. They implemented the algorithm in terms of Kernel shape, adaptability and weight. Results from three different datasets showed that the crown-shaped kernel consistently shows 7% better results than the other variants.

### Area-Based Approach

Area-based approach is carried out in two steps:

1. In the first step, Airborne Laser Scanning (ALS) data is obtained for the entire area of interest, measured tree values are obtained on the sample plots, and predictive models such as regression and non-parametric methods are developed. To develop the model, the ALS point cloud is clipped to the corresponding region of sample plots. Metrics, which are descriptive statistics, are calculated from the rasterized normalized ALS point cloud and include height derivation, height percentiles and other descriptors. Ground sampling areas should be representative of the entire population and contain the full range of variability of the raster or the pointcloud itself.
2. In the second step, the model is applied to the entire area of interest to generate wall-to-wall estimates and maps of a specific forest inventory attribute. The same metrics that are calculated for the sampled ALS point cloud are generated for the wall-to-wall ALS data. The predictive equations developed in the first step are then applied to the entire area of interest using wall-to-wall metrics. A sample unit is a grid cell, the size of which depends on the size of land areas. Once the predictive equations are applied, each grid cell will have an estimate for the attribute of interest (White et al. 2013).

### Statistical Analysis

As it was written before the statistical models and methods are the base for estimation of desired variable over all territory. In general, we can define three approaches to model building. Regression based model, machine learning and nowadays popular deep neural networks. In this work we compare only regression and machine learning (more precisely Random Forest and discuss the impact on the final estimation accuracy). The main challenge in estimation of quality of the model is the choice of

predictors which works best for the accuracy. Finally, the last decision is whether or not to split the data into training and validation model, which is common technique, though for classical regression the classical goodness of fit (like coefficient of determination) may be used with sufficient validity.

## 2. Method

We compare different approaches for creation of statistical models for area-based estimation of volume in individual forest stands. As the study data we are using ground data from different plot sizes, the definition of plot is compact unit of forest visible on the LiDAR-based raster. The raster is based on LiDAR scan with approximately 5 points per square meter and it was rasterized using resolution of 1 meter. The purpose of this study is to benchmark different techniques on the same dataset.

For the polygons of ground measured plots following raster characteristic were obtained in ArcGIS Pro (ESRI) : MIN, MAX, RANGE, MEAN, STD, SUM, MEDIAN, PCT90 . These are common descriptors for a given area of the raster. PCT90 is the 90th percentile which is one of the metrics describing vertical structure of the vegetation. It is percentile of point heights, i.e. 90% of ALS points are lower than this height (White et al. 2017).

Many other can be provided but these can be considered as the principal ones with following meaning: MIN, MAX, RANGE represent the minimum, maximum and range of values of height in a given polygon and are related to extreme values in the area, usually MIN represents ground, in case there is no ground it represents the lowest vegetation. MEAN, MEDIAN and PCT90 are point estimates of individual cell heights within the polygon. Here it has to be noted that the estimates are related, in terms of forest, not to the mean height of trees or so, but to the mean height value of the cells in a given polygons, what means that the if the polygon has lower tree density and this is reflected in the raster characteristics (more cells with zero height) the MEAN value will be lower. In extreme case: a polygon of one hectare with one solitaire tree with height 30 meters would have MEAN value close to zero, or probably less than one meter, because the MEAN represents the average value of the cells. The same is valid for MEDIAN and PCT90, where PCT90 is of course less sensitive to the area related problem. SUM is a summary value of all heights in the polygon, basically it is multiplication of mean by area, so it takes to account the size of the polygon and the heights of the individual cells. STD is standard deviation and it is expected to describe the variation of heights of the individual cells, usually related to the canopy density or stocking. More variation can mean more sparse tree positions, less variation then represents more closed canopy.

We use R studio and following packages: Partial Least Squares Regression (<https://CRAN.R-project.org/package=pls>), caret package (<https://CRAN.R-project.org/package=caret>) and Random Forest package (<https://cran.r-project.org/package=randomForest>). Each of this method is commonly recognized and deployed in literature for modeling of underlying phenomena like wood volume, average diameter or tree amount. The main reason for these methods is to test all available predictors and either construct a model, either choose those variables which are most important for the model, in case the understanding of phenomena is complex.

Partial Least Squares (PLS) Regression is first technique evaluated. It was originally developed by (Wold 1966), and it is related to Principal Component Analysis (PCR) with the difference that PLS provides not only analysis of predictors but also the model, which can be directly deployed in estimation of, for example forest variables, in mapping areas. This technique was among others applied for example in (Luo et al. 2016). PLS is considered to be effective in overcoming of collinearity of LiDAR based predictors using projection of predictors and dependent variables onto new space. It is considered particularly useful for situation when there are more predictors than observed variables, though it is not the case in LiDAR data, also despite this, it is often used in literature. PLS provides variable importance estimation, e.g. their value on how much do they contribute to the model accuracy or variance explained.

Stepwise linear regression (SLR) is another statistical method useful for finding, handling or removing collinearity of the data, and similarly to partial least squares technique it creates a final model which may be utilized for mapping purposes. The stepwise linear regression was among other work used for example in (Sumnall et al. 2016), (Kim et al. 2009), (Lu et al. 2012), (Farid et al. 2008), (Skowronski et al. 2011), (Yang et al. 2022), (Badreldin and Sanchez-Azofeifa 2015) and it is as well as PLS considered important method for choosing among large set of possible predictors. Though

SLR has met with criticism (Harrell 2001) due to the several factors (including that R-squared values are too high and p-values are too low because of multiple comparisons) it is considered a valid option for investigating which variables plays important role for mapping purposes.

Finally, one of the most frequently used techniques nowadays, evaluated here is Random Forest (RF). Random Forest is considered machine learning algorithm based on Decision Trees algorithm which rank individual predictors based on their influence on misclassification and or GINI coefficient before and after the split (decision). Each decision tree consists of nodes and branches. The GINI index is used to decide whether a node that divides down the progression of the tree is placed as a root node, a leaf node, or internal nodes and decides the importance of the variable. This importance of variable is determined by summing the reduced GINI index for all nodes for and for each deciding tree in the Random Forest (Chen and Ishwaran 2012). Again, among many others, the method was used for example in (Li et al. 2022). Random Forest provides the variable importance and in contrast to previously mentioned two techniques it does not produce variable weight (like in case of linear regression) but the quality of the model can be evaluated using accuracy or test the accuracy on dataset which was not used for training. The three methods were implemented in R studio and the results are discussed.

### 3. Results and Discussion

The figure 1 shows individual values for volume (marked as *zasoba*) and the previously mentioned variables extracted for rasterized lidar.

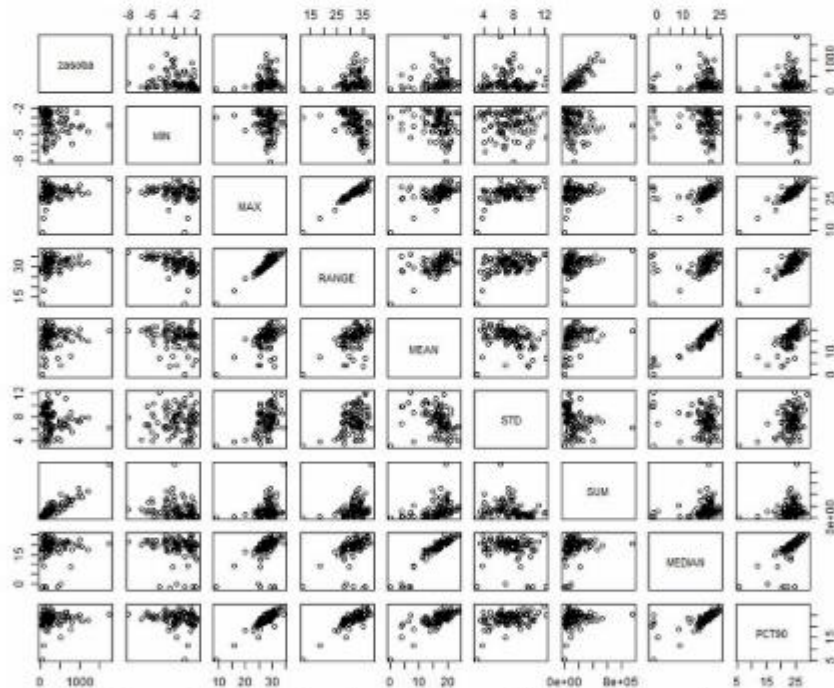


Figure 1. Scatter plot for available predictors and the volume.

It is possible to observe that the volume is mostly correlated with SUM and the other predictors show none or very little correlation (taking to account that this is only simple linear correlation). Though it can be observed the strong collinearity as mentioned before for example among: MAX and RANGE, or MEDIAN and PCT90, which is based on the vegetation properties. The MIN value has horizontal shape for the small min values, but later when MIN rises the RANGE decreases as expected (e.g. higher the MIN smaller the RANGE). MAX value is correlated with MEDIAN, PCT90 and MEAN which is caused by the vegetation total height in a given polygon.






Figure 2. Variable importance using Partial Least Square Regression.

Figure 2 shows results for variable importance using Partial Least Squares Regression from package caret in R. The amount of selected variable for best model is 3, e.g. including SUM, MIN and RANGE variable.

Overall quality of the model is reported by RMSE and coefficient of determination (R-squared) being these: 109,26 and 0.826 respectively. Figure 3 represents variable importance as produced by stepwise linear regression also from package caret. Similarly, as in previous case SUM is the most important variable. The final model though selects following combination of variable: SUM, MIN, STD, MEDIAN and MEAN, which is slightly in discordance with variable importance. We do not select the variables to the model, but the model selects the variables automatically.




Figure 3. Variable importance using Linear Regression with Stepwise Selection.

The quality of the model is estimated by RMSE and R-squared: 101.26 and 0.848 respectively. Finally the random forest algorithm was tested. Figure 4 represents the variable importance for individual predictors. Accordingly, to previous methods the SUM is the most important variable, but in contrast the MIN value usually selected among most important is for RF algorithm the least important one.

The RF models are usually considered more suitable for predictions and the regression more for the estimation of the relation itself. Therefore it is not needed for example to split to test and train




Figure 4. Variable importance using linear regression with Random Forest. %IncMSE value is a measure of how much our model’s accuracy decreases when a particular variable is randomly permuted. With increase %IncMSE value, also increases variable importance (Kuhn et al. 2008). IncNodePurity is derived from loss function. This index is measured on the basis of the Gini purity index. Higher node purity values (bigger blue circle) achieve more useful variables.

data because the RMSE or R2 indicators are sufficiently understandable for the relation quality. On the other hand for RF splitting train/test is reasonable for better evaluation of the accuracy but the sample size should then be high. In our case we are mostly interested in relation analysis so the splitting would not yield reliable results and the caret package in R allow estimation of RMSE and R2 also for Random Forest models (without split). These are 135.8 and 0.817 respectively. Summary is presented in following table:

Table 1. RMSE and R-square for the different error type

Error/type	PLS	SWR	RF
RMSE	109.26	101.26	135.8
R-square	0.826	0.848	0.817

It has to be noted that, though RF algorithm appears to be weakest among the 3 in terms of R-square value, it is not deployed here in the correct (split to train/test) form.

As an additional test we applied the individual models into areas where no ground data were collected and compared them with commonly acceptable hectare values of wood volume. Most of the values provided values within expected interval based on age and specie of the forest, except the areas where no ground (soil) data were caught within the polygon, e.g. dense forests with fully closed canopy where the minimum value of raster (MIN) was equal to higher part of canopy (for example 20 or more meters). In such situations especially in combination with very small total area of polygon the estimated volumes were extremely high. These observations is in accordance with work published by (Meyer and Pebesma 2022), where it was noted that the areas with no terrestrial verification data often run into risk of unwarranted model behavior and providing unrealistic values. Therefore, we recommend for model purposes either extend the ground sampling to all possible combination

of predictors, either limit model to those areas who are similar to sampling areas, either underline the interpretative biological background of predictors and verify by more methods which of them are less or more important.

#### 4. Conclusion

In this work we carried out a simple comparison of various techniques for statistical modeling of wood volume and analysis of predictors based on remote sensed data, more precisely rasterized Lidar scan. All the evaluated techniques provided similar results in terms of accuracy and relatively similar in terms of most important variables chosen for modelling. Some of variables proved to lead to incorrect predictions when tested on independent data and their removal from the model improved accuracy. Therefor we conclude that in smaller datasets biological analysis of predictors could be taken to account for prediction and extrapolation of the data.

#### Acknowledgement

This work is supported by Ministry of Agriculture of the Czech Republic, grant number QK21010435.

#### Disclosure Statement

The authors declare there are no conflicting interests.

#### Data Availability

Data are available on request for research purposes.

#### Author Contribution

Conceptualization: PS, ZM  
Funding acquisition: PS  
Investigation: PS, ZM  
Methodology: PS, ZM  
Project administration: N/A  
Supervision: PS  
Writing - original draft: ZM  
Writing - review & editing: ZM, PS

#### ORCID iDs

Peter Surový  <https://orcid.org/0000-0001-6637-8661>

#### References

- Badreldin, N., Sanchez-Azofeifa, A. (2015) Estimating Forest Biomass Dynamics by Integrating Multi-Temporal Landsat Satellite Images with Ground and Airborne LiDAR Data in the Coal Valley Mine, Alberta, Canada, *Remote Sens-Basel*. 7: 2832–2849.
- Chen, X., Ishwaran, H. (2012) Random forests for genomic data analysis, *Genomics* 99(6): 323–329.
- Farid, A., Goodrich, D.C., Bryant, R., Sorooshian, S. (2008) Using airborne lidar to predict Leaf Area Index in cottonwood trees and refine riparian water-use estimates, *J. Arid Environ.* 72(1): 1–15.
- Harrel, F. (2006) *Regression Modeling Strategies, With Applications to Linear Models, Logistic Regression, and Survival Analysis*, Springer, New York, 598p.



- Kim, Y., Yang, Z., Cohen, W.B., Pflugmacher, D., Lauver, C.L., Vankat, J.L. (2009) Distinguishing between live and dead standing tree biomass on the North Rim of Grand Canyon National Park, USA using small-footprint lidar data, *Remote Sens. Environ.* 113(11): 2499–2510.
- Kuhn, S., Egert, B., Neumann, S., Steinbeck, C. (2008) Building blocks for automated elucidation of metabolites: Machine learning methods for NMR prediction, *BMC Bioinformatics* 9(October).
- Li, Y., Wang, R., Shi, W., Yu, Q., Li, X., Chen, X. (2022) Research on Accurate Estimation Method of Eucalyptus Biomass Based on Airborne LiDAR Data and Aerial Images, *Sustainability-Basel* 14: 10576.
- Lu, D., Chen, Q., Wang, G., Moran, E., Batistella, M., Zhang, M., Vaglio Laurin, G., Saah, D. (2012) Aboveground Forest Biomass Estimation with Landsat and LiDAR Data and Uncertainty Analysis of the Estimates, *Int. J. For. Res.* 2012(1): 1–16.
- Luo, S., Chen, J., Wang, C., Xiaohuan, X., Zeng, H., Peng, D., Li, D. (2016) Effects of LiDAR point density, sampling size and height threshold on estimation accuracy of crop biophysical parameters, *Optics. Express*. 24: 11578.
- Meyer, H., Pebesma, E. (2022) Machine learning-based global maps of ecological variables and the challenge of assessing them, *Nat. Commun.* 13: 2208.
- Skowronski, N.S., Clark, K.L., Duveneck, M., Hom, J. (2011) Three-dimensional canopy fuel loading predicted using upward and downward sensing LiDAR systems, *Remote Sens. Environ.* 115(2):703–714.
- Sumnall, M., Peduzzi, A., Fox, T.R., Wynne, R.H., Thomas, V.A., Cook, B. (2016) Assessing the transferability of statistical predictive models for leaf area index between two airborne discrete return LiDAR sensor designs within multiple intensely managed Loblolly pine forest locations in the south-eastern USA, *Remote Sens. Environ.* 176: 308–319.
- Tompalski, P., Coops, N.C., Marshall, P.L., White, J.C., Wulder, M.A., Bailey, T. (2018) Combining Multi-Date Airborne Laser Scanning and Digital Aerial Photogrammetric Data for Forest Growth and Yield Modelling, *Remote Sens-Basel* 10(2): 1–21.
- White, J.C., Wulder, M.A., Varhola, A., Vastaranta, M., Coops, N.C., Cook, B.D., Pitt, D., Woods, M. (2013) A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach, *Forest. Chron.* 89(6): 722–723.
- White, J.C., Tompalski, P., Vastaranta, M. (2017) A model development and application guide for generating an enhanced forest inventory using airborne laser scanning data and an area-based approach Landsat Science Team Meeting Reports View project Bioenergy Solutions for Tomorrow View project (Issue December).
- Wold, H. (1966) *Estimation of principal components and related models by iterative least squares*, In: Krishnaiah, P.R. (ed.) *Multivariate Analysis*, Academic Press, New York, pp. 391–420.
- Xiao, W., Zaforemska, A., Smigaj, M., Wang, Y., Gaulton, R. (2019) Mean Shift Segmentation Assessment for Individual Forest Tree Delineation from Airborne Lidar Data, *Remote Sens-Basel* 11: 1263.
- Yang, Q., Su, Y., Hu, T., Jin, S., Liu, X., Niu, C., Liu, Z., Kelly, M., Wei, J., Guo, Q. (2022) Allometry-based estimation of forest aboveground biomass combining LiDAR canopy height attributes and optical spectral indexes, *For. Ecosyst.* 9(June): 100059.
- Yu, X., Hyyppä, J., Holopainen, M., Vastaranta, M. (2010) Comparison of Area-Based and Individual Tree-Based Methods for Predicting Plot-Level Forest Attributes, *Remote Sens-Basel* 2(6):1481–1495.

