

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

FAKULTA ŽIVOTNÍHO PROSTŘEDÍ

KATEDRA PROSTOROVÝCH VĚD

**Porovnání leaf-off a leaf-on UAV modelů vegetace
v bezpečnostním monitoringu**

DIPLOMOVÁ PRÁCE

Vedoucí práce: Ing. Tomáš Klouček, Ph.D.

Diplomant: Bc. Barbora Maletínská

2024

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Barbora Maletínská

Prostorové vědy v životním prostředí

Název práce

Porovnání leaf-off a leaf-on UAV modelů vegetace v bezpečnostním monitoringu

Název anglicky

Comparison of leaf-off and leaf-on UAV-based vegetation models in safety monitoring

Cíle práce

Cílem diplomové práce je porovnat výškovou přesnost modelů vegetace (leaf-off a leaf-on) vypočtených na základě dat pořízených UAV senzory. Dalším cílem je zhodnocení zdravotního stavu vegetace podél dopravní infrastruktury pomocí vybraných spektrálních indexů.

Dílčí cíle práce souvisí s těmito výzkumnými otázkami:

- Liší se přesnost leaf-on a leaf-off UAV modelů vegetace při určování výšek stromů?
- Jaká je přesnost leaf-on a leaf-off UAV modelů vegetace v porovnání s pozemním měřením výšek stromů?
- Existují u leaf-on a leaf-off UAV modelů rozdíly výškové přesnosti pro jednotlivé druhy stromů?
- Zvýší výškovou přesnost modelu vegetace kombinace leaf-on DSM a leaf-off DTM?
- Jsou spektrální indexy odvozené z UAV dat vhodné k monitoringu zdravotního stavu vegetace a mohou tak být využity v úlohách zaměřených na bezpečnost dopravní infrastruktury?

Metodika

Rámcovou náplní práce bude:

- Zpracování UAV dat;
- Stratifikovaný výběr a měření referenčních dat pomocí laserových výškoměrů NICON Forestry Pro II a HAGLOF Laser GEO;
- Validace modelů leaf-on a leaf-off a vyhodnocení výškové přesnosti v porovnání s referenčními daty;
- Statistické vyhodnocení výškové přesnosti jednotlivých druhů stromů;
- Zhodnocení zdravotního stavu stromů kolem dopravní infrastruktury;
- Zodpovězení výzkumných otázek uvedených v cílech práce.

Doporučený rozsah práce

cca 40 normovaných stran

Klíčová slova

normovaný digitální model povrchu, canopy height model, Structure from Motion, bodové mračno, MAE, RMSE