### 7.3 Odhad prírastku a bonity z bitemporálnych lidarových dát

#### **Bitemporal aerial laser scans as an alternative to site index estimation: A case study in the Bohemian Switzerland National Park.**

V štúdiu bol použitý Chapman-Richardsov rastový model pre odhad parametrov rastovej krivky. Dynamika prírastku má typický nelineárny tvar s nižšími počiatocnými hodnotami, nasledovanými vyššími hodnotami (mladý vek) a potom dosahuje hodnoty, kde sa zvyčajne ustáli dosiahne svoju asymptotu. Takéto správanie sa očakáva vo všetkých rastových krivkách, pretože opisuje typický biologický vývoj organizmu, a väčšina rastových kriviek sa dá ľahko prispôbiť takýmto dátam. Tieto rastové modely by mohli byť využité na hrubé odhady budúcich prírastkov výšky, ako je uvedené v štúdiu Woo et al. (2020). Zmienená asymptota sa potom často využíva práve pre odhad bonity porastu. Okrem odhadu bonity pomocou rastovej krivky, sme v práci skúšali odhad bonity už verifikovanej na zemi v LHP, pomocou vlastností bitemporálneho skenu. Inými slovami, vedecká hypotéza bola, že je možné odhadnúť bonitu stanovišťa. V prvej časti článku je na odhad bonity použitá metóda *stepwise regression*, na odhad parametrov lineárneho modelu za predpokladu, že bonita má rozdelenie aspoň blízke normálnemu.

Model1 bol využívajúci LiDARové metriky (a vo verzii „a“ aj vek) pre odhad absolútnej bonity za pomoci lineárnej regresie. Medzi prediktory bola zahrnutá premenná vek získaná z LHP. Zahrnutie veku pomocou Stepwise regression zvýšilo koeficient determinácie o niekoľko percent.

Model2 využíva metódu strojového učenia, konkrétne RandomForest na určenie absolútnej bonity bez veku. Ako najdôležitejšia premenná je zvolený medián rozdielov. Model2a využíva metódu strojového učenia, konkrétne RandomForest na určenie absolútnej bonity s veku. Podobne ako pri lineárnej regresii je najdôležitejším prediktorom vek.

Model3 sa zaoberá odhadom relatívnej bonity bez veku. Medzi najdôležitejšie premenné patrí opäť medián rozdielov. Model3a sa zaberá použitím strojového učenia na odhad relatívnu bonitu s vekom ako prediktorovú premennú, pričom vek je najdôležitejším prediktorom. Výsledná presnosť je najvyššia spomedzi všetkých modelov, vek je najdôležitejším prediktorom a opäť medián rozdielov patrí medzi najvplyvnejšie premenné. Na druhej strane, rozdiel oproti modelu bez veku je v tomto prípade pomerne malý.

*Publikované ako:*

Melichová, Z., Vébrová, D., Marušák, R., & Surový, P. (2024). Bitemporal aerial laser scans as an alternative to site index estimation: A case study in the Bohemian Switzerland National Park. *Central European Forestry Journal*.

*Prínosy autorov*

Konceptualizácia, Z.M. a P.S.; metodika, Z.M., a P.S.; softvér, Z.M. a P.S.; validácia, Z.M., R.M., a P.S.; formálna analýza, Z.M. a D.V.; výzkum, Z.M.; zdroje, P.S.; kurátorstvo údajov, Z.M., P.S., a R.M.; písanie - príprava pôvodného návrhu, Z.M. a P.S.; písanie - recenzia a úprava, Z.M. a P.S.; vizualizácia, Z.M.; dohľad, P.S.; administrácia projektu, P.S.; získavanie finančných prostriedkov, P.S. Všetci autori si prečítali a súhlasia s publikovanou verziou rukopisu.

**Bitemporal aerial laser scans as an alternative to site index estimation:  
A case study in the Bohemian Switzerland National Park.**

Zlatica Melichová<sup>1</sup>, Dana Věbrová<sup>2</sup>, Robert Marušák<sup>1</sup>, Peter Surový<sup>1</sup>

<sup>1</sup> *Faculty of Forestry and Wood Sciences, Czech University of Life Sciences Prague, Kamýcká 129, 16500 Prague, Czech Republic*

<sup>2</sup> *Department of Monitoring, The Bohemian Switzerland National Park Administration, Pražská 457/52, CZ-407 46 Krásná Lípa, Czech Republic*

**Abstract**

In this work, we present a study about the application of bi-temporal, large interval aerial laser scans for constructing of tree growth models and estimating site index quality based on the measured increments from the laser scans. We compared two lidar scans with 14 years of difference in the national park area, where most areas are unmanaged. We derived the increment curve based on the Chapman-Richard growth formula. We used site index estimates from forest management plans from the national scale as the ground truth (both absolute and relative). We constructed three predictive models for site index estimates from bi-temporal scans, in modalities with and without stand age. Including the stand age improved all models, but even without the age, the models performed relatively well for differentiation between better and worse sites. At this moment, it is not directly possible to estimate age from remotely sensed data, but consistent monitoring, with laser scanning or photogrammetry, undoubtedly detects the harvest or dieback, so in the future, age can be considered as a variable easily estimated from remotely sensed data and so remote sensed material are viable source for understanding of forest growth and production.

**Keywords:** site index; empirical models; bitemporal laser scanning, machine learning, height growth

## 1. Introduction

Knowledge about forest growth and development is one of the key pieces of information for sustainable forest management. Since the first inventories were based on permanent plots and their repeated measurements, the technology for estimating forest/tree growth has developed through dendrochronological methods till sophisticated 3D techniques based on architecture measurements (Antonelli 1992).

As the mensuration technologies developed, so have developed prediction techniques for forest growth. According to (Kurth & Anzola Jürgenson 1997), three main groups of models can be distinguished: empirical (also termed as aggregated), process-based, and morphological. The empirical models are mostly based on direct observation of the modeled variable like height, dbh., etc., and use mathematical functions from relatively simple ones (Richards 1959; Zhao-Gang & Feng-ri 2003; Nigul et al. 2021) to sophisticated mathematical methods allowing prediction of variety of behavior (Cieszewski & Strub 2018; Cieszewski 2001; Cieszewski et al. 2000). The second class of models is called process based or often mechanistic because of the underlying models for mechanism and processes including photosynthesis, respiration, etc. The third class, according to (Kurth & Anzola Jürgenson 1997), is called the morphological group of models which belongs to the description of plant's structure and development and systems aiming to provide structural information with the possibility of prolonging the prediction of future. Each of the modeling techniques can be differently linked to data. Authors generally use an empirical approach with variables directly estimated from remotely sensed material. To improve the forest inventory, it is advisable to include negative or zero values of height increment in the dataset. When predicting height increment, the difference in modeled heights - can be improved by using random effects models that explicitly account for observations of negative or zero height increments. Uncategorized these values can lead to models that are not fully representative of the entire population of trees being measured (Woo et al., 2020).

In recent years, LiDAR technology has gained great significance in the forestry sector (Muhamad-Afizzul et al., 2019). (Goodbody et al., 2021) describe several possibilities of incorporating airborne laser scanning into sustainable forest management and describing how the LiDAR is increasingly important as a meaningful method for sustainable management, not only from productive point of view but also from point of view of biodiversity mapping, forest

structure, ecosystem services and others. With the help of ALS, we can also obtain very accurate height estimates. If we also know what dominant species is expected in a stand, even if we do not have more detailed information about species composition, accurate volume estimates can be generated (Tompalski et al. 2014). However, several challenges could still be focused on in the future so that data from remote sensing is used more in forest inventory and monitoring programs (Fassnacht et al., 2023). Remote sensing provides opportunities to gather a wealth of information on forest attributes. In the last decade, advances in these processing technologies and algorithms have been rapid (White et al., 2015), enabling and facilitating the use of this data in forest monitoring. High-resolution three-dimensional data are useful in forest inventory (Vauhkonen et al., 2014). LiDAR technology is also suitable for clearcut detection. LiDAR technology is also suitable for clearcut detection. When we compare the technology of highly detailed image point clouds (IPCs) from aerial stereo images (which is usually cheaper than LiDAR) and LiDAR, this technology can detect major changes in the vegetation but is incapable of detecting minor changes, similar to LiDAR data (Ali-Sisto & Packalen, 2017).

At present, the impact of global climate change and the ever-increasing concentration of CO<sup>2</sup> in the air emphasize its sequestration. Forest ecosystems bind more carbon than all other terrestrial ecosystems (Næsset et al., 2011). Data from laser scanning has also found application in this area, where we can estimate aboveground and underground biomass (Silva et al., 2013). We can use the data difference from two time intervals to detect the change in biomass (Bollandsås et al., 2013). Reliable estimates of carbon stocks are also affected by the field plot size. From the technical point of view, increasing the plot size is relatively more efficient when ALS is used to enhance the estimates (Mauya et al. 2015).

Repeated measurements (separated by a time interval) of the same tree or stand can assess growth from remote sensing. Time differences in remote sensing data usually indicate growth directly or indirectly. LiDAR data, with the help of which we can derive the age, we can divide it into bitemporal (Ma et al., 2018) or multitemporal (Yu et al., 2005). Repeated measurements may be a substitute for measurements from permanent or temporary sample plots. It can be expected that with the improvement of technology and the reduction of costs, the accuracy of the estimate of height increments will increase (Socha et al. 2017). The first mentions in the current literature can be found in the work (Næsset & Gobakken, 2005), where the authors compare a shorter interval with a difference of 2 years (1999 and 2001) and evaluated the change

in forest conditions using LiDAR data and found the difference in 50<sup>th</sup> and 90<sup>th</sup> height percentile with the help of which they predicted a change in height, basal area, and volume. These data could predict the growth of variables over two years, even though the accuracy of measurements was low. There are two methods for deriving forest information from airborne laser scanning: Individual Tree Detection (IDT) (Yu et al., 2010) and Area Based Approach (ABA) (Tompalski, Coops, White, & Wulder, 2015b). The above-mentioned area-based approach for processing data from laser scanning for forest inventory has been used in Scandinavia since 2002 (Patočka & Mikita, 2016). The new approach was tested by utilizing airborne laser scanning (ALS), where (Tompalski et al., 2016) derived forest stand attributes to determine future growth and yield. A combination of ALS and DAP can be used to estimate growth and yield. The use of a combination of laser scanning data and digital photogrammetry to model growth and yield was described in the article (Tompalski et al., 2018), who are used two three-dimensional point cloud datasets from ALS (airborne laser scanning) and DAP (digital aerial photogrammetry). ALS can also be used in combination with satellite time series (Tompalski et al. 2015) (Tompalski, Coops, White, Wulder, et al., 2015) or aerial hyperspectral images (Bollandsås et al. 2019). LiDAR data is also suitable for estimating site index (SI). The authors (Noordermeer et al. 2018) used the estimation of heights from bitemporal laser data to estimate the site index of the area-based approach. The use of bitemporal data and an area-based approach proved to be suitable for estimating site index with reasonable accuracy. Utilizing bitemporal ALS data for site index determination necessitates the undisturbed height growth of dominant trees. The data effectively distinguished disturbed from undisturbed forest areas with moderate to high accuracy in complex temperate mixed wood forests. The exclusion of disturbed forest areas substantially improved the fit statistics of SI prediction models (Moan et al., 2023).

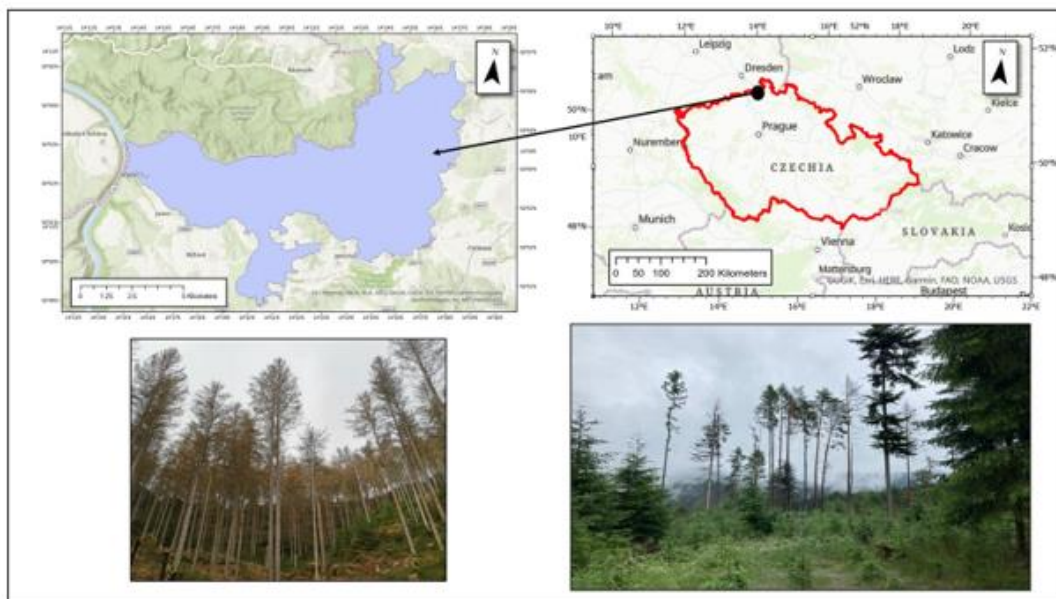
## 2. Materials and Methods

### 2.1 Study Area

Our area of interest for our research is The Bohemian Switzerland National Park. It is in the north-west of the Czech Republic, where the state border separates it from Germany and the Saxon Switzerland National Park (Fig. 1) (50 ° 53'0.7 " N, 14 ° 23'21.6 " V). The altitude ranges

from 120 m above sea level (Labe near Hřensko) to 619 m above sea level (Růžovský vrch). The average rainfall here is 600 to 800 mm per year, and the average temperature is between 7 and 8 ° C. There are mostly acid soils formed on sandstones with the predominant soil type cambium. Forest vegetation stages are in this area: oak-beech 32,7%, fir-beech 60,3%, spruce-beech 7,0%. The park is 79.23 km<sup>2</sup> and it is a partially uncultivated area.

Remnants of the original forests have been preserved in the form of so-called relict pines and in deep ravines where the original form of spruce can still be found. In some places, remnants of deciduous forests have also survived, including beech forests, warm-loving oak forests and floodplain forests that are linked to watercourses.



**Fig. 1.** The study is in the context of Czech Republic, and examples of dead and alive forest stands

Bi-temporal data from the Bohemian Switzerland National Park were used in our research. The first laser data was from 2005, acquired by the Technical University of Dresden (TU Dresden) made company TopoSys Topographische Systemdaten GmbH, Biberach. The density of points during laser scanning was on average, 4 points/m<sup>2</sup>. The second laser data was from 2019, acquired by commercial company Primis. The density of points during laser scanning was, on average, 15 points/m<sup>2</sup>.





## 2.2 Processing of data

The laser data from 2005 was in binary data format 3d3 and 3d3i (format from TopoSys) and has a structure according to the type of scanner used. Therefore, for further processing, the data in these formats were converted to text format using TopoSys Converter V.2.2.0. Because it was a large amount of data, it was necessary to divide the territories into smaller parts and convert it gradually. With this software, the data were exported to a basic text file with records for each point in the form X, Y, Z, T (time), I (intensity, for the data of the last reflection) (Bruna et al., 2012). The disordered point cloud, which has about 12 billion points, must be filtered and classified.

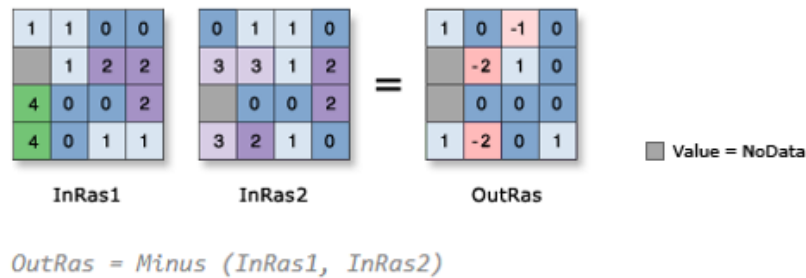
### 2.2.1 Point cloud filtering, classification rasterization and generating a DTM

Filter and classification were done in the software environment PDAL running on Anaconda. PDAL, used to classify ground, returns the Simple Morphological Filter (SMRF) technique, which is based on finding the minimum z-value in a chosen buffer and angle connection to the closest point. The algorithm discriminated the points into two groups, ground and non-ground. First, the outlier filter merely classifies outliers with a Classification value 7. These outliers are then ignored during SMRF processing with the ignore option. Finally, we added a range filter to extract only the ground returns (i.e., Classification value of 2) (PDAL, 2022a).

We used PDAL to generate a raster surface using a fully classified point cloud with PDAL's `writers.gdal`. PDAL capability to generate rasterized output is provided by the `writers.gdal` stage (PDAL, 2022b).

(PDAL, 2022b) PDAL was used to generate an elevation model surface using the output from the filtering. PDAL's `writers.gdal` operation, and GDAL to generate an elevation and hillshade surface from point cloud data (PDAL, 2022c).

The spatial analysis was done using ArcGIS Pro Esri ® (Fig. 2). The minus subtracts the value of the second input raster from the value of the first input raster on a cell-by-cell basis.



**Fig. 2.** Illustration of Minus function in software ArcGIS Pro Esri ® (Minus (Spatial Analyst, ArcGIS Pro 3.2))

For estimation of pure biomass expansion, we eliminated data where the increment was larger than 15 meters, which corresponds to the largest increments found in Czech growth and yield tables (Černý, M., Pařez, J., Malík, 1993). We also eliminated negative increment, which can be understood as either harvested area or influenced by some kind of disturbance causing decreased height (tree top break, snow damage, etc.).

#### ArcGIS Change Detection function.

The geoprocessing tools within the Change Detection toolset enable the execution of basic change detection analyses between raster datasets. Additionally, the Compute Change raster function can be employed for real-time change detection between two raster datasets.

For change detection across a time series of raster images, one can utilize either the Analyze Changes Using CCDC tool or the Analyze Changes Using LandTrend tool. Each tool can be linked with the Detect Change Using Change Analysis Raster tool to ascertain details about the timing and extent of changes for each pixel time series (Change Detection in ArcGIS Pro, ArcGIS Pro 3.2).

We used Zonal statistics as data source for numerical descriptions of changes in the two periods.

The following variables are obtained automatically as potential predictors:

MEAN—The average of all cells in the value raster that belong to the same zone as the output cell; MAXIMUM—The largest value of all cells in the value raster that belong to the same zone as the output cell, MEDIAN—The median value of all cells in the value raster that belong to the same zone as the output cell, MINIMUM—The smallest value of all cells in the value raster that

belong to the same zone as the output cell, PERCENTILE 90—The percentile of all cells in the value raster that belong to the same zone as the output, RANGE—The difference between the largest and smallest value of all cells in the value raster that belong to the same zone as the output cell, STANDARD DEVIATION—The standard deviation of all cells in the value raster that belong to the same zone as the output cell, SUM—The total value of all cells in the value raster that belong to the same zone as the output cell, VARIETY—The number of unique values for all cells in the value raster that belong to the same zone as the output cell (Zonal Statistics as Table (Spatial Analyst, ArcGIS Pro 3.2)).

### 2.2.2 Verification data

In the Czech Republic, to assess site quality, site index is used. Currently, the most used variable is stand height, based on the mean or dominant height of the stand. Site index can be absolute or relative. Relative site index expresses the relative quality of the site, while absolute site index directly indicates the values of the mean heights of stands, usually at 100 years.

### 2.2.3 Statistical modelling and machine learning based model creation.

The statistical analysis was done using software R version 4.2.3 (R Core Team, 2023). Firstly, increments were modeled over the age and mean height, respectively. The nonlinear package (nls2) was used to fit the incremental form of the Chapman-Richards function (equation 1) (Richards, 1959).

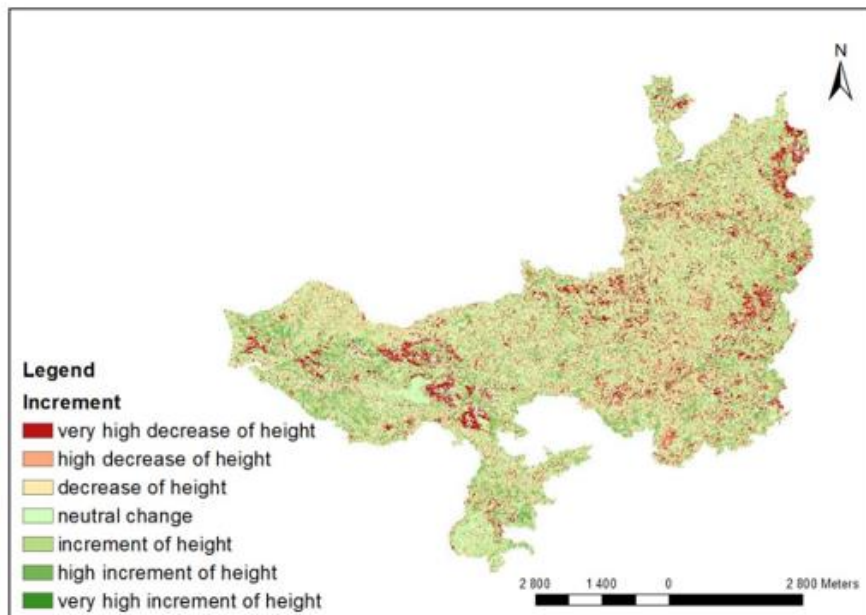
$$y = a(1 - e^{-bt})^c \quad [1]$$

The function is one of the potential candidates for such work, and future work may include more detailed analysis and deployment of other functions available (Kuželka & Marušák, 2015). For linear model creation, we used forward stepwise regression, with starting variables all available from remotely sensed data: first set from 2005 and second from the difference between 2005 and 2019. (the variables are standard zonal statistics variables from ArcGIS Zonal toolbox). The machine learning approach for model creation was done by deploying the RandomForest package v 4.7-1.1. The model's accuracy was estimated by confusion matrix and by the accuracy provided from the model. For both cases (absolute and relative site index), the values were

transformed into factors and modelled as discrete classes.

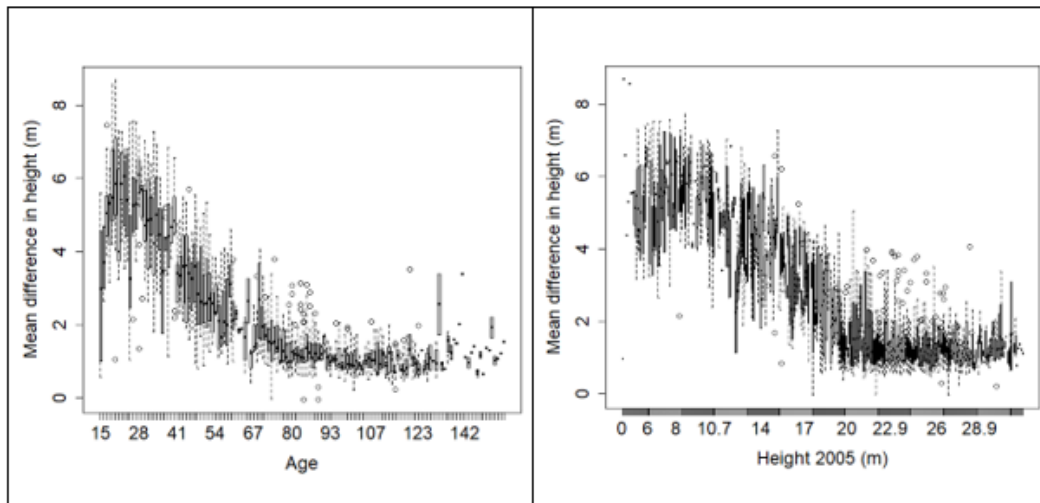
### 3. Results

The distribution of all changes between 2005 and 2019 is shown on the map (Fig. 3). The larger red areas represent clearcuts resulting from the preliminary removal of bark beetle-attacked areas, an approach which was later abandoned in favor of natural evolution.



**Fig. 3.** The distribution of height changes between years 2005 and 2019.

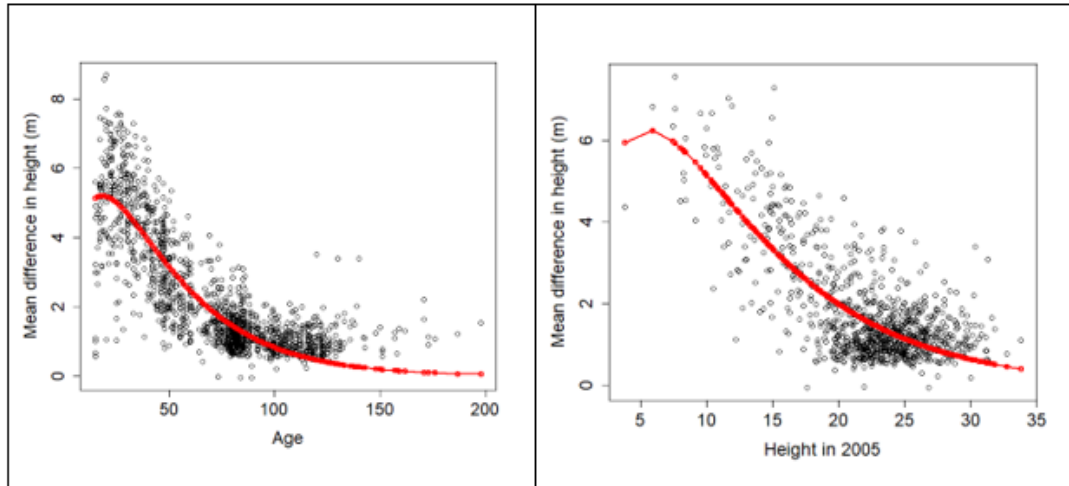
The Chapman-Richards growth model was used in its incremental (first derivative) form to fit the increment data. The data based on age are displayed in Fig. 4 left and based on mean height in Fig. 4 right.



**Fig.4.** The Chapman-Richards growth model input data. The left part shows the data based on age, and the right part shows the data based on mean height.

It is possible to observe that the overall known and expected dynamics of the increments follow the typical nonlinear shape, with lower starting values, immediately followed by the high values (young age), and then continuously decreasing to low values where it usually stabilizes. Such behavior is expected in all the growth curves as it describes the typical biological evolution of the organism, and most of the growth curves can easily be fitted over such data.

Growth model parameters for age:					Growth model parameters for height:				
	Estimate	Std.error	t-val	Pr (>  t )		Estimate	Std.error	t-val	Pr (>  t )
a	3.23e+02	378e+01	23.468	<2e-16	a	1.03e+02	4.6e+00	22.174	<2e-16
b	2.69e-02	1.3e-03	20.241	<2e-16	b	1.192e-01	4.7e-03	24.923	<2e-16
c	1.57e+00	1.6e-01	9.798	<2e-16	c	1.916e+00	2.0e-01	9.437	<2e-16
AIC = 2248.75					AIC = 2302.181				




**Fig. 5.** Comparing increments over age and heights in 2005. The left chart shows increments from 2005 related to age status in 2017, and the right chart shows increments from 2005 related to height in 2005.

There are significant similarities when comparing increments over age and over height in 2005. The left chart shows increments from 2005 related to age status in 2019, and the right chart shows increments from 2005 related to the height in 2005. Such growth models could be utilized for rough estimates of future height increments, for example, mentioned by (Woo et al., 2020). As the authors also mentioned in their study, it is also good to incorporate negative or zero height increment observation into the model so that the resulting models better represent the total population of tree measurements.

The resulting coefficients of the function fit are shown in Figure 5, upper row left and right, for age and mean height, respectively.

The creation of height increment models is an interesting and important challenge. Especially local models for smaller areas might be of interest for estimating site index and determining better and worse growth sites compared to the local average. On the other hand, given the existence of a global state site index system, the possibility of this growth curve might not be sufficient for the estimation and assessment of the nationwide site index scale. On the other hand, the state site index is available in the ground truth data from Forest Management Plan, as mentioned in the Methods section. Therefore, the classical statistical approach using linear regression can be evaluated for the assessment of the site index.





**Fig. 6.** The approximate normal distribution of the absolute site index values.

Distribution of values of absolute site index values. Fig. 6 shows the approximate normal distribution of the values, and it is also expected that the phenomena itself has a normal distribution in general. Despite this, the machine learning approach was also tested in model 2 for the absolute site index.

Model1 – Regression model only using lidar for absolute site index estimation

This model was created for absolute site index estimation using a linear model approach. The resulting variables (those which are most significant to describe the fit are shown in Table 1). The most important predictors are median, mean, and 90th percentile differences.

**Table 1.** The significant resulting variables of the model for absolute site index estimation without age. Multiple R-squared: 0.2825, Adjusted R-squared: 0.2771, p-value: < 2.2e-16

	Estimate	Std.error	t – val	Pr (>  t )	significance
(Intercept)	2.20E+01	7.66E-01	28.678	0	***
diff_MEDIAN	4.79E+00	6.36E-01	7.535	1.17E-13	***
r2005_PCT90	-2.08E-02	7.29E-02	-0.285	0.77576	
diff_MEAN	-5.28E+00	9.38E-01	-5.631	2.38E-08	***
diff_PCT90	1.13E+00	2.30E-01	4.922	1.02E-06	***

r2005_SUM	-4.42E-06	1.64E-06	-2.697	0.00713	**
r2005_MAX	1.03E-01	3.35E-02	3.086	0.00209	**
r2005_MEDIAN	1.51E-01	5.72E-02	2.647	0.00826	**

The coefficient of determination of this model ( $R^2$ ) is equal to 0.277, which signals a significant correlation, though not very strong. On the other hand, the fact that there is a trend between variables found as significant predictors and predicted site index means that better and worse sites might be differentiated by the lidar only.

#### Modella – Regression model using lidar and age for absolute site index estimation

In this model the AGE variable obtained from Forest Management Plan was included among predictors.

**Table 2.** The significant resulting variables of the model for absolute site index estimation with age. Multiple R-squared: 0.4439, Adjusted R-squared: 0.4384, p-value: < 2.2e-16

	Estimate	Std.error	t – val	Pr (>  t )	significance
AGE	-6.71E-02	4.11E-03	-16.335	2.00E-16	***
r2005_PCT90	-4.40E-02	7.36E-02	-0.598	0.550229	
diff_MEDIAN	2.73E+00	5.87E-01	4.655	3.71E-06	***
r2005_MEDIAN	3.19E-01	5.92E-02	5.382	9.36E-08	***
r2005_STD	2.65E-01	7.54E-02	3.515	0.000461	***
r2005_MAX	1.18E-01	2.96E-02	3.972	7.67E-05	***
r2005_SUM	-4.92E-06	1.45E-06	-3.395	0.000715	***
diff_MEAN	-2.64E+00	8.50E-01	-3.1	0.001993	**

The selected variable is again the median from the difference raster, but now the initial median and other starting predictors. The age was included by stepwise regression, and its inclusion increased the coefficient of determination to 0.438, which is approximately 0.16 more. It is a significant improvement, and as mentioned before, the age of a stand or tree is not directly detectable from remotely sensed data, but in long term monitoring, it is possible to detect by the detection of clearcut or individual tree breakdown.

Model2 - Model using machine learning for absolute site index without age

For comparison of model quality with relative site index, which does not have a normal distribution and is also not possible to be modeled by linear regression approach, we also constructed a predictive model for absolute site index using machine learning, more precisely random forest method.

**Table 3.** The most important variables of the random forest model for absolute site index estimation without age. Overall Statistics: Accuracy: 0.3474, 95% CI: (0.2799, 0.4197)

diff_MEDIAN	100.0
r2005_MIN	87.8
diff_PCT90	72.5
diff_MEAN	71.6
r2005_SUM	67.0
diff_STD	63.8
diff_SUM	59.3
r2005_STD	56.9
r2005_MEDIAN	54.9
r2005_MAX	52.5
diff_MIN	50.1
r2005_PCT90	35.7
r2005_MEAN	34.1
r2005_RANGE	34.0
diff_RANGE	4.0
diff_MAX	0.0

The accuracy of the model is 0.3474. From the variable importance table, it is possible to observe that again, as in the linear model, the median of differences is selected as the most important variable, and approximately ten other variables alternatively from the starting year, and the difference contributes more than 50 percent to the final model.

Model2a- Model using machine learning for absolute site index with age

The model includes age in the predictors in this scenario, and similarly, as in the linear regression model, age is the most important predictor.

**Table 4.** The most important variables of random forest model for absolute site index estimation with age. Overall Statistics: Accuracy: 0.4105, 95% CI: (0.3398, 0.484)

Age	100
r2005_MIN	41.9061
r2005_MAX	33.8553
r2005_STD	31.8844
r2005_PCT90	30.9755
r2005_MEDIAN	30.671
r2005_SUM	30.2382
r2005_MEAN	25.3025
diff_MIN	25.2751
diff_STD	22.8977
diff_SUM	18.6345
r2005_RANGE	17.7695
diff_MEDIAN	14.9402
diff_PCT90	13.2787
diff_MEAN	4.9568
diff_RANGE	0.3649

#### Model3 - Model using machine learning for relative site index without age

In this model, we estimated the relative site index (bonita) with fewer levels than the absolute site index; the relative one has only nine classes, which are not linearly connected as the absolute site index. Though it is possible to say that 1<sup>st</sup> class is better than 2<sup>nd</sup> class, it is not possible to claim that 1<sup>st</sup> class is twice as better as 2<sup>nd</sup> class. Therefore, the problem cannot be easily solved by linear modeling, and machine learning offers a much better approach.

**Table 5.** The most important variables of the random forest model for relative site index

estimation without age. Overall Statistics: Accuracy: 0.5105, 95% CI: (0.4371, 0.5836)

diff_MEDIAN	100
diff_MEAN	93.046
diff_PCT90	69.911
diff_STD	43.772
r2005_SUM	42.786
r2005_PCT90	28.869
r2005_MEDIAN	28.711
r2005_MEAN	28.552
r2005_MAX	27.237
r2005_RANGE	25.614
diff_SUM	24.352
r2005_STD	21.983
r2005_MIN	15.022
diff_MAX	5.627
diff_RANGE	2.337
diff_MIN	0

This model has the highest accuracy of all models so far; again, among the most important variables is the median difference between the two scans.