Doporučené zdroje informací

- JIN, Cheonggil; OH, Che-young; SHIN, Sanghyun; WILFRED NJUNGWI, Nkwain a CHOI, Chuluong. A Comparative Study to Evaluate Accuracy on Canopy Height and Density Using UAV, ALS, and Fieldwork. Online. *Forests*. 2020, roč. 11, č. 2. ISSN 1999-4907. Dostupné z: <https://doi.org/10.3390/f11020241>.
- JURJEVIĆ, Luka; LIANG, Xinlian; GAŠPAROVIĆ, Mateo a BALENOVIĆ, Ivan. Is field-measured tree height as reliable as believed – Part II, A comparison study of tree height estimates from conventional field measurement and low-cost close-range remote sensing in a deciduous forest. Online. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2020, roč. 169, s. 227-241. ISSN 09242716. Dostupné z: <https://doi.org/10.1016/j.isprsjprs.2020.09.014>.
- KOMÁREK, Jan; LAGNER, Ondřej a KLOUČEK, Tomáš. UAV leaf-on, leaf-off and ALS-aided tree height: A case study on the trees in the vicinity of roads. Online. *Urban Forestry & Urban Greening*. 2024, roč. 93. ISSN 16188667. Dostupné z: <https://doi.org/10.1016/j.ufug.2024.128229>.
- KWAK, Doo-Ahn; LEE, Woo-Kyun; LEE, Jun-Hak; BIGING, Greg S. a GONG, Peng. Detection of individual trees and estimation of tree height using LiDAR data. Online. *Journal of Forest Research*. 2017, roč. 12, č. 6, s. 425-434. ISSN 1341-6979. Dostupné z: <https://doi.org/10.1007/s10310-007-0041-9>.
- NASIRI, Vahid; DARVISHSEFAT, Ali A.; AREFI, Hossein; PIERROT-DESEILLIGNY, Marc; NAMIRANIAN, Manochehr et al. Unmanned aerial vehicles (UAV)-based canopy height modeling under leaf-on and leaf-off conditions for determining tree height and crown diameter (case study: Hyrcanian mixed forest). Online. *Canadian Journal of Forest Research*. 2021, roč. 51, č. 7, s. 962-971. ISSN 0045-5067. Dostupné z: <https://doi.org/10.1139/cjfr-2020-0125>.
- VAN TREESE II, Jeffery W.; KOESER, Andrew K.; FITZPATRICK, George E.; OLEXA, Michael T. a ALLEN, Ethan J. A review of the impact of roadway vegetation on drivers' health and well-being and the risks associated with single-vehicle crashes. Online. *Arboricultural Journal*. 2017, roč. 39, č. 3, s. 179-193. ISSN 0307-1375. Dostupné z: <https://doi.org/10.1080/03071375.2017.1374591>.

Předběžný termín obhajoby

2023/24 LS – FŽP

Vedoucí práce

Ing. Tomáš Klouček, Ph.D.

Garantující pracoviště

Katedra prostorových věd

Elektronicky schváleno dne 6. 3. 2024

prof. Ing. Petra Šimová, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 7. 3. 2024

prof. RNDr. Michael Komárek, Ph.D.

Děkan

V Praze dne 26. 03. 2024

Čestné prohlášení

Prohlašuji, že jsem diplomovou práci na téma: „Porovnání leaf-off a leaf-on UAV modelů vegetace v bezpečnostním monitoringu“ vypracovala samostatně a citovala jsem všechny informační zdroje, které jsem v práci použila a které jsem rovněž uvedla na konci práce v seznamu použitých informačních zdrojů.

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

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

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

V dne
(podpis autora práce)

Poděkování

Ráda bych poděkovala svému vedoucímu práce Ing. Tomáši Kloučkovi, Ph.D. za trpělivé a laskavé vedení při zpracování diplomové práce a své rodině a příteli za podporu během celého studia. Také bych chtěla poděkovat Kristýně Štěpánové za pomoc při sběru dat do této diplomové práce.