Model3a - Model using machine learning for relative site index with age

In this model, similarly to previous models, age was incorporated into predictor variables. Also, it was selected as the most important predictor variable.

**Table 6.** The most important variables of the random forest model for relative site index estimation with age. Overall Statistics: Accuracy: 0.5368, 95% CI: (0.4632, 0.6093)

Age	100
diff_MEDIAN	43.81
r2005_MEDIAN	32.9
r2005_MAX	27.37

r2005_MEAN	26.17
r2005_STD	23.99
diff_MEAN	22.46
r2005_SUM	22.25
r2005_MIN	22.21
r2005_PCT90	21.09
diff_PCT90	15.91
r2005_RANGE	15.17
diff_SUM	13.82
diff_STD	11.65
diff_MIN	11.39
diff_RANGE	0.64

Despite using age as a predictor with the highest importance, this model did not improve as much as the previous one. The resulting accuracy is the highest among all possible models, age is the most important predictor, and the median of differences is among the most influential variables. On the other hand, the difference to the model without age is, in this case, rather small.

#### 4. Discussion

Estimating site index quality using empirical growth models is of essential use for practical forestry. Previous studies show the potential of ALS data for modeling and observation of forest characteristics, especially site index (Guerra-Hernández et al., 2021). (Tompalski, Coops, White, Wulder, et al., 2015) estimated height from remote sensing to developed site productivity estimates. For the estimation of the dominant height of the stand, they used ALS. Landsat time series was used to identify disturbances areas for stand age estimation. For fit, a site productivity guide curve was used for nonlinear regression for stands aged 7 to 32. Site productivity models were validated by Remote sensing, inventory data, and existing and developed models. This method of data estimation is more suitable for young stands in areas lacking wall-to-wall forest inventory data.

After deriving the Site Index, we can predict the height of the stand at a given age. The authors (Tompalski, Coops, White, & Wulder, 2015a) investigated the accuracy of height derivation from traditional site index (SI) curves and those measured using Airborne Laser Scanning (ALS)

data. Their investigations showed a significant difference between the compared stand heights, influenced by factors such as stand complexity and canopy cover. On the other hand, the characteristics of elevation, slope, and aspect had less of an impact on site index estimation. Parametric and non-parametric models can be used to model site index. According to a study (Watt et al., 2015) parametric models have higher accuracy. It may also be the case that age information is not always available, although this value improves the accuracy of the model. In our study, we added age, and the results show that adding age increases the accuracy of the model.

For mapping and predicting, the site index is also used with repeated laser scanning (Noordermeer et al., 2020)(Socha et al., 2020). (Socha et al., 2017), in their study, using airborne laser scanning data, they derived a site index for site-specific growth trajectories. Already, a five-year interval between data collection has proven to be sufficient.

It has been several years since the use of ALS technology in forest inventories, and we can now use repeated scans with a time interval of up to 15 years (Noordermeer et al., 2019). Besides that, laser scanning can accurately detect the vertical distribution of forest vegetation components. Detecting understory vegetation is possible with direct return and full-waveform recording methods but significantly more accurately with full-waveform (Crespo-Peremarch et al., 2020). In our work, 14 years interval showed successful estimates of site index for fine-scale (in case of absolute site index) to coarser scale in case of relative site index.

Repeated laser scanning (fifteen years) can also be used in site index estimation using direct and indirect methods. In the direct method, field observations can be a regress of age-height site index against canopy height metrics derived from ALS data from the first point in time and changes in ALS metrics reflecting canopy height growth during the observation period. The two points in time were firstly modeled Hdom using the respective ALS metrics as predictors SI, derived from the initial Hdom, the estimated Hdom increment, and the length of the observation period using empirical SI curves. Both approaches yield a satisfactory site index estimation (Noordermeer et al., 2018). In our study, instead, we used the mean height of the stand, and we proved that in all cases, the median height of lidar measurements was always among the most important predictors. On the other hand, in all modalities (regression, machine learning), the age proved to be improved by including variable age. At first glance, the age does not appear directly accessible by remote sensing materials. However, consistent long-term



monitoring can delineate clear-cuts or disturbances and define the starting period for a new generation of tree cover. Such mapping can nowadays also easily be done (Melichová et al., 2023), and clearcut areas with very high-resolution mapping can be analyzed for prediction of vegetation survival (Hüttnerová et al., 2024).

(Bollandsås et al., 2019), they have compared the accuracy of site index modeling based on single-time hyperspectral data with different types of processing, bitemporal laser scans, and their combination. The aerial laser scan (ALS) data used in this study were obtained at two-time intervals with a twelve-year difference. Hyperspectral data were obtained by the same flight as ALS data in 2011. Using a combination of ALS data and hyperspectral images, the results showed that the contribution of hyperspectral data was negligible compared to using only bitemporal ALS data. In the cases where only spectral data are available, it is still possible to construct predictive models of the H40 site index (which is used in Norway to represent forest productivity). They also found that models constructed with normalized hyperspectral data showed lower RMSE values than models constructed with atmospheric correction and that pixel selection based on NDVI did not improve results compared to using all pixels.

Even today, the financial aspect is important when deciding what data will be used. Direct methods, using bi-temporal ALS and DAP data, demonstrated testing the highest accuracy and the lowest total cost (Noordermeer et al., 2021).

## 5. Conclusions

This study used distant bitemporal datasets from aerial laser scanning to estimate growth and site index quality. Initial and differential rasters were used as input data for models, and ground truth from Forest management plans was used to evaluate the accuracy of the outputs. We demonstrated that machine learning (random forest method) could estimate both absolute and relative site indices and that linear regression can also be used to model absolute site index successfully. In all three modalities of models, including age as a predictive variable, accuracy improved significantly by 3 to 15 percent. Age is a logical predictor for site index estimation because it relates to growth trajectory. In the future, age can be easily estimated from remotely sensed material as a moment when canopy height is reduced to zero, either by harvest or natural disturbance. Continuous remote sensing monitoring may contribute to a better understanding of

forest growth status and conditions.

### Acknowledgements

This research was funded by the Ministry of Agriculture of the Czech Republic, grant number QK21010198 and by EVA4.0 “Advanced Research Supporting the Forestry and Wood-processing Sector’s Adaptation to Global Change and the 4th Industrial Evolution” (No. CZ.02.1.01/0.0/0.0/16\_019/0000803).

### References

- Ali-Sisto, D., Packalen, P., 2017: Forest Change Detection by Using Point Clouds from Dense Image Matching Together with a LiDAR-Derived Terrain Model. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10:1197–1206.
- Antonelli, P. L., 1992: The Algorithmic Beauty of Plants (Przemyslaw Prusinkiewicz and Aristid Lindenmayer). *SIAM Review*, 34:142–143.
- Bollandsås, O. M., Gregoire, T. G., Næsset, E., Øyen, B. H., 2013: Detection of biomass change in a Norwegian mountain forest area using small footprint airborne laser scanner data. *Statistical Methods and Applications*, 22:113–129.
- Bollandsås, O. M., Ørka, H. O., Dalponte, M., Gobakken, T., Næsset, E., 2019: Modelling site index in forest stands using airborne hyperspectral imagery and Bi-temporal laser scanner data. *Remote Sensing*, 11:1020.
- Bruna, V., Elznicova, J., Pacina, J., 2012: Využití geoinformačních technologií pro hodnocení krajiny přeshraniční oblasti Česko-Saské Švýcarsko. Ústí and Labem, Univerzita J. E. Purkyně v Ústí nad Labem, Fakulta životního prostředí, 104 p.
- Černý, M., Pařez, J., Malík, Z., 1993: Růstové modely hlavních dřevin České republiky (smrk, borovice, buk, dub) –2. etapa. Zpráva o výsledcích řešení za rok 1993. Skupina ekologického monitoring, PYRUS, 66 p.
- Cieszewski, C. J., 2001: Three methods of deriving advanced dynamic site equations demonstrated on inland Douglas-fir site curves. *Canadian Journal of Forest Research*, 31:165–173.
- Cieszewski, C. J., Harrison, M., Martin, S. W., 2000: Practical methods for estimating non-biased parameters in self-referencing growth and yield models. University of Georgia. PMRC-TR, 2000-7:1–11.

- Cieszewski, C. J., Strub, M., 2018: Comparing properties of self-referencing models based on nonlinear-fixed-effects versus nonlinear-mixed-effects modeling approaches. *Mathematical and Computational Forestry and Natural-Resource Sciences*, 10:46–57.
- Crespo-Peremarch, P., Fournier, R. A., Nguyen, V. T., van Lier, O. R., Ruiz, L. Á., 2020: A comparative assessment of the vertical distribution of forest components using full-waveform airborne, discrete airborne and discrete terrestrial laser scanning data. *Forest Ecology and Management*, 473:118268.
- Fassnacht, F. E., White, J. C., Wulder, M. A., Næsset, E., 2023: Remote sensing in forestry: current challenges, considerations and directions. *Forestry: An International Journal of Forest Research*, 97:11–37.
- Goodbody, T. R. H., Coops, N. C., Luther, J. E., Tompalski, P., Mulverhill, C., Frizzle, C., Fournier, R., Furze, S., Herniman, S., 2021: Airborne laser scanning for quantifying criteria and indicators of sustainable forest management in Canada. *Canadian Journal of Forest Research*, 51:972–985.
- Guerra-Hernández, J., Arellano-Pérez, S., González-Ferreiro, E., Pascual, A., Sandoval Altelarra, V., Ruiz-González, A. D., Álvarez-González, J. G., 2021: Developing a site index model for *P. Pinaster* stands in NW Spain by combining bi-temporal ALS data and environmental data. *Forest Ecology and Management*, 481:118690.
- Hüttnerová, T., Muscarella, R., Surový, P., 2024: Drone microrelief analysis to predict the presence of naturally regenerated seedlings. *Frontiers in Forests and Global Change*, 6-2023.
- Kurth, W., Anzola Jürgenson, G., 1997: Triebwachstum und Verzweigung junger Fichten in Abhängigkeit von den beiden Einflussgrößen "Beschattung" und "Wuchsdichte": Datenaufbereitung undanalyse mit GROGRA. *Dtsch. Verb. Forstl. Forschungsanstalten* Sekt. Forstl. Bio. Und Inform., 10:89–108.
- Kuželka, K., Marušák, R., 2015: KORFit: An efficient growth function fitting tool. *Computers and Electronics in Agriculture*, 116:187–190.
- Ma, Q., Su, Y., Tao, S., Guo, Q., 2018: Quantifying individual tree growth and tree competition using bi-temporal airborne laser scanning data: a case study in the Sierra Nevada Mountains, California. *International Journal of Digital Earth*, 11:485–503.
- Mauya, E. W., Hansen, E. H., Gobakken, T., Bollandsås, O. M., Malimbwi, R. E., Næsset, E., 2015: Effects of field plot size on prediction accuracy of aboveground biomass in airborne laser scanning-assisted inventories in tropical rain forests of Tanzania. *Carbon Balance and Management*, 10:10.

- Melichová, Z., Pekár, S., Surový, P., 2023: Benchmark for Automatic Clear-Cut Morphology Detection Methods Derived from Airborne Lidar Data. *Forests*, 14:2408.
- Moan, M. Å., Noordermeer, L., White, J. C., Coops, N. C., Bollandsås, O. M., 2023: Detecting and excluding disturbed forest areas improves site index determination using bitemporal airborne laser scanner data. *Forestry: An International Journal of Forest Research*, May 2023, 97:48–58.
- Muhamad-Afizzul, M., Siti-Yasmin, Y., Hamdan, O., Tan, S. A., 2019: Estimating stand-level structural and biophysical variables of lowland dipterocarp forest using airborne LiDAR data. *Journal of Tropical Forest Science*, 31:312–323.
- Næsset, E., Gobakken, T., 2005: Estimating Forest growth using canopy metrics derived from airborne laser scanner data. *Remote Sensing of Environment*, 96:453–465.
- Næsset, E., Gobakken, T., Solberg, S., Gregoire, T. G., Nelson, R., Ståhl, G., Weydahl, D., 2011: Model-assisted regional forest biomass estimation using LiDAR and InSAR as auxiliary data: A case study from a boreal forest area. *Remote Sensing of Environment*, 115:3599–3614.
- Nigul, K., Padari, A., Kiviste, A., Noe, S. M., Korjus, H., Laarmann, D., Frelich, L. E., Jõgiste, K., Stanturf, J. A., Paluots, T., Pöldveer, E., Kängsepp, V., Jürgenson, H., Metslaid, M., Kangur, A., 2021: The possibility of using the chapman-richards and näslund functions to model height-diameter relationships in hemiboreal old-growth forest in Estonia. *Forests*, 12:1–15.
- Noordermeer, L., Bollandsås, O. M., Gobakken, T., Næsset, E., 2018: Direct and indirect site index determination for Norway spruce and Scots pine using bitemporal airborne laser scanner data. *Forest Ecology and Management*, 428:104–114.
- Noordermeer, L., Gobakken, T., Næsset, E., Bollandsås, O. M., 2020: Predicting and mapping site index in operational forest inventories using bitemporal airborne laser scanner data. *Forest Ecology and Management*, 457:117768.
- Noordermeer, L., Gobakken, T., Næsset, E., Bollandsås, O. M., 2021: Economic utility of 3D remote sensing data for estimation of site index in Nordic commercial forest inventories: a comparison of airborne laser scanning, digital aerial photogrammetry and conventional practices. *Scandinavian Journal of Forest Research*, 36:55–67.
- Noordermeer, L., Økseter, R., Ørka, H. O., Gobakken, T., Næsset, E., Bollandsås, O. M., 2019: Classifications of Forest Change by Using Bitemporal Airborne Laser Scanner Data. *Remote Sensing*, 11:2145.
- Patočka, Z., Mikita, T., 2016: Využití Plošného Přístupu Ke Zpracování Dat Leteckého Laserového Skenování V Inventarizaci Lesa Use of Area-Based Approach To Process the

- Airborne Laser Scanning Data in Forest Inventory. 61:115–124.
- Richards, F. J., 1959: A flexible growth function for empirical use. *Journal of Experimental Botany*, 10:290–301.
- Silva, C. A., Klauberg, C., De Pádua Chaves Carvalho, S., Rodriguez, L. C. E., 2013: Estimation of aboveground carbon stocks in Eucalyptus plantations using LIDAR. *International Geoscience and Remote Sensing Symposium (IGARSS)*, January 2015, 972–974.
- Socha, J., Hawryło, P., Stereńczak, K., Miścicki, S., Tymińska-Czabańska, L., Młócek, W., Gruba, P., 2020: Assessing the sensitivity of site index models developed using bi-temporal airborne laser scanning data to different top height estimates and grid cell sizes. *International Journal of Applied Earth Observation and Geoinformation*, 91:102129.
- Socha, J., Pierzchalski, M., Bałazy, R., Ciesielski, M., 2017: Modelling top height growth and site index using repeated laser scanning data. *Forest Ecology and Management*, 406:307–317.
- Tompalski, P., Coops, N. C., Marshall, P. L., White, J. C., Wulder, M. A., Bailey, T., 2018: Combining multi-date airborne laser scanning and digital aerial photogrammetric data for forest growth and yield modelling. *Remote Sensing*, 10:1–21.
- Tompalski, P., Coops, N. C., White, J. C., Wulder, M. A., 2015a: Augmenting site index estimation with airborne laser scanning data. *Forest Science*, 61:861–873.
- Tompalski, P., Coops, N. C., White, J. C., Wulder, M. A., 2015b: Enriching ALS-derived area-based estimates of volume through tree-level downscaling. *Forests*, 6:2608–2630.
- Tompalski, P., Coops, N. C., White, J. C., Wulder, M. A., 2016: Enhancing forest growth and yield predictions with airborne laser scanning data: Increasing spatial detail and optimizing yield curve selection through template matching. *Forests*, 7:1–20.
- Tompalski, P., Coops, N. C., White, J. C., Wulder, M. A., Pickell, P. D., 2015: Estimating Forest Site Productivity Using Airborne Laser Scanning Data and Landsat Time Series. *Canadian Journal of Remote Sensing*, 41:232–245.
- Vauhkonen, J., Ørka, H. O., Holmgren, J., Dalponte, M., Heinzl, J., Koch, B., 2014: Tree species recognition based on airborne laser scanning and complementary data source. In *Forestry applications of airborne laserscanning*. Springer, Dordrecht, 135–156 p.
- Watt, M. S., Dash, J. P., Bhandari, S., Watt, P., 2015: Comparing parametric and non-parametric methods of predicting Site Index for radiata pine using combinations of data derived from environmental surfaces, satellite imagery and airborne laser scanning. *Forest Ecology and Management*, 357:1–9.
- White, J. C., Stepper, C., Tompalski, P., Coops, N. C., Wulder, M. A., 2015: Comparing ALS

and image-based point cloud metrics and modelled forest inventory attributes in a complex coastal forest environment. *Forests*, 6:3704–3732.

Woo, H., Eskelson, B. N. I., Monleon, V. J., 2020: Tree height increment models for national forest inventory data in the Pacific Northwest, USA. *Forests*, 11:2.