Porovnání leaf-off a leaf-on UAV modelů vegetace v bezpečnostním monitoringu

Abstrakt

Diplomová práce se zaměřuje na porovnání výškové přesnosti leaf-on (vegetační období) a leaf-off (mimo vegetační období) modelů vegetace vytvořených na základě dat pořízených UAV (angl. unmanned aerial vehicles) senzory. Mezi dílčí cíle práce patří zjištění přesnosti leaf-on a leaf-off modelů vegetace při určování výšek stromů a jak se přesnost těchto modelů liší v porovnání s terénním měřením. Dále se diplomová práce zaměřuje na otázku, zda existují rozdíly výškové přesnosti modelů pro jednotlivé druhy stromů a zda kombinace leaf-on digitálního modelu povrchu (DSM) a leaf-off digitálního modelu terénu (DTM) přináší zvýšení přesnosti. Součástí je také monitoring zdravotního stavu vegetace podél dopravní infrastruktury pomocí spektrálních indexů Normalized Difference Vegetation Index (NDVI) a Normalized Difference Red Edge Index (NDRE) a vyhodnocení vhodnosti využití těchto indexů pro monitoring stavu vegetace. Výzkum probíhal na třech lokalitách reprezentujících tři rozdílné typy porostu (listnatý, jehličnatý a smíšený) pomocí terénního měření a náletu oblastí bezpilotními prostředky. Z canopy height modelů (CHM) byla následně extrahována a porovnána výška jednotlivých stromů s referenčním měřením pomocí lineární regrese, mean absolute erroru (MAE) a root mean square erroru (RMSE). Nejlepších výsledků v průměru dosahoval leaf-on model, který se zdá být vhodný pro odhadování výšky jak u listnatého typu lesa, tak jehličnatého. Výsledky leaf-off modelu ukazují, že je nevhodný pro odhad výšky listnatých stromů, ale naopak je přínosný pro analýzy jehličnatého typu porostu. Kombinace leaf-on a leaf-off modelů ve většině případů nepřinášela zlepšení výsledků, a to až na odhad výšky u smíšeného typu lesa a následně také u koeficientu determinace u dubu. Z výsledků práce je zřejmé, že lze pomocí UAV dat přesně odhadovat výšky vegetace a je možné je tak považovat za spolehlivou metodu, která má potenciál doplňovat, případně zcela nahrazovat pozemní měření. Dále diplomová práce prokazuje přínosnost vegetačních indexů spočtených z UAV multispektrálních snímků pro monitoring a odhad zdravotního stavu vegetace. NDRE se svými výsledky zdá být citlivější k drobnějším změnám zdravotního stavu vegetace, což může být užitečné pro včasné odhalení zhoršujícího se stavu vegetace.

Klíčová slova: normovaný digitální model povrchu, canopy height model, Structure from Motion, bodové mračno, MAE, RMSE

Comparison of leaf-off and leaf-on UAV-based vegetation models in safety monitoring

Abstract

This thesis focuses on the comparing the height accuracy of leaf-on (growing season) and leaf-off (non-growing season) vegetation models created from data acquired by unmanned aerial vehicles (UAV) sensors. The sub-objectives of the thesis include determining the accuracy of leaf-on and leaf-off vegetation models in determining tree heights and how the accuracy of these models differs compared to field measurements. Furthermore, the thesis focuses on whether there are differences in the height accuracy of the models for different tree species and whether the combination of leaf-on digital surface model (DSM) and leaf-off digital terrain model (DTM) brings an increase in accuracy. The thesis also includes monitoring vegetation health along transportation infrastructure using the Normalized Difference Vegetation Index (NDVI) and Normalized Difference Red Edge Index (NDRE) and evaluating the suitability of using these indices for vegetation health monitoring. The research was conducted at three sites representing a particular vegetation type (deciduous, coniferous and mixed) using field measurements and aerial surveys of the areas by UAV. The height of each tree was then extracted from the canopy height models (CHM) and compared to the reference measurement using linear regression, mean absolute error (MAE) and root mean square error (RMSE). On average, the best results were achieved by the leaf-on model, which seems to be suitable for estimating height in both deciduous and coniferous forest types. The results of the leaf-off model show that it is unsuitable for estimating the height of deciduous trees, but on the contrary it is beneficial for coniferous stand type analyses. The combination of the leaf-on and leaf-off models did not yield improved results in most cases, except for height estimation in mixed forest type and subsequently for the coefficient of determination in oak. From the results of this work it is clear that UAV data can be used to accurately estimate vegetation heights and can be considered as reliable method that has the potential to complement or completely replace ground-based measurements. Furthermore, the thesis demonstrates the usefulness of vegetation indices calculated from UAV multispectral imagery for monitoring vegetation health. NDRE with its results is more sensitive to minor changes in vegetation health, which can be useful for early detection of deteriorating vegetation condition.

Keywords: normalized digital surface model, canopy height model, Structure from Motion, point cloud, MAE, RMSE

Obsah

1	Úvod.....	12
2	Cíle práce.....	13
3	Literární rešerše.....	13
3.1	Bezpečnost dopravní infrastruktury	13
3.1.1	Vegetace podél dopravní infrastruktury	13
3.1.2	Ochranná pásma podél železničních tratí	14
3.1.3	Silniční ochranná pásma.....	15
3.2	Typy dat dálkového průzkumu Země (DPZ).....	15
3.3	Mapování vegetace pomocí DPZ	16
3.3.1	Vegetační indexy.....	17
3.4	Měření výšky stromů	19
3.4.1	Pozemní měření standardními lesnickými technikami	20
3.4.2	Měření pomocí metod DPZ.....	21
3.5	Statistické metody	22
3.5.1	Mean Absolute Error (MAE).....	22
3.5.2	Root Mean Squared Error (RMSE).....	22
3.5.3	Lineární regrese	23
3.6	Současný stav řešené problematiky	23
4	Charakteristika studijního území	26
4.1	Smíšený les.....	26
4.2	Opadavý listnatý les.....	27
4.3	Jehličnatý les.....	27
5	Metodika.....	28
5.1	Porovnání výškové přesnosti UAV modelů vegetace s referenčními daty.....	28
5.1.1	Pozemní měření výšky vegetace.....	28
5.1.2	Zpracování UAV dat.....	30
5.1.3	Statistické zpracování dat.....	33
5.2	Zhodnocení zdravotního stavu vegetace podél dopravní infrastruktury ...	34

5.2.1	Poloautomatická detekce stromů.....	35
5.2.2	Definování oblasti koruny stromu	36
5.2.3	Analýza zdravotního stavu vegetace pomocí spektrálních vegetačních indexů	37
6	Výsledky.....	39
6.1	Porovnání výškové přesnosti.....	39
6.1.1	Všechny stromy.....	39
6.1.2	Srovnání lokalit Loučeň, Veselka a Neratovice.....	41
6.1.3	Jehličnaté a listnaté druhy	43
6.1.4	Vybrané druhy stromů.....	46
6.2	Zhodnocení zdravotního stavu vegetace.....	48
7	Diskuse	50
8	Závěr a přínos práce.....	53
9	Přehled literatury a použitých zdrojů	55
10	Přílohy	60

Seznam obrázků

Obrázek 1: Ultrazvukový hypsometr Haglöf Vertex 5 (vlevo) s laserovým dálkoměrem Haglöf Laser Geo (vpravo) (https://1url.cz/iun4j , https://1url.cz/pun4d)	20
Obrázek 2: Lokality reprezentující zájmové území pro výzkum: Neratovice, Loučeň a Veselka, vlastní zpracování	26
Obrázek 3: Autorka práce při měření výšky stromů na zájmových lokalitách	28
Obrázek 4: Multispektrální leaf-on Ortomozaika z lokality Veselka v pravých barvách (vlevo) a nepravých barvách (vpravo), vlastní zpracování.....	31
Obrázek 5: Hydrologické funkce použité v algoritmu pro detekci vrcholku stromů (A): Flow Accumulation, (B): Flow Direction (https://1url.cz/Aun4h)	35
Obrázek 6: Rastr NDVI pro jednotlivé koruny stromů, které vznikly na základě poloautomatických algoritmů, vlastní zpracování.....	38
Obrázek 7: Průměrné hodnoty NDVI pro jednotlivé koruny stromů, lokalita Neratovice, vlastní zpracování.....	49
Obrázek 8: Průměrné hodnoty NDRE pro jednotlivé koruny stromů, lokalita Neratovice, vlastní zpracování.....	49

Seznam tabulek

Tabulka 1: Datum pořízení dat pro jednotlivé lokality	30
Tabulka 2: Statistické vyhodnocení modelů vegetace pro všechny stromy	39
Tabulka 3: Statistické vyhodnocení modelů vegetace pro jednotlivé lokality	41
Tabulka 4: Statistické vyhodnocení modelů vegetace pro jehličnatý a listnatý typ porostu.....	43
Tabulka 5: Statistické vyhodnocení modelů vegetace pro jednotlivé druhy stromů .	46