Yu, X., Hyyppä, J., Holopainen, M., Vastaranta, M., 2010: Comparison of area-based and individual tree-based methods for predicting plot-level forest attributes. *Remote Sensing*, 2:1481–1495.

Yu, X., Hyyppä, J., Kaartinen, H., Hyyppä, H., Maltamo, M., Rönnholm, P., 2005: Measuring the growth of individual trees using multi-temporal airborne laser scanning point clouds. *ISPRS Workshop Laser Scanning*, May 2014, 204–208.

Zhao-gang, L., Feng-ri, L., 2003: The generalized Chapman-Richards function and applications to tree and stand growth. *Journal of Forestry Research*, 14:19–26.

#### *Other sources*

Change detection in ArcGIS Pro. <https://pro.arcgis.com/en/pro-app/latest/help/analysis/image-analyst/change-detection-in-arcgis-pro.htm>

Minus (Spatial Analyst). <https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-analyst/minus.htm>

PDAL. (2022a). <https://pdal.io/en/2.4.3/workshop/exercises/analysis/ground/ground.html>

PDAL. (2022b). <https://pdal.io/en/2.4.3/workshop/exercises/analysis/rasterize/rasterize.html>

PDAL. (2022c). <https://pdal.io/en/2.4.3/workshop/exercises/analysis/dtm/dtm.html>

R Core Team, 2023. *R Core Team. R: A Language and Environment for Statistical Computing; R Foundation for Statistical Computing: Vienna, Austria, 2023; Available online: https://www.R-project.org/ (accessed on 7 December 2023).*

Zonal Statistics as Table (Spatial Analyst). <https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-analyst/zonal-statistics-as-table.htm>

## 7.4 Odhad hrúbky stromu za pomoci terestriálneho pozemného a mobilného laserového skeneru

### **Tree Diameter Estimation Using a Low-Cost Mobile Laser Scanner: A Comparative Analysis.**

Tento článok sa zameriava na hodnotenie vhodnosti nových nízkonákladových systémov LiDAR pre odhad priemeru kmeňa stromu. Jeho previazanie na tému PhD je dané hlavne využitím LiDARovej technológie a možnosťou opakovaného skenovania s touto presnosťou získať do budúcnosti dáta pozemných prírastkov pre koreláciu s leteckým lidarom.

Porovnáva sa poloautomatická detekcia pomocou algoritmu RANSAC a ručná detekcia stromov s plne automatickou extrakciou pomocí voľne dostupného balíčku FORTLS v softvare R.

Jediný sken ukázal najnižší počet zistených stromov pre obe metódy spracovania. V prípade zariadenia Mapry však jedno skenovanie ukázalo vyššiu presnosť (v MAE aj RMSE) ako viacpriechodový prístup. Podľa referenčných zariadení (TLS a ZEB) vykazovali podobné výsledky vo všetkých štatistikách. FORTLS zistil menej stromov ako manuálna extrakcia sekcií stromu a presnosť v odhadoch DBH bola vo všetkých prípadoch o niečo nižšia s výnimkou ZEB, ktorá sa ukázala byť o niečo vyššia.

Z výsledkov štúdie vyplýva, že nový nízkonákladový mobilný skener má potenciál poskytnúť presný odhad priemeru kmeňa stromu. Je však dôležité zobrať do úvahy, že presnosť môže byť ovplyvnená spôsobom skenovania a spracovania dát.

*Submitnuté ako:*

Surový, P., Mokroš, M., Tatsumi, S., Yamaguchi, K., Valero, M. A. J., & Melichová, Z. (2023). Tree Diameter Estimation Using a Low-Cost Mobile Laser Scanner: A Comparative Analysis. Remote Sensing.

*Prínosy autorov*

Konceptualizácia, P.S., S.T. a M.M.; metodika, P.S. K.Y.; softvér, K.Y., P.S. a J.M.; validácia, M.M., Z.M. a J.M.; písanie - príprava pôvodného návrhu, P.S., J.M.; písanie-revizia a úprava, M.M., K.Y., Z.M; administrácia projektu, P.S.; získavanie finančných prostriedkov, P.S. Všetci autori si prečítali a súhlasia s publikovanou verzou rukopisu.



## **Rozšírené zhrnutie**

Type of the Paper (Communication)

# Tree Diameter Estimation Using a novel Low-Cost Mobile Laser Scanner: A Comparative Analysis.

Peter Surový <sup>1\*</sup>, Shinichi Tatsumi <sup>2</sup>, Keiji Yamaguchi <sup>3</sup>, Juan Alberto Molina-Valero <sup>1</sup> and Zlatica Melichová <sup>1</sup>, Martin Mokroš <sup>1</sup>

1  
2  
3  
4  
5

**Citation:** To be added by editorial staff during production.

Academic Editor: Firstname Last-name

Received: date

Revised: date

Accepted: date

Published: date



**Copyright:** © 2023 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/>).

<sup>1</sup> Faculty of Forestry and Wood Sciences, Czech University of Life Sciences Prague, Kamýcká 129, 16500 Prague, Czech Republic

<sup>2</sup> Hokkaido Research Center, FFPRI, [community.ecologist@gmail.com](mailto:community.ecologist@gmail.com)

<sup>3</sup> Mapry, [keiji\\_yamaguchi@pkp.co.jp](mailto:keiji_yamaguchi@pkp.co.jp)

\* Correspondence: [surovy@fd.czu.cz](mailto:surovy@fd.czu.cz);

**Abstract:** In this research, we evaluated the Livox Avia, a novel low-cost laser scanning device integrated into a laser scanner prototype for tree diameter measurement. Accurate tree diameter information is crucial for applications such as forest structure inventory, urban tree assessment, and information collection for road and railway environments, and it is extremely important in assessing the tree growth dynamics. The conventional scanning approach, involving the creation of a LiDAR point cloud through multiple scans of the target area, resulted in lower measurement quality, averaging 4.37 cm in accuracy when compared to established commercial static and mobile LiDAR devices. Conversely, employing a simplified scan pattern, equivalent to onboard or time-based data processing, yielded highly precise diameter measurements with an accuracy of 1.42 cm. This level of accuracy is comparable to that achieved by static LiDAR systems. These findings suggest that future developments should consider onboard processing as a viable option to minimize errors introduced by creating a complete point cloud.

**Keywords:** low cost lidar; tree stem; urban trees, forest structure, diameter at breast height (DBH)

## 1. Introduction

Mapping and monitoring trees on a global scale have become increasingly important, particularly in the current context where the urgency of addressing climate is getting more attention, and new approaches, such as climate-smart forestry, are being developed [1]. The managed forests must increase their resilience towards climate change and be more structured and diverse, which will lead to challenging forest inventories. Consequently, the integration of cutting-edge technologies into these inventories is essentially not only due to their availability, but due to their capacity for efficient data collection, accuracy, and notably, the capability to cover larger areas.

Currently, National Forest Inventories (NFI) serve as the primary means for monitoring forests, typically employing statistical sampling methods [2]. NFIs yield a substantial volume of data, enabling the extraction of crucial information at national or even larger scales [3, 4]. However, it is noteworthy that the spatial coverage of these inventories is rather limited in comparison to the total expanse of forests. These inventories are structured on grids of 1x1 km or occasionally 2x2 km, with each grid cell encompassing an area ranging from 0.05 to 0.2 hectares. This effectively results in a coverage of less than one percent of the total forested area, and it might be significantly improved with remote sensing technology. For example, Čerňava et al. [5] demonstrated the possibility of deploying the mobile scanner on forest tractors, which can significantly enlarge the assessment of surrounding forest area around forest roads and skidding trails. Similarly, carrying a wearable scanner was shown as an important and practical way for larger area data acquisition [6, 7].

Apart from forests, another important area where trees are monitored is the urban environment [8, 9, 10]. Trees in the urban environment bring significant benefits to the microclimate including cooling, carbon sequestration and noise reduction [11, 12, 13].

Generally, the typical tree attributes of primary interest for measurement are height, diameter at breast height (DBH), crown extension, and volume. These fundamental parameters serve as the foundation for computing various other tree characteristics by utilizing allometric models. In traditional forestry practices, determining tree height can be

challenging, particularly within dense closed-canopy forest stands. Consequently, most established forest allometric models primarily revolve around tree diameter [14, 15].

The diameter at breast height (DBH) refers to the measurement of a tree's diameter taken at a height of 1.3 meters above the ground. This specific measurement height is chosen due to its practicality and accessibility, and it has been statistically validated to ensure that the presence of roots does not significantly impact the recorded stem size.

As previously discussed, various tree parameters are frequently associated with tree diameter through the utilization of allometric models. These models employ the DBH as a predictive variable for estimating other parameters like tree height, crown size, total biomass, etc. As a result, there is a substantial interest in methods for the rapid, accurate, and ideally cost-effective measurement of DBH. Over time, numerous techniques and tools have been developed for this purpose, with innovations spanning from the historical use of calipers to more modern approaches based on LiDAR devices. [2, 3] The utilization of remote sensing devices from a close distance, either from the ground or from low-flying unmanned aircraft, is termed close-range scanning.

### 1.1. Close-range laser scanning state-of-the-art

In the last two decades of research, many experiments have been focused on new ground-based remote sensing techniques. The main approaches are based on laser scanning (lidar) and photogrammetry. Especially the lidar devices have proven to be operationally viable for forest inventory purposes [16]. However, the appearance of close-range laser scanner devices led to a new approach to forestry measurements, enhancing forest inventories [18] and forest ecology research [19]. Nevertheless, the operational use of close-range laser scanner devices should be contemplated in further research [16]. In this sense, equipment affordability was recognized as one of the main challenges to overcome [20]. Hence, a new low-cost laser scanner could play an important role in future development.

Among all close-range laser scanner devices, terrestrial laser scanners (TLS) have been the first to be studied as forestry measurement instruments. Although they usually have the highest precision, they must be in static positions while scanning, which generates occlusions behind trees that hinder data processing and analysis. To overcome this problem, a multi-scan approach can be implemented, and by merging several scans, the occlusion problems can be partially overcome. However, data is becoming heavier, and data collection time is increasing. The alternative to TLS is mobile laser scanning (MLS). This approach to scanning the forest has been under research for many years. Based on the type of carrier, we know (MLS) placed on the vehicle, such as ATVs (All-Terrain Vehicle) or tractors. When the person is carrying the scanner, it can be a backpack or handheld laser scanning.

Despite the advantages of these technologies, most TLS and MLS devices have very high market prices for many potentially interested companies. That is why new low-cost MLS are of great interest. One of them is Smartphone mobile laser scanning, a low-cost mobile laser scanning using smart devices, especially iPhones or iPads [17]. The advantage is that the point cloud or model can be seen immediately in the field. The operator has the flexibility to immediately rescan the data in the event of incorrect data collection. Another advantage is in teaching, where students can scan and see the results in the field, which helps them understand the basics of lidar scanning. The current disadvantage is the short range (around 5 meters) and sparse point cloud. The main impact is on implementing the SLAM (Simultaneous Localization and Mapping) algorithm. In a forest setting, implementing Simultaneous Localization and Mapping (SLAM) with such a sparse point cloud is almost unfeasible. This means that the scanning with such a device must be carefully done and not rescan the same areas because it will delete the already scanned point cloud.

This work introduces a handheld low-cost MLS prototype with the potential for mass production and a price tag of around 2,000 euros. The results of this device are compared to those obtained by state-of-the-art TLS and handheld MLS, which are currently considered one of the leading devices on the market (Trimble and Geoslam Horizon). We compared them based on the performance for tree detection and diameter measurements. Additionally, the prototype is well-described and introduced.

## 2. Materials and Methods

### 2.1. Study Area

The study area is in a wooded area of the Czech University of Life Sciences Prague (CZU), where three different plots were established for measurement. The geographical coordinates of the centers of the plots are as follows: red plot 50.13106N, 14.37195E; yellow plot 50.13151N, 14.37285E and pink plot 50.13092N, 14.37274E (sites 1, 2, and 3 respectively). The positions of the trees on the plots are shown in Figure 1.

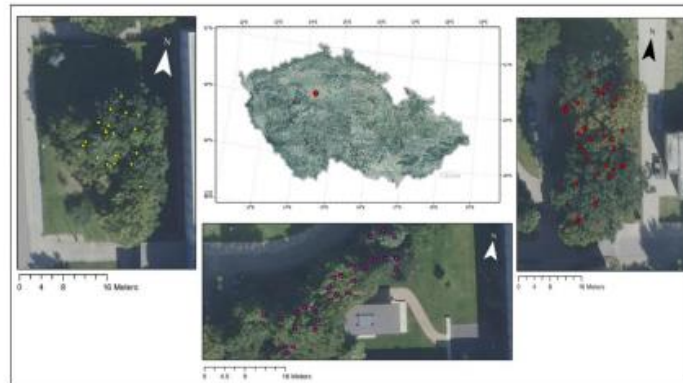


Figure 1. Testing area for all scanners.

### 2.2. The mobile scanner prototype

The device prototype is based on the Livox Avia LiDAR sensor (Livox Technology Company Limited, Shenzhen, Guangdong, China). The sensor itself weighs 498g, the maximum detection range is  $70.4^\circ \times 77.2^\circ$  with triple echo maximum number of returns, point rate  $\geq 240,000$  and range precision of 2 cm.

The Livox Avia LiDAR sensor is placed within the device developed by the authors (Keiji Yamaguchi, Mapry Inc.). The device holds the sensor, a power bank to power up the sensor, a USB key to store the data, a Bluetooth low energy (BLE) module for communicating with the smartphone application, an inertial measurement unit (IMU), and a camera.

The Mapry application was developed by one of the authors (Keiji Yamaguchi, Mapry Inc.), and it is currently available on Google Play. The main purpose of the application is to communicate with the sensor where the user can check whether all aspects of the scanner are working correctly. Then, it is possible to start the scanning and store it on the USB stick.





Table 1 The view of Mapry scanning device (left) and application interface (right, image from Google Playstore)

### 2.3. Data collection

Data collection was carried out with four different close-range remote approaches. The ground truth data were acquired following the common inventory-defined procedure measuring two perpendicular diameters for each tree at 1.3 meters above ground level (diameter at breast height – DBH). These approaches were multiscan static lidar as the oldest and most established technique considered for lidar scanning, and mobile multipass starting and ending in the same position with the MLS ZEB. We avoided single scan lidar due to occlusion in the dense forest which would not be representative.

The acquisition with the Mapry device was divided into two types. Classic mobile multipass, starting and ending in the same position as recommended for ZEB, and a single pass simulating passage by car or a single walk with hypotheses that this scan excludes the errors from rotations and might provide more accurate outputs as suggested by Čerňava et al., 2019 [5].

### 2.4. Data processing and evaluation

Firstly, point clouds were normalized for all devices and approaches, and a 4 cm thick slice at 1.3 m above ground level was obtained. From these slices, all sections belonging to trees were extracted using the CloudCompare software (<https://www.danielgm.net/cc/>), rejecting doubtful ones, which meant a total of 60 sections. Due to the computational limitations of our implementation of Random sample consensus (Ransac), the number of points in the sections was reduced to 600 points in case there were more of them in the section, using the CloudCompare random subsampling algorithm for that purpose.

### 2.5. Description of applied algorithms


164

Our objective is to analyze the data, positing that varying algorithms may yield divergent results. Therefore, we will examine two well-known algorithms to assess these differences. It's important to note that the anticipated variation doesn't necessarily reflect the quality of the algorithms, but rather, our goal is to explore the fullest potential of the data.

#### RANSAC

169

The Ransac works on voting for the most frequent radius found from a so-called random sample of points within a given dataset. The points can be selected randomly from a dataset or tested for each combination of points (so-called brute force approach). Our implementation depends on the last one, and therefore, it is only capable of working with datasets with less than 600 points, otherwise it would result in billions of iterations with the corresponding amount of data necessary to store and evaluate the results. For the majority of trees, 600 points is sufficient. The algorithm then stores the circle size and position for every triplet of points, and the most frequent one is then considered correct. Examples of outputs are shown in Figure 2, upper row:



179

**Figure 2.** Examples of application of the RANSAC algorithm in different situations. The upper row shows the application of RANSAC in incomplete stem scans; the bottom row shows the application of RANSAC in different scanning methods.

180

181

182

The algorithm works well for any dataset, and its results are the best for static lidar (TLS), mostly because the number of correct points on the surface is the highest. Figure 3 (bottom row) shows an example of the algorithm in practice. Left is a TLS scan analyzed with the RANSAC algorithm able to achieve the error of 2 centimeters compared to ground measurement; in the middle is multi-scan Livox, obviously resulting in a complex scan (though visually OK from outside), but rather complex for automatic analysis resulting in an error of 5 centimeters in diameter estimation. On the most right position is a single scan Livox pass with a diameter estimation error of 0.7 cm.

183

184

185

186

187

188

189

190

### 2.6. FORTLS description

191

All the aforementioned approaches were also analyzed with the R package FORTLS [21] to compare results with one of the reference tools for processing data belonging to


192

193

these technologies. The FORTLS package implements an automated approach in which, although some parameters can be defined before processing, outputs (DBHs in this case) will be obtained as a final dataset. Regarding DBH estimates, two approaches are considered: 1) one belonging to the RANSAC algorithm implemented in the function “circle-RANSAC” included in the R package TLS [22], and 2) another is based on regular square grids overlapped on the tree sections, where the centre of the tree section is considered to be the point in the grid where the variance of the distances between it and all points in the cluster is minimized. In this way, the average of the distances is the estimate of the radius (Figure 3 d, [21]). Finally, the best of the two approaches in terms of radius variance (and preference for RANSAC) is considered as DBH estimates.