Seznam grafů

Graf 1: Zobrazení lineární závislosti pomocí lineárního regresního modelu pro všechny stromy	40
Graf 2: Zobrazení lineární závislosti pomocí lineárního regresního modelu pro lokalitu Veselka	42
Graf 3: Zobrazení lineární závislosti pomocí lineárního regresního modelu pro lokalitu Loučeň (vlevo) a Neratovice (vpravo)	43
Graf 4: Zobrazení lineární závislosti pomocí lineárního regresního modelu pro jehličnaté druhy (vlevo) a listnaté druhy stromů (vpravo)	44
Graf 5: Zobrazení lineární závislosti pomocí lineárního regresního modelu pro borovici (vlevo) a smrk (vpravo).....	47
Graf 6: Zobrazení lineární závislosti pomocí lineárního regresního modelu pro dub (vlevo) a ostatní listnaté druhy stromů (vpravo)	48

Seznam příloh

Příloha 1: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro všechny stromy.....	60
Příloha 2: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro lokalitu Veselka.....	60
Příloha 3: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro lokalitu Loučeň.....	61
Příloha 4: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro lokalitu Neratovice	61
Příloha 5: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro jehličnaté druhy stromů	62
Příloha 6: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro listnaté druhy stromů	62

Příloha 7: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro smrk	63
Příloha 8: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro borovici.....	63
Příloha 9: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro ostatní listnaté druhy stromů	64
Příloha 10: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro dub	64

1 Úvod

Dálkový průzkum Země (DPZ) se stává velmi používanou a žádanou metodou pro pozorování jevů na Zemi ze vzduchu pomocí družic, letadel, či dronů. Aplikaci těchto dat lze velmi dobře využívat v mnoha oborech, mezi které patří například i lesnictví. DPZ lze využít jako nástroj k lesní inventarizaci, mapování i modelování různých parametrů lesních porostů (Surový, et al., 2019). Mezi možné využití dat DPZ v lesnictví lze zařadit například odhadování výšky vegetace pomocí modelů vytvořených na základě dat pořízených bezpilotními prostředky (UAV), které je v současnosti velmi aktuálním nejen výzkumným tématem. Z doposud publikovaných studií navíc zatím vyplývá značných, ale ne zatím zcela prokázaný, potenciál těchto dat, která by tak mohla doplnit, či v budoucnu zcela nahradit časově i finančně náročný pozemním terénním průzkum a měřením. Ni et al. (2019) navíc dokazují, že metody extrakce výšky lesního porostu pomocí vybraných metod UAV lze využívat nejen pro odhad samotné výšky, ale například i pro inventarizaci nadzemní biomasy lesů. Existuje již celá řada studií zaměřených na hodnocení leaf-on a leaf-off modelů vegetace, avšak málokdy je jejich výzkum zaměřen na kombinaci těchto dvou modelů (vytvořených v různých částech vegetačního období), která by potencionálně mohla zvyšovat přesnost odhadu výšky stromů.

Další možnou aplikací DPZ dat je opakovaný monitoring zdravotního stavu vegetace, který je důležité nejen pro lesní porosty, ale například i pro vegetaci nalézající se podél dopravní infrastruktury. Takový monitoring může sloužit jako prevence před dopravními nehodami vznikajícími vlivy popadaných stromů na silnice, dálnice, či železnice. K monitoringu jednotlivých stromů se nabízí využití dat s velmi vysokým prostorovým rozlišením z bezpilotních prostředků či letadel, na kterých lze následně za využití vybraných algoritmů detekovat vrcholky a koruny stromů a následně pomocí spektrálních vegetačních indexů vyhodnocovat jejich zdravotní stav.