### 3. Results

Percentage of detected trees for individual scanning types is shown in Figure 3:



**Figure 3.** Comparison of automatic tree detection capability using semi and fully automatic methods.

The single scan showed the lowest number of detected trees for both processing methods. However, in the case of the Mapry device, the single scan showed higher accuracy (in both MAE and RMSE) than the multipass approach. According to reference devices (TLS and ZEB), they showed similar results in all statistics. FORTLS detected fewer trees than the manual tree section extraction, and the accuracy in DBH estimates was slightly lower in all cases except for ZEB, which turned out to be slightly higher.

Accuracy of individual methods expressed by MAE, RMSE, and RMSE%, respectively:



**Table 1.** Comparison of errors for individual scanning methods and analysis methods

	TLS Trimble		MLS Zeb		MLS Mappy Full		MLS Mappy Single	
	Ransac	FORTLS	Ransac	FORTLS	Ransac	FORTLS	Ransac	FORTLS
MAE Site 1	1.65	1.88	1.81	1.84	2.51	2.84	1.62	2.19
MAE Site 2	1.42	1.19	1.42	1.37	1.71	3.05	1.54	2.43
MAE Site 3	1.43	2.75	2.59	1.46	2.59	2.93	2.26	2.28
<b>MAE avg</b>	<b>1.50</b>	<b>1.94</b>	<b>1.94</b>	<b>1.56</b>	<b>2.27</b>	<b>2.94</b>	<b>1.80</b>	<b>2.30</b>
RMSE Site 1	3.24	4.44	3.61	3.73	7.21	10.25	3.62	6.12
RMSE Site 2	3.23	2.44	2.44	2.09	4.12	12.66	2.81	8.17
RMSE Site 3	2.21	2.36	9.22	2.11	10.46	10.83	6.53	7.35
<b>RMSE avg</b>	<b>2.89</b>	<b>3.08</b>	<b>5.09</b>	<b>2.64</b>	<b>7.26</b>	<b>11.25</b>	<b>4.31</b>	<b>7.21</b>
RMSE% Site 1	5.79	7.47	7.10	6.74	13.62	16.43	5.82	9.57
RMSE% Site 2	6.07	3.66	4.02	3.43	7.10	22.08	5.10	15.28
RMSE% Site 3	4.54	5.65	27.78	4.18	12.69	21.26	12.80	13.06
<b>RMSE% avg</b>	<b>5.47</b>	<b>5.59</b>	<b>12.97</b>	<b>4.78</b>	<b>11.14</b>	<b>19.92</b>	<b>7.91</b>	<b>12.64</b>

### 3.1. Statistical analysis of the results

A one-way ANOVA model was used to evaluate whether scanning type has a significant effect on RMSE. The results revealed a nearly significant difference between at least two groups ( $F = 2.47$ ,  $p = 0.0629$ ). The Posthoc Tukey test was used for multiple comparisons, and it was found to be significantly different for groups TLS and Mapry – full with  $p = 0.049$ . There was no statistical difference among other groups (for all the other combinations:  $p > 0.2$ ).

## 4. Discussion

The study evaluates the ability of low-cost novel lidar systems for diameter estimation of tree stems. Estimating diameter represents important data for many aspects, from forestry [23], to urban tree systems, road and rails surrounding, and many others. We compared semi-automatic measurement using the RANSAC algorithm and manual tree detection and fully automatic extraction using the freely available FORTLS package.

FORTLS showed a slightly lower accuracy than RANSAC in most cases. That may be expected as the RANSAC approach consisted of manually selected tree sections. Thus avoiding many complex situations (leaves, branches, etc.) that the algorithms implemented in FORTLS had to deal because of the automatic approach. This was even more evident with the Mapry device because this technology generated more noise in their point clouds. Especially in the complex scans due to matching errors. The performance of the Mapry device shows clearly better results for both processing methods than for full scans, which is mostly due to the misalignment of longer trajectories, as mentioned by other authors [5].

The assessment of tree diameter and positions of trees, by other words the structure of the forest is important not only for the information about forest but also for example for movement of vehicles designed for such conditions. cite

221

222

223

224

225

226

227

228

229

230

231

232

233

234

235

236

237

238

239

240

241

242

243

244

245

246

247

248

249

## 5. Conclusions

250

This work aimed to evaluate the suitability of the new low-cost MLS Livox with the state-of-the-art technology in DBH estimation. We demonstrated the accuracy using manually selected datasets from stem cross-sections, using the RANSAC algorithm and complete workflow from scanning to automatic analysis using the FORTLS ready-to-go package in R software. Both procedures showed a high accuracy for diameter detection, though, in the case of RANSAC, single scans were more precise than full multi traversal scans due to the error in rotation and movements of the device itself. Therefore, it is recommended to incorporate this information into the scanning workflow procedure for future data acquisition and analysis.

251  
252  
253  
254  
255  
256  
257  
258  
259  
260

**Author Contributions:** “Conceptualization, P.S., S.T. and M.M.; methodology, P.S. K.Y.; software, K.Y., P.S. and J.M.; validation, M.M., Z.M. and J.M.; writing—original draft preparation, P.S., J.M.; writing—review and editing, M.M., K.Y., Z.M; project administration, X.X.; funding acquisition, P.S. All authors have read and agreed to the published version of the manuscript.”

261  
262  
263  
264

**Funding:** The work was financially supported by project TH74010001 funded by the Technological Agency of the Czech Republic through the program Chist-era and the Faculty of Forestry and wood sciences, Czech University of Life Sciences Prague through grant FORESTin3D.

265  
266  
267

**Data Availability Statement:** Data are available on demand

268

**Acknowledgments:**

269

**Conflicts of Interest:** Authors declare no conflict of interest

270

## References

271

- [1] Torresan, C.; Garzón, M. B.; Grady, M. O.; Robson, T. M.; Picchi, G.; Panzacchi, P.; Tomelleri, E.; Smith, M.; Marshall, J.; Wingate, L.; et al. *REVIEW*. **2021**, *1765* (March), 1751–1765. 272  
273
- [2] Temperli, C.; Santopuoli, G.; Bottero, A.; Barbeito, I.; Alberdi, I.; Condés, S.; Gschwantner, T.; Bosela, M.; Neroj, B.; Fischer, C.; et al. *National Forest Inventory Data to Evaluate Climate-Smart Forestry*; **2022**.  
[https://doi.org/10.1007/978-3-030-80767-2\\_4](https://doi.org/10.1007/978-3-030-80767-2_4). 274  
275  
276
- [3] Alberdi, I.; Cañellas, I.; Vallejo Bombín, R. The Spanish National Forest Inventory: History, Development, Challenges and Perspectives. *Pesqui. Florest. Bras.*, **2017**, *37* (91), 361. <https://doi.org/10.4336/2017.pfb.37.91.1337>. 277  
278
- [4] Avitabile, V.; Camia, A. An Assessment of Forest Biomass Maps in Europe Using Harmonized National Statistics and Inventory Plots. *For. Ecol. Manage.*, **2018**, *409* (October 2017), 489–498. 279  
<https://doi.org/10.1016/j.foreco.2017.11.047>. 280  
281
- [5] Čerňava, J.; Mokroš, M.; Tuček, J.; Antal, M.; Slatkovská, Z. Processing Chain for Estimation of Tree Diameter from Gnss-Imu-Based Mobile Laser Scanning Data. *Remote Sens.*, **2019**, *11* (6), 1–25. 282  
<https://doi.org/10.3390/RS11060615>. 283  
284
- [6] Cabo, C.; Del Pozo, S.; Rodríguez-Gonzálvez, P.; Ordóñez, C.; González-Aguilera, D. Comparing Terrestrial Laser Scanning (TLS) and Wearable Laser Scanning (WLS) for Individual Tree Modeling at Plot Level. *Remote Sens.*, **2018**, *10* (4). <https://doi.org/10.3390/rs10040540>. 285  
286  
287
- [7] Xie, Y.; Yang, T.; Wang, X.; Chen, X.; Pang, S.; Hu, J.; Wang, A.; Chen, L.; Shen, Z. Applying a Portable Backpack 288

- Lidar to Measure and Locate Trees in a Nature Forest Plot: Accuracy and Error Analyses. *Remote Sens.*, **2022**, *14* (8). <https://doi.org/10.3390/rs14081806>. 289  
290
- [8] Münzinger, M.; Prechtel, N.; Behnisch, M. Mapping the Urban Forest in Detail: From LiDAR Point Clouds to 3D Tree Models. *Urban For. Urban Green.*, **2022**, *74* (November 2021), 127637. <https://doi.org/10.1016/j.ufug.2022.127637>. 291  
292  
293
- [9] Pu, R.; Landry, S. Mapping Urban Tree Species by Integrating Multi-Seasonal High Resolution Pléiades Satellite Imagery with Airborne LiDAR Data. *Urban For. Urban Green.*, **2020**, *53* (October 2019), 126675. <https://doi.org/10.1016/j.ufug.2020.126675>. 294  
295  
296
- [10] Rodríguez-Puerta, F.; Barrera, C.; García, B.; Pérez-Rodríguez, F.; García-Pedrero, A. M. Mapping Tree Canopy in Urban Environments Using Point Clouds from Airborne Laser Scanning and Street Level Imagery. *Sensors*, **2022**, *22* (9). <https://doi.org/10.3390/s22093269>. 297  
298  
299
- [11] Wang, C.; Ren, Z.; Du, Y.; Guo, Y.; Zhang, P.; Wang, G.; Hong, S.; Ma, Z.; Hong, W.; Li, T. Urban Vegetation Cooling Capacity Was Enhanced under Rapid Urbanization in China. *J. Clean. Prod.*, **2023**, *425* (June), 138906. <https://doi.org/10.1016/j.jclepro.2023.138906>. 300  
301  
302
- [12] Wang, C.; Ren, Z.; Dong, Y.; Zhang, P.; Guo, Y.; Wang, W.; Bao, G. Efficient Cooling of Cities at Global Scale Using Urban Green Space to Mitigate Urban Heat Island Effects in Different Climatic Regions. *Urban For. Urban Green.*, **2022**, *74* (January), 127635. <https://doi.org/10.1016/j.ufug.2022.127635>. 303  
304  
305
- [13] Guo, Y.; Ren, Z.; Wang, C.; Zhang, P.; Ma, Z.; Hong, S.; Hong, W.; He, X. Spatiotemporal Patterns of Urban Forest Carbon Sequestration Capacity: Implications for Urban CO<sub>2</sub> Emission Mitigation during China's Rapid Urbanization. *Sci. Total Environ.*, **2024**, *912*, 168781. <https://doi.org/10.1016/j.scitotenv.2023.168781>. 306  
307  
308
- [14] Barbosa, R. I.; Ramírez-Narváez, P. N.; Fearnside, P. M.; Villacorta, C. D. A.; Carvalho, L. C. da S. Allometric Models to Estimate Tree Height in Northern Amazonian Ecotone Forests. *Acta Amaz.*, **2019**, *49* (2), 81–90. <https://doi.org/10.1590/1809-4392201801642>. 309  
310  
311
- [15] Blanchard, E.; Birnbaum, P.; Ibanez, T.; Boutreux, T.; Antin, C.; Ploton, P.; Vincent, G.; Pouteau, R.; Vandrot, H.; Hequet, V.; et al. Contrasted Allometries between Stem Diameter, Crown Area, and Tree Height in Five Tropical Biogeographic Areas. *Trees - Struct. Funct.*, **2016**, *30* (6), 1953–1968. <https://doi.org/10.1007/s00468-016-1424-3>. 312  
313  
314
- [16] Liang, X.; Hyyppä, J.; Kaartinen, H.; Lehtomäki, M.; Pyörälä, J.; Pfeifer, N.; Holopainen, M.; Brolly, G.; Francesco, P.; Hackenberg, J.; et al. International Benchmarking of Terrestrial Laser Scanning Approaches for Forest Inventories. *ISPRS J. Photogramm. Remote Sens.*, **2018**, *144* (June), 137–179. <https://doi.org/10.1016/j.isprsjprs.2018.06.021>. 315  
316  
317
- [17] Tatsumi, S.; Yamaguchi, K.; Furuya, N. ForestScanner: A Mobile Application for Measuring and Mapping Trees with LiDAR-Equipped iPhone and iPad. *Methods Ecol. Evol.*, **2023**, *14* (7), 1603–1609. <https://doi.org/10.1111/2041-210X.13900>. 318  
319  
320
- [18] White, J. C.; Coops, N. C.; Wulder, M. A.; Vastaranta, M.; Hilker, T.; Tompalski, P. Remote Sensing Technologies for Enhancing Forest Inventories: A Review. *Can. J. Remote Sens.*, **2016**, *42* (5), 619–641. 321  
322

- <https://doi.org/10.1080/07038992.2016.1207484>. 323
- [19] Calders, K.; Adams, J.; Armston, J.; Bartholomeus, H.; Bauwens, S.; Bentley, L. P.; Chave, J.; Danson, F. M.; Demol, M.; Disney, M.; et al. Terrestrial Laser Scanning in Forest Ecology: Expanding the Horizon. *Remote Sens. Environ.*, **2020**, *251* (September), 112102. <https://doi.org/10.1016/j.rse.2020.112102>. 324  
325  
326
- [20] Liang, X.; Kankare, V.; Hyypää, J.; Wang, Y.; Kukko, A.; Haggrén, H.; Yu, X.; Kaartinen, H.; Jaakkola, A.; Guan, F.; et al. Terrestrial Laser Scanning in Forest Inventories. *ISPRS J. Photogramm. Remote Sens.*, **2016**, *115*, 63–77. <https://doi.org/10.1016/j.isprsjprs.2016.01.006>. 327  
328  
329
- [21] Molina-Valero, J. A.; Martínez-Calvo, A.; Ginzo Villamayor, M. J.; Novo Pérez, M. A.; Álvarez-González, J. G.; Montes, F.; Pérez-Cruzado, C. Operationalizing the Use of TLS in Forest Inventories: The R Package FORTLS. *Environ. Model. Softw.*, **2022**, *150* (January). <https://doi.org/10.1016/j.envsoft.2022.105337>. 330  
331  
332
- [22] Guzman, JA, Hernandez, R., and Sanchez-Azofeifa, A. RTLS: Tools to Process Point Clouds Derived from Terrestrial Laser Scanning. R Package Version 0.2.5. <https://CRAN.R-Project.Org/Package=rTLS>. **2021**. 333  
334
- [23] Kuželka, K.; Slavík, M.; Surový, P. Very High Density Point Clouds from UAV Laser Scanning for Automatic Tree Stem Detection and Direct Diameter Measurement. *Remote Sens.*, **2020**, *12* (8). <https://doi.org/10.3390/RS12081236>. 335  
336  
337  
338  
339  
340

## 8 Diskusia

Dynamika a rozvoj lesa predstavujú neoddeliteľnú časť hospodárskej úpravy lesa. Pre dosiahnutie trvalo udržateľného hospodárenia v lesoch je nevyhnutné disponovať informáciami nielen o súčasnom ale aj budúcom stave lesa. Možnosť získavať trojrozmerné údaje z diaľkového prieskumu Zeme je v tomto kontexte kľúčová a už dlhú dobu sa javí použitie dát diaľkového prieskumu Zeme ako vhodná alternatíva alebo doplnok pre presnejšie, správnejšie a v neposlednom rade aj lacnejšie získavanie dát o lesoch.

K tomu aby sme sa dopracovali k získaniu informácii o zmenách zásob porastu je najskôr potrebná presná detekcia, toho čo sa z lesa odstránilo alebo odumrelo. Ak by sme sa nezameriavali na oblasť inventarizácie lesa tak presná detekcia plochy holín je tiež dôležitá v oblasti znižovania emisií a zachytávaní CO<sub>2</sub>, na čo má vplyv ťažba (Pilli et al., 2016).

Kartografická generalizácia je podstatná činnosť pri tvorbe mapových výstupov (Allouche & Moulin, 2005). Autori sa v predchádzajúcich štúdiách zameriavali na úpravu tvarov polygónov za pomoci zjednodušovacích algoritmov, ktoré sú v súčasnosti dostupné v software ArcGIS Pro Esri®. Za pomoci týchto algoritmov vieme zjednodušiť zobrazenia tvarov striech budov, plány mestských obytných oblastí alebo zachovať krivky trajektórie z údajov z GPS vo vozidle (Zielewska-Büttner et al., 2016). Naša štúdia ukázala vhodnosť využitia tejto technológie v Lesníckom sektore, kedy sa v ňom čoraz viac využívajú nástroje diaľkového prieskumu Zeme.

Na zjednodušenie tvarov holín sme otestovali algoritmy Zhou-Jones, Visvalingam-Whyatt, Douglas-Peucker a Wang-Müller integrovaných do softwaru ArcGIS Pro Esri®. Porovnanie z predchádzajúceho výskumu ukázali, že algoritmus Douglas-Peucker bol vhodný na kompresiu údajov a odstránenie nadbytočných detailov polygónov ale za cenu straty topologických charakteristík pôvodnej línie. Na druhej strane algoritmus na zjednodušenie ohybu (Wang-Müller) zachoval viac bodov, čím zachoval topológiu bližšiu pôvodnej línii (Alves et al., 2006).