Diplomová práce se, na příkladu tří zájmových lokalit, zabývá porovnáním výškové přesnosti leaf-on a leaf-off canopy height modelů a monitoringem zdravotního stavu vegetace nacházející se podél liniové dopravní infrastruktury, a to pomocí dat pořízených UAV senzory. Hlavním cílem výzkumu je zjistit, zda se od sebe liší výšková přesnost jednotlivých UAV modelů vegetace v porovnání s výškou stromů zjištěnou přesným terénním pozemním měřením. Je zkoumána jak přesnost mezi jednotlivými typy porostu, jako je jehličnatý, listnatý a smíšený les, tak i mezi vybranými druhy stromů. Jednou z nejdůležitějších výzkumných otázek práce je, zda kombinace leaf-on a leaf-off modelů přináší zlepšení odhadu výšky stromů. Mimo

studiu výškové přesnosti je diplomová práce dále zaměřená na hodnocení zdravotního stavu vegetace podél dopravní infrastruktury pomocí spektrálních indexů Normalized Difference Vegetation Index (NDVI) a Normalized Difference Red Edge Index (NDRE).

2 Cíle práce

Hlavním cílem diplomové práce je porovnat výškovou přesnost modelů vegetace (leaf-off a leaf-on) vypočtených na základě dat pořízených UAV senzory. Dalším cílem je zhodnocení zdravotního stavu vegetace podél dopravní infrastruktury pomocí vybraných spektrálních indexů. Dílčím cílem práce se zodpovězení níže uvedených výzkumných otázek: (a) Liší se přesnost leaf-on a leaf-off UAV modelů vegetace při určování výšek stromů?; (b) Jaká je přesnost leaf-on a leaf-off UAV modelů vegetace v porovnání s pozemním měřením výšek stromů?; (c) Existují u leaf-on a leaf-off UAV modelů rozdíly výškové přesnosti pro jednotlivé druhy stromů?; (d) Zvýší výškovou přesnost modelu vegetace kombinace leaf-on DSM a leaf-off DTM?; (e) Jsou spektrální indexy odvozené z UAV dat vhodné k monitoringu zdravotního stavu vegetace a mohou tak být využity v úlohách zaměřených na bezpečnost dopravní infrastruktury?

3 Literární rešerše

3.1 Bezpečnost dopravní infrastruktury

3.1.1 Vegetace podél dopravní infrastruktury

Vegetaci podél dopravní infrastruktury, například silnic, dálnic a železnic, lze označit jako silniční vegetaci. Jedná se o termín, který je přímo definovaný zákonem o pozemních komunikacích (Zákon č. 13/1997 Sb., o pozemních komunikacích, § 15). Tato vegetace má mnoho kladných funkcí, jako je poskytování útočiště živočichům žijícím blízko dopravní infrastruktury a obecně vytváří specifické habitaty a mikroklima pro živočichy. Dále zlepšuje podmínky životního prostředí svojí estetickou funkcí, schopností snižovat hluk dopravních prostředků, nebo slouží jako ochrana před navátým sněhem. Důležitou funkcí je také odstínění ostrého slunečního svitu, které oslňuje řidiče a zvyšuje riziko dopravních nehod. Vysoká hustá vegetace napomáhá tlumit ostrý světelný svit a tím zajišťovat bezpečnější podmínky pro řidiče (Kocur-Bera et Dudzinska, 2015).

Dalším faktorem pozitivního vlivu vegetace je ochrana proti větru, který řady stromů nebo keřů pomáhají výrazně regulovat. Druhové složení a typ vegetace velmi ovlivňuje sílu, rychlost a směr bočního větru, který má negativní vliv na dopravu. Dále

také brání navátí prachu, sněhu a ledu (Kocur-Bera et Dudzinska, 2015). Silniční vegetace může mít také například schopnost snižovat stres řidičů (Van Treese II et al., 2017), a v podobě menších keřů má také schopnost tlumit nárazy do objektů podél infrastruktury, jako jsou například informační tabule a sloupy. Umístění jednoho až čtyř keřů před rizikové objekty částečně pohlcuje sílu nárazu automobilu do objektu (Kocur-Bera & Dudzinska, 2015).