Praktické využitie týchto algoritmov bolo ilustrované na úprave polygónov holín identifikovaných pomocou leteckého laserového skenovania. Ručné spracovanie, sa ukázalo ako zdĺhavé a málo efektívne, najmä pri práci so značným počtom polygónov. V našom konkrétnom prípade bolo potrebné upraviť 29 polygónov, čo zahŕňalo celkovo 16 649 vrcholov polygónov vytvorených z ALS. Porovnanie ukázalo, že manuálna úprava bola

až dvakrát pomalšia ako použitie týchto nástrojov, čo zdôrazňuje praktické výhody automatickej úpravy.

Hodnotenie lesných zdrojov a znalosť situácie v lese má zásadný význam pre rozhodovanie na úrovni krajiny alebo štátu. Tradične sa na tento účel používajú terestrické metódy spojené so štatistickými technikami, ktoré zahŕňajú extrapoláciu údajov na nemerané oblasti alebo výpočet súhrnných hodnôt pre veľké regióny. Národné inventarizácie lesov (NFI) sa považujú za moderné a presné nástroje na hodnotenie lesných zdrojov, ktoré sa pravidelne vykonávajú vo vyspelých krajinách. Tieto NFI, ktorých cieľom je poskytovať aktuálne a súhrnné údaje o stave a vývoji lesov, sa často dopĺňajú technikami diaľkového prieskumu Zeme. Tieto dáta sa väčšinou používajú ako orientačné informácie na určenie prítomnosti alebo neprítomnosti lesných porastov alebo ako náhrada za inventarizačné dáta zo zkusných plôch v prípade nedostupnosti. Pri získavaní vzoriek najmä v prírodných, prírode blízkyh lesných oblastiach však môže byť požadovaná hustota vzoriek nedostatočná na získanie spoľahlivých a presných súhrnných hodnôt, pretože jednotlivé plochy je náročné extrapolovať na susedné oblasti, ktoré sa môžu líšiť. Na odhad porastových veličín z DPZ sa môžu použiť dve metódy: Individuálna detekcia stromov a Plošný prístup (Yu et al. 2010). V prípade keď chceme charakterizovať celú plošnú jednotku použijeme plošný prístup založený na štatistickým modeloch a metódach (Surový & Kuželka, 2019).

V práci sme vykonali porovnanie rôznych techník štatistického modelovania objemu dreva a analýzu prediktorov na základe údajov diaľkového prieskumu Zeme, presnejšie rasterizovaných lidarových skenov. Všetky hodnotené techniky poskytli podobné výsledky z hľadiska presnosti a relatívne podobné z hľadiska najdôležitejších premenných vybraných na modelovanie. Ukázalo sa, že niektoré premenné viedli pri testovaní na nezávislých datach k nesprávnym predpovediam a ich odstránenie z modelu zlepšilo presnosť. Preto sme dospeli k záveru, že v menších súboroch údajov by sa pri predikcii a extrapolácii údajov mohla zohľadniť biologická analýza prediktorov.

Z dát diaľkového prieskumu Zeme dokážeme okrem získania informácií o aktuálnom stave lesa, predikovať aj jeho vývoj. Predchádzajúce štúdie zdôrazňujú potenciál údajov leteckého laserového skenovania (ALS) na modelovanie a pozorovanie vlastností lesa, najmä bonitu (Guerra-Hernández et al., 2021). (Tompalski, Coops, White, Wulder, et al., 2015) použili ALS na odhad dominantnej výšky porastu, pričom využili časové rady

Landsat na identifikáciu oblastí s disturanciami na odhad veku porastu. Nelineárna regresia s využitím vodiacej krivky bonity bola použitá na fitovanie pre porasty vo veku 7 až 32 rokov, pričom validácia bola vykonaná pomocou diaľkového prieskumu Zeme, inventarizačných údajov a existujúcich modelov. Táto metóda odhadu údajov je vhodná najmä pre mladé porasty v oblastiach, kde chýbajú komplexné inventarizačné údaje o lesoch.

Po odvodení bonity je možné predikovať výšku porastu v danom veku. (Tompalski, Coops, White, & Wulder, 2015) skúmali presnosť odvodenia výšky z tradičných bonitných kriviek v porovnaní s krivkami odvodenými z leteckého laserového skenovania (ALS), pričom odhalili významné rozdiely ovplyvnené faktormi, ako je zložitosť porastu a pokryvnosť korún. Na modelovanie indexu stanovišťa je možné použiť parametrické a neparametrické modely, pričom parametrické modely vykazujú vyššiu presnosť, najmä ak sú zahrnuté informácie o veku (Watt et al., 2015). Na mapovanie a predpovedanie bonity sa taktiež využíva opakované laserové skenovanie, pričom intervaly od piatich rokov sa ukázali ako dostatočné (Socha et al., 2017).

Od využitia technológie ALS pri inventarizácii lesov uplynulo už niekoľko rokov a v súčasnosti môžeme využívať opakované skenovanie s časovým odstupom až 15 rokov (Noordermeer et al., 2019). V našej štúdii sme v intervale 14 rokov úspešne odhadli bonitu v jemnejšej mierke (v prípade absolútnej bonity) až po hrubšiu mierku v prípade relatívneho bonity. Opakované laserové skenovanie (pätnásť rokov) sa môže použiť aj pri odhade bonity pomocou priamych a nepriamych metód. Pri priamej metóde môžu terénne pozorovania predstavovať regresiu vekovo-výškovej bonity voči metrikám výšky odvodeným z údajov ALS z prvého časového bodu a zmenám v metrikách ALS odrážajúcich rast výšky počas obdobia pozorovania. V týchto dvoch časových bodoch sa najprv modelovala  $H_{dom}$  pomocou príslušných metrik ALS ako prediktorov bonity, odvodených z počiatkovej  $H_{dom}$ , odhadovaného prírastku  $H_{dom}$  a dĺžky obdobia pozorovania pomocou empirických kriviek bonity. Oba prístupy prinášajú uspokojivý odhad bonity (Noordermeer et al., 2018). V našej štúdii sme namiesto toho použili strednú výšku porastu a dokázali sme, že vo všetkých prípadoch patril medián výšky lidarových dát vždy medzi najdôležitejšie prediktory. Na druhej strane sa vo všetkých modalitách (regresia, strojové učenie) ukázalo, že vek sa zlepšil zahrnutím premennej vek. Na prvý pohľad sa zdá, že vek nie je priamo dostupný z materiálov diaľkového prieskumu Zeme.



Dôsledné dlhodobé monitorovanie však môže vymedziť holiny alebo disturbancie a definovať počiatočné obdobie pre novú generáciu stromového porastu. Takéto mapovanie sa dá v súčasnosti tiež ľahko realizovať (Melichová et al., 2023) a plochy holín s veľmi vysokým rozlíšením mapovania možno analyzovať na účely predikcie prežívania vegetácie (Hüttnerová et al., 2024).

Porovnanie, ktoré vykonali (Bollandsås et al., 2019), poukázalo na presnosť modelovania indexu lokality na základe jednorazových hyperspektrálnych údajov, bitemporálnych laserových skenov a ich kombinácie. Údaje z ALS použité v tejto štúdií boli získané v dvoch časových obdobiach s dvanásťročným rozdielom. Hyperspektrálne údaje boli získané tým istým letom ako údaje ALS. Údaje ALS v kombinácii s hyperspektrálnymi snímkami vykazovali zanedbateľný príspevok hyperspektrálnych údajov v porovnaní so samotnými bitemporálnymi údajmi ALS. V prípadoch, keď sú k dispozícii len spektrálne dáta, je stále možné zostaviť prediktívne modely bonity H40 (ktoré sa v Nórsku používa na vyjadrenie produktivity lesa). Aj v súčasnosti je pri rozhodovaní o tom, aké dáta sa použijú, dôležitý finančný aspekt. Priame metódy využívajúce bitemporálne ALS a DAP preukázali najvyššiu presnosť s najnižšími celkovými nákladmi (Noordermeer et al., 2021).

Na základe nameraných prírastkov z bitemporálnych dát diaľkového prieskumu Zeme je možné skonštruovať rastové modely a odhadnúť bonitu (Noordermeer et al., 2018). V našej štúdií sme prírastkovú funkciu odvodili na základe Chapman-Richard rastovej funkcie a dát z opakovaného leteckého laserového skenovania.

V prípade lesníctva sa stále viac dostáva do pozornosti potreba reakcie obhospodarovania lesa na klimatickú zmenu. Dáta z diaľkového prieskumu Zeme sa čoraz viac dostávajú do popredia kvôli dostupnosti, efektívnosti zberu dát a ploche ktorú je potreba pokryť. NFI vie pri zbere dát pokryť len obmedzené územie v porovnaní s celkovou rozlohou lesov. Upevnenie nástroja DPZ ako napríklad mobilného laserového skeneru na lesný traktor umožňuje zvýšiť plochu hodnotenia (Čerňava et al., 2019). Atribúty stromov ako výška, priemer v prsnej výške, a objem sú základnými parametrami pre výpočet ďalších charakteristík stromov za pomoci alometrických modelov. Väčšina týchto modelov sa zameriava na priemer stromu (Barbosa et al., 2019). Naša štúdiá hodnotí schopnosť nových nízkonákladových lidarových systémov odhadovať hrúbky stromov. Odhad hrúbky predstavuje dôležitý údaj pre mnohé aspekty, od lesníctva (Karel Kuželka et al., 2020), cez mestské stromové systémy, okolie ciest a koľajníc, až po mnohé ďalšie. Porovnávali sme



poloautomatické meranie pomocou algoritmu RANSAC a manuálnu detekciu stromov a plne automatickú extrakciu pomocou voľne dostupného balíka FORTLS. FORTLS vykazoval vo väčšine prípadov o niečo nižšiu presnosť ako RANSAC, keďže prístup RANSAC pozostával z manuálne vybraných sekcií stromov. Tým sa vyhol mnohým zložitým situáciám (listy, vetvy atď.)s ktorými sa algoritmy implementované v systéme FORTLS museli vysporiadať kvôli automatickému prístupu. V prípade zariadenia Mapry to bolo ešte zjavnejšie, pretože táto technológia generovala viac šumu vo svojich mračnách bodov. Výkonnosť zariadenia Mapry vykazuje pri oboch metódach spracovania jednoznačne lepšie výsledky ako pri úplnom skenovaní, čo je spôsobené najmä nesprávnym vyrovnaním dlhších trajektórií, ako uvádzajú iní autori (Čerňava et al., 2019).

## 9 Záver

Táto práca sa zaoberá možnosťami využitia laserových dát pre odhad rastu a dynamiky lesných porastov. Výsledky boli publikované v troch prijatých prácach a jednej, ktorá je v recenznom konaní. Celkove boli popísané tri základné kroky pre odhad rastu a to: detekcia úbytku pomocou automatického vylíšenia holín, možnosti využitia strojového učenia a lineárneho modelovania pre odhad zásob, odhad bonity stanovišťa pomocou bitemporálneho laserového skenu a možnosti využitia nízkonákladových laserových prototypov pre získavanie pozemných dát o lesných porastoch. Zrejme najdôležitejšou prácou je odhad bonity, kde bola preukázaná dobrá kvalita odhadu bonity len pomocou dát z LiDARu, a bolo preukázané, že dôležitý prediktor – vek porastu, dnes sice nie je k dispozícii z DPZ dát, ale opakovaným a dlhoročným skenovaním bude možné ho získať napríklad aj automaticky ako to bolo popísané v článku o automatickej detekcii holín. Laserové skenovanie je relevantnou alternatívou k pozemnému zberu dát, a jeho širšie používanie pomôže nielen statickej inventarizácii, tj kde je koľko lesa, ale hlavne k pochopeniu dynamiky a rastu lesa, a tým aj ku krokom k jeho lepšiemu obhospodarovaniu alebo jeho ochrany. Dúfam, že mojím kúskom k tomu prispeje aj táto dizertačná práca.

## Referencie

- Ahmad, N., Ghazilla, R. A. R., Khairi, N. M., & Kasi, V. (2013). Reviews on Various Inertial Measurement Unit (IMU) Sensor Applications. *International Journal of Signal Processing Systems*, 1(2), 256–262. <https://doi.org/10.12720/ijsp.1.2.256-262>
- Allouche, M. K., & Moulin, B. (2005). Amalgamation in cartographic generalization using Kohonen's feature nets. *International Journal of Geographical Information Science*, 19(8–9), 899–914. <https://doi.org/10.1080/13658810500161211>
- Alves, M., Santo, D., & Oliveira, F. H. De. (n.d.). Algorithms for Automated Line Generalization in GIS 1 Introduction 2 Geographic Information Systems 3 Line Simplifying. *Information Systems*.
- Antonelli, P. L. (1992). The Algorithmic Beauty of Plants (Przemyslaw Prusinkiewicz and Aristid Lindenmayer). *SIAM Review*, 34(1), 142–143. <https://doi.org/10.1137/1034030>
- Avitabile, V., & Camia, A. (2018). An assessment of forest biomass maps in Europe using harmonized national statistics and inventory plots. *Forest Ecology and Management*, 409(December), 489–498. <https://doi.org/10.1016/j.foreco.2017.11.047>
- Baltsavias, E. P. (1999). Airborne laser scanning: Existing systems and firms and other resources. In *ISPRS Journal of Photogrammetry and Remote Sensing* (Vol. 54, Issues 2–3). [https://doi.org/10.1016/S0924-2716\(99\)00016-7](https://doi.org/10.1016/S0924-2716(99)00016-7)
- Barbosa, R. I., Ramírez-Narváez, P. N., Fearnside, P. M., Villacorta, C. D. A., & Carvalho, L. C. da S. (2019). Allometric models to estimate tree height in northern amazonian ecotone forests. *Acta Amazonica*, 49(2), 81–90. <https://doi.org/10.1590/1809-4392201801642>
- Bollandsås, O. M., Ørka, H. O., Dalponte, M., Gobakken, T., & Næsset, E. (2019). Modelling site index in forest stands using airborne hyperspectral imagery and Bi-temporal laser scanner data. *Remote Sensing*, 11(9). <https://doi.org/10.3390/rs11091020>
- Bruna, V., Elznicova, J., & Pacina, J. (2012). *Využití geoinformačních technologií pro hodnocení krajiny přeshraniční oblasti Česko-Saské Švýcarsko. January 2015.*
- Căţeanu, M., & Ciubotaru, A. (2021). The effect of lidar sampling density on dtm accuracy for areas with heavy forest cover. *Forests*, 12(3), 1–20. <https://doi.org/10.3390/f12030265>
- Čerňava, J., Mokroš, M., Tuček, J., Antal, M., & Slatkovská, Z. (2019). Processing chain for estimation of tree diameter from gnss-imu-based mobile laser scanning data. *Remote*

*Sensing*, 11(6), 1–25. <https://doi.org/10.3390/RS11060615>

Černý, M., Pařez, J., Malík, Z. (1993). *Růstové modely hlavních dřevin České republiky (smrk, borovice, buk, dub) –2. etapa. Zpráva o výsledcích řešení za rok 1993. Skupina ekologického monitoringu PYRUS, 66 s.*

Di, L., & Yu, E. (2023). *Remote Sensing BT - Remote Sensing Big Data* (L. Di & E. Yu (Eds.); pp. 17–43). Springer International Publishing. [https://doi.org/10.1007/978-3-031-33932-5\\_2](https://doi.org/10.1007/978-3-031-33932-5_2)

Dolanský, T. (2004). *Lidary a letecké laserové skenování.*

Erdle, K., Mistele, B., & Schmidhalter, U. (2011). Comparison of active and passive spectral sensors in discriminating biomass parameters and nitrogen status in wheat cultivars. *Field Crops Research*, 124(1), 74–84. <https://doi.org/10.1016/j.fcr.2011.06.007>

Fabrika, M., & Pretzsch, H. (2011). *Analýza a modelovanie lesných ekosystémov.* Technická univerzita vo Zvolene.

Fatehi, P., Damm, A., Leiterer, R., Bavaghar, M. P., Schaepman, M. E., & Kneubühler, M. (2017). Tree density and forest productivity in a heterogeneous alpine environment: Insights from airborne laser scanning and imaging spectroscopy. *Forests*, 8(6). <https://doi.org/10.3390/f8060212>

Fernandez-Diaz, J. C., Carter, W. E., Shrestha, R. L., & Glennie, C. L. (2014). Now you see it... Now you don't: Understanding airborne mapping LiDAR collection and data product generation for archaeological research in Mesoamerica. *Remote Sensing*, 6(10), 9951–10001. <https://doi.org/10.3390/rs6109951>

Fitzgerald, G. J. (2010). Characterizing vegetation indices derived from active and passive sensors. *International Journal of Remote Sensing*, 31(16), 4335–4348. <https://doi.org/10.1080/01431160903258217>

Forkuo, E. K. (2008). Digital terrain modeling in a GIS environment. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37(B2), 1023–1029.

Habib, A., Bang, K. I., Kersting, A. P., & Chow, J. (2010). Alternative methodologies for LiDAR system calibration. *Remote Sensing*, 2(3), 874–907. <https://doi.org/10.3390/rs2030874>

Hay, S. I. (2000). An overview of remote sensing and geodesy for epidemiology and public health application. *Advances in Parasitology*, 47(May 2000), 1–35. [https://doi.org/10.1016/s0065-308x\(00\)47005-3](https://doi.org/10.1016/s0065-308x(00)47005-3)

- Hüttnerová, T., Muscarella, R., & Surový, P. (2024). *Drone microrelief analysis to predict the presence of naturally regenerated seedlings. January.* <https://doi.org/10.3389/ffgc.2023.1329675>
- Kuželka, K, & et. al. (2014). *Měření lesa: Moderní metody sběru a zpracování dat.* Česká zemědělská univerzita, Fakulta lesnická a dřevařská. <https://books.google.cz/books?id=T4tmrgEACAAJ>
- Kuželka, Karel, Slavík, M., & Surový, P. (2020). Very high density point clouds from UAV laser scanning for automatic tree stem detection and direct diameter measurement. *Remote Sensing*, 12(8). <https://doi.org/10.3390/RS12081236>
- Larsson, P. (2003). Global Positioning System and Sport-Specific Testing. *Sports Medicine*, 33(15), 1093–1101. <https://doi.org/10.2165/00007256-200333150-00002>
- Liang, X., Kankare, V., Hyypä, J., Wang, Y., Kukko, A., Haggrén, H., Yu, X., Kaartinen, H., Jaakkola, A., Guan, F., Holopainen, M., & Vastaranta, M. (2016). Terrestrial laser scanning in forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 63–77. <https://doi.org/10.1016/j.isprsjprs.2016.01.006>
- Liang, X., Kukko, A., Hyypä, J., Lehtomäki, M., Pyörälä, J., Yu, X., Kaartinen, H., Jaakkola, A., & Wang, Y. (2018). In-situ measurements from mobile platforms: An emerging approach to address the old challenges associated with forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 143(June), 97–107. <https://doi.org/10.1016/j.isprsjprs.2018.04.019>
- Lu, Z., Kwoun, O., & Rykhus, R. (2007). Interferometric synthetic aperture radar (InSAR): Its past, present and future. *Photogrammetric Engineering and Remote Sensing*, 73(3), 217–221.
- Lundemo, S., Izquierdo, P., Korakaki, E., Aguilar-Amuchastegui, N., Korhonen, L., Melin, M., Shapiro, A. C., & Glover, P. (2017). Conservation Technology: Remote Sensing: LIDAR. *WWF Conservation Technology Series*, 1(3).
- Maltamo, M., Eerikäinen, K., Pitkänen, J., Hyypä, J., & Vehmas, M. (2004). Estimation of timber volume and stem density based on scanning laser altimetry and expected tree size distribution functions. *Remote Sensing of Environment*, 90(3), 319–330. <https://doi.org/10.1016/j.rse.2004.01.006>
- Maranda, B. H. (2008). *Passive Sonar BT - Handbook of Signal Processing in Acoustics* (D. Havelock,

- S. Kuwano, & M. Vorländer (Eds.); pp. 1757–1781). Springer New York.  
[https://doi.org/10.1007/978-0-387-30441-0\\_97](https://doi.org/10.1007/978-0-387-30441-0_97)
- Mason, A., & Schmetz, J. (1992). Meteorological satellites. *International Journal of Remote Sensing*, 13(6–7), 1153–1172. <https://doi.org/10.1080/01431169208904185>
- Melichová, Z., Pekár, S., & Surový, P. (2023). Benchmark for Automatic Clear-Cut Morphology Detection Methods Derived from Airborne Lidar Data. *Forests*, 14(12).  
<https://doi.org/10.3390/f14122408>
- Meng, X., Currit, N., & Zhao, K. (2010). Ground filtering algorithms for airborne LiDAR data: A review of critical issues. *Remote Sensing*, 2(3), 833–860. <https://doi.org/10.3390/rs2030833>
- Minus (Spatial Analyst)*. (n.d.). <https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-analyst/minus.htm>
- Morsdorf, F., Nichol, C., Malthus, T., & Woodhouse, I. H. (2009). Assessing forest structural and physiological information content of multi-spectral LiDAR waveforms by radiative transfer modelling. *Remote Sensing of Environment*, 113(10), 2152–2163.  
<https://doi.org/10.1016/j.rse.2009.05.019>
- Næsset, E. (1997). Estimating timber volume of forest stands using airborne laser scanner data. *Remote Sensing of Environment*, 61(2), 246–253. [https://doi.org/10.1016/S0034-4257\(97\)00041-2](https://doi.org/10.1016/S0034-4257(97)00041-2)
- Næsset, E. (2002). Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sensing of Environment*, 80(1), 88–99.  
[https://doi.org/10.1016/S0034-4257\(01\)00290-5](https://doi.org/10.1016/S0034-4257(01)00290-5)
- Næsset, E., & Gobakken, T. (2005). Estimating forest growth using canopy metrics derived from airborne laser scanner data. *Remote Sensing of Environment*, 96(3–4), 453–465.  
<https://doi.org/10.1016/j.rse.2005.04.001>
- Nelson, R. (2013). How did we get here? An early history of forestry lidar. *Canadian Journal of Remote Sensing*, 39(SUPPL.1). <https://doi.org/10.5589/m13-011>
- Nilsson, M. (1996). Estimation of tree heights and stand volume using an airborne lidar system. *Remote Sensing of Environment*, 56(1), 1–7. [https://doi.org/10.1016/0034-4257\(95\)00224-3](https://doi.org/10.1016/0034-4257(95)00224-3)
- Noordermeer, L., Bollandsås, O. M., Gobakken, T., & Næsset, E. (2018). Direct and indirect site index determination for Norway spruce and Scots pine using bitemporal airborne laser

- scanner data. *Forest Ecology and Management*, 428(June), 104–114.  
<https://doi.org/10.1016/j.foreco.2018.06.041>
- Noordermeer, L., Gobakken, T., Næsset, E., & Bollandsås, O. M. (2020). Predicting and mapping site index in operational forest inventories using bitemporal airborne laser scanner data. *Forest Ecology and Management*, 457(December 2019), 117768.  
<https://doi.org/10.1016/j.foreco.2019.117768>
- Noordermeer, L., Gobakken, T., Næsset, E., & Bollandsås, O. M. (2021). Economic utility of 3D remote sensing data for estimation of site index in Nordic commercial forest inventories: a comparison of airborne laser scanning, digital aerial photogrammetry and conventional practices. *Scandinavian Journal of Forest Research*, 36(1), 55–67.  
<https://doi.org/10.1080/02827581.2020.1854340>
- Noordermeer, L., Økseter, R., Ørka, H. O., Gobakken, T., Næsset, E., & Bollandsås, O. M. (2019). Classifications of Forest Change by Using Bitemporal Airborne Laser Scanner Data. *Remote Sensing*, 11(18), 2145. <https://doi.org/10.3390/rs11182145>
- Olofsson, K., Holmgren, J., & Olsson, H. (2014). Tree stem and height measurements using terrestrial laser scanning and the RANSAC algorithm. *Remote Sensing*, 6(5).  
<https://doi.org/10.3390/rs6054323>
- PDAL. (2022a). <https://pdal.io/en/2.4.3/workshop/exercises/analysis/ground/ground.html>
- PDAL. (2022b). <https://pdal.io/en/2.4.3/workshop/exercises/analysis/rasterize/rasterize.html>
- PDAL. (2022c). <https://pdal.io/en/2.4.3/workshop/exercises/analysis/dtm/dtm.html>
- Percuoco, R. (2014). *Chapter 1 - Plain Radiographic Imaging* (D. M. B. T.-C. I. (Third E. Marchiori (Ed.); pp. 1–43). Mosby. <https://doi.org/https://doi.org/10.1016/B978-0-323-08495-6.00001-4>
- Perttunen, J. (2008). The LIGNUM functional-structural tree model. In *Ecological Modelling* (Issue December). <http://lib.tkk.fi/Diss/2009/isbn9789512297108/>
- Peter, S., & Kuželka, K. (2019). *Aplikace dálkového průzkumu Země v lesnictví*. Česká zemědělská univerzita, Fakulta lesnická a dřevařská.  
<https://books.google.cz/books?id=iUgBzgEACAAJ>
- Pierzchała, M., Giguère, P., & Astrup, R. (2018). Mapping forests using an unmanned ground vehicle with 3D LiDAR and graph-SLAM. *Computers and Electronics in Agriculture*, 135

- 145(March), 217–225. <https://doi.org/10.1016/j.compag.2017.12.034>
- Pilli, R., Grassi, G., Kurz, W. A., Moris, J. V., & Viñas, R. A. (2016). Modelling forest carbon stock changes as affected by harvest and natural disturbances. II. EU-level analysis. *Carbon Balance and Management*, 11(1). <https://doi.org/10.1186/s13021-016-0059-4>
- Riofrío, J., White, J. C., Tompalski, P., Coops, N. C., & Wulder, M. A. (2023). Modelling height growth of temperate mixedwood forests using an age-independent approach and multi-temporal airborne laser scanning data. *Forest Ecology and Management*, 543(June). <https://doi.org/10.1016/j.foreco.2023.121137>
- Roberts, K. C., Lindsay, J. B., & Berg, A. A. (2019). An Analysis of Ground-Point Classifiers for Terrestrial LiDAR. *Remote Sensing*, 11(16), 1915. <https://doi.org/10.3390/rs11161915>
- Saarela, S., Holm, S., Healey, S. P., Andersen, H. E., Petersson, H., Prentius, W., Patterson, P. L., Næsset, E., Gregoire, T. G., & Ståhl, G. (2018). Generalized hierarchical model-based estimation for aboveground biomass assessment using GEDI and landsat data. *Remote Sensing*, 10(11). <https://doi.org/10.3390/rs10111832>
- Salas, E. A. L. (2021). Waveform LiDAR concepts and applications for potential vegetation phenology monitoring and modeling: a comprehensive review. *Geo-Spatial Information Science*, 24(2), 179–200. <https://doi.org/10.1080/10095020.2020.1761763>
- Sardar, A. M. (1997). The Evolution of Space-Borne Imaging Radar Systems: A Chronological History. *Canadian Journal of Remote Sensing*, 23(3), 276–280. <https://doi.org/10.1080/07038992.1997.10855210>
- Socha, J., Pierzchalski, M., Bałazy, R., & Ciesielski, M. (2017). Modelling top height growth and site index using repeated laser scanning data. *Forest Ecology and Management*, 406(October), 307–317. <https://doi.org/10.1016/j.foreco.2017.09.039>
- Socha, J., Tyminska-Czabanska, L., Grabska, E., & Orzeł, S. (2020). Site index models for main forest-forming tree species in poland. *Forests*, 11(3), 8–10. <https://doi.org/10.3390/f11030301>
- SOLODUKHIN, V. ., ZHUKOV, A. Y., MAZHUGIN, I. N., & NARKEVICH, V. . (1979). *Metody Izuchenija Vertikal'nyh Sechenij Drevostoev (Method of study of vertical sections of forest stands)*. Leningrad Scientific Research Institute of Forestry.
- Sopchaki, C. H., & Sampaio, T. V. M. (2016). Airborne Laser Scanner: principles of operation, recent uses in Brazil and regulatory issue from laws and parameters in Brazil and in the USA. *Journal*

- of Hyperspectral Remote Sensing*, 6(7), 338. <https://doi.org/10.29150/jhrs.v6.7.p338-353>
- Stereńczak, K. (2011). Wykorzystanie numerycznego modelu terenu i modelu pokrycia terenu do klasyfikacji drzewostanów na podstawie ich struktury pionowej i gatunkowej. *Sylwan*, 155(4), 219–227. <https://www.researchgate.net/publication/236233392>
- Sun, L., Fang, L., Weng, Y., & Zheng, S. (2020). An integrated method for coding trees, measuring tree diameter, and estimating tree positions. *Sensors (Switzerland)*, 20(1). <https://doi.org/10.3390/s20010144>
- Surový, P., & Kuželka, K. (2019). Acquisition of forest attributes for decision support at the forest enterprise level using remote-sensing techniques-a review. *Forests*, 10(3). <https://doi.org/10.3390/f10030273>
- Surový, P., & Melichová, Z. (2023). A Note on Statistical Techniques and Biological Background in Analysis of Remote Sensed Data in Forest Inventory. *Formath*, 22(0), 8. <https://doi.org/10.15684/formath.22.003>
- Tompalski, P., Coops, N. C., Marshall, P. L., White, J. C., Wulder, M. A., & Bailey, T. (2018). Combining multi-date airborne laser scanning and digital aerial photogrammetric data for forest growth and yield modelling. *Remote Sensing*, 10(2), 1–21. <https://doi.org/10.3390/rs10020347>
- Tompalski, P., Coops, N. C., White, J. C., & Wulder, M. A. (2015). Augmenting site index estimation with airborne laser scanning data. *Forest Science*, 61(5), 861–873. <https://doi.org/10.5849/forsci.14-175>
- Tompalski, P., Coops, N. C., White, J. C., & Wulder, M. A. (2016). Enhancing forest growth and yield predictions with airborne laser scanning data: Increasing spatial detail and optimizing yield curve selection through template matching. *Forests*, 7(11), 1–20. <https://doi.org/10.3390/f7110255>
- Tompalski, P., Coops, N. C., White, J. C., Wulder, M. A., & Pickell, P. D. (2015). Estimating Forest Site Productivity Using Airborne Laser Scanning Data and Landsat Time Series. *Canadian Journal of Remote Sensing*, 41(3), 232–245. <https://doi.org/10.1080/07038992.2015.1068686>
- Turner, W., Spector, S., Gardiner, N., Fladeland, M., Sterling, E., & Steininger, M. (2003). Remote sensing for biodiversity science and conservation. *Trends in Ecology and Evolution*, 18(6),



306–314. [https://doi.org/10.1016/S0169-5347\(03\)00070-3](https://doi.org/10.1016/S0169-5347(03)00070-3)

- Ussyshkin, V., & Theriault, L. (2011). Airborne lidar: Advances in discrete return technology for 3D vegetation mapping. *Remote Sensing*, 3(3), 416–434. <https://doi.org/10.3390/rs3030416>
- Van Genchten, B. (2008). Theory and practice on Terrestrial Laser Scanning. *Learning Tools for Advanced Three-Dimensional Surveying in Risk Awareness Project*, June, 1–241.
- Verhoeven, G. J. (2018). *AARGnews*. October 2017, 10–18. <https://doi.org/10.5281/zenodo.3534245>
- Wang, X., Pan, H., Guo, K., Yang, X., & Luo, S. (2020). The evolution of LiDAR and its application in high precision measurement. *IOP Conference Series: Earth and Environmental Science*, 502(1). <https://doi.org/10.1088/1755-1315/502/1/012008>
- Watt, M. S., Dash, J. P., Bhandari, S., & Watt, P. (2015). Comparing parametric and non-parametric methods of predicting Site Index for radiata pine using combinations of data derived from environmental surfaces, satellite imagery and airborne laser scanning. *Forest Ecology and Management*, 357, 1–9. <https://doi.org/10.1016/j.foreco.2015.08.001>
- Wehr, A., & Lohr, U. (1999). Airborne laser scanning - An introduction and overview. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(2–3), 68–82. [https://doi.org/10.1016/S0924-2716\(99\)00011-8](https://doi.org/10.1016/S0924-2716(99)00011-8)
- Weiskittel, A. R., Hann, D. W., Kershaw, J. A., & Vanclay, J. K. (2011). Forest Growth and Yield Modeling. *Forest Growth and Yield Modeling*, January 2014. <https://doi.org/10.1002/9781119998518>
- Wujanz, D. (2016). Terrestrial Laser Scanning For Deformation Monitoring. *3rd IAG / 12th FIG Symposium, Baden, May 22-24, January*, 1–10. <https://doi.org/10.14279/depositonce-5136>
- Xiao, W., Zaforemska, A., Smigaj, M., Wang, Y., Gaulton, R., Xiao, W., Zaforemska, A., Smigaj, M., Wang, Y., & Gaulton, R. (2019). Mean Shift Segmentation Assessment for Individual Forest Tree Delineation from Airborne Lidar Data. *Remote Sensing*, 11(11), 1263. <https://doi.org/10.3390/rs11111263>
- Yu, X., Hyyppä, J., Kaartinen, H., Maltamo, M., & Hyyppä, H. (2008). Obtaining plotwise mean height and volume growth in boreal forests using multi-temporal laser surveys and various change detection techniques. *International Journal of Remote Sensing*, 29(5), 1367–1386. <https://doi.org/10.1080/01431160701736356>

- Yu, Xiaowei, Hyypä, J., Holopainen, M., & Vastaranta, M. (2010). Comparison of area-based and individual tree-based methods for predicting plot-level forest attributes. *Remote Sensing*, 2(6), 1481–1495. <https://doi.org/10.3390/rs2061481>
- Yu, Xiaowei, & Maltamo, M. (2006). METHODS OF AIRBORNE LASER SCANNING FOR FOREST Test Site and Applied Laser Scanner Data. *Workshop on 3D Remote Sensing in Forestry, May 2014*, 1–16.
- Zielewska-Büttner, K., Adler, P., Ehmann, M., & Braunisch, V. (2016). Automated detection of forest gaps in spruce dominated stands using canopy height models derived from stereo aerial imagery. *Remote Sensing*, 8(3). <https://doi.org/10.3390/rs8030175>
- Zonal Statistics as Table (Spatial Analyst) tle.* (n.d.). <https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-analyst/zonal-statistics-as-table.htm>
- Zuzulová, V., Žilinský, M., & Kováčik, M. (2020). *Diaľkový prieskum Zeme a jeho využitie na hodnotenie sucha v poľnohospodárskej krajine.*