Přítomnost vegetace podél dopravní infrastruktury může mít ale i negativní vliv na dopravu. Kvůli tomuto vlivu může nastávat více dopravních nehod jednotlivých vozidel. Hlavním rizikem stromů podél dopravní infrastruktury je samotný pád stromu a jeho následné zasažení vozidla, případně naražení vozidla do spadlého stromu. Stromy však představují další riziko, čímž je jejich přílišná blízkost k vozovce. To může mít za následek špatný výhled motoristy na protijedoucí vozidla či značky (Van Treese II et al., 2017).

Dalším negativním faktorem může být nevhodné druhové složení vegetace, které v kombinaci se silným větrem/pokrývkou sněhu mnohdy zapříčiní pád stromů na vozovku/železnici. Smrkové monokultury, které byly v minulosti intenzivně sázeny, mohou mít velmi nízkou odolnost vůči těmto vlivům (Kučera et Dobesova, 2021). Tato vegetace dále přitahuje přítomnost velkých zvířat, což může mít za následek vběhnutí těchto zvířat do silnice a následnou dopravní nehodu (Rea, 2003).

Dopravní infrastruktura a živočichové

Přítomnost vegetace podél silnic a železnic sice poskytuje vhodné životní podmínky pro živočichy, ale přítomnost zejména savců u dopravní infrastruktury má za následek zvýšený počet dopravních nehod právě s těmito tvory. Úmrtnost savců kvůli srážkám s vlakem může mít na populace savců významný dopad, zejména pro již ohrožené druhy, nebo druhy s velkým areálem výskytu a nízkou populační hustotou, či pro druhy s nízkou mírou reprodukce (Borda-de-Água et al., 2017).

3.1.2 Ochranná pásma podél železničních tratí

Kolem dopravní infrastruktury se tvoří ochranná pásma, která slouží mimo jiné jako ochrana železničních tratí před stromy, které rostou podél železnic. Podle drážního zákona (Zákon č. 266/1994 Sb., o dráhách, § 8) jsou takové stromy obecně nebezpečné, konkrétně zmiňuje, že „stromoví a jiné porosty, které při svém pádu mohou zasáhnout do průjezdného průřezu dráhy, jsou stromovím ohrožujícím bezpečnost nebo plynulost drážní dopravy nebo provozuschopnost dráhy“. Zákon č. 266/1994 Sb. o dráhách požaduje velikost ochranného pásma 60 metrů kolem

regionálních drah, které dosahuje od osy okraje dráhy a minimálně 30 metrů od hranice obvodní dráhy (Zákon č. 266/1994 Sb., o dráhách, § 8).

Tato ochranná pásma ale nejsou vždy striktně dodržována z mnoha důvodů. Může se jednat o složitý terén, ve kterém je náročné se o tato ochranná pásma starat, nebo z důvodu vlastnických podmínek, které údržbu neumožňují. Kvůli spadlým stromům dojde ročně na trati průměrně k sedmdesáti srážkám s vlakem. Tyto nehody kvůli spadlým stromům mají za následek obrovské škody, které například v roce 2016 činily škodu 5,6 milionu korun (Kučera et Dobesova, 2021). Mezi lety 2012 až 2015 na českou železniční síť popadalo více než 2000 stromů, které v mnoha případech na železniční dráhy popadaly v důsledku extrémních povětrnostních situací. V tomto období bylo také zaznamenáno 12 vykolejení vlaků, které vzniklo v důsledku pádu stromů na dráhu (Bíl et al., 2017). Škody vycházející ze srážky vlaku se stromem mohou vznikat i na základě větrných přírodních katastrof, konkrétně v roce 2017 vznikly majetkové škody až 6,6 milionu korun v důsledku cyklonu Herwart, kdy došlo k 80 srážkám vlaků s popadanými stromy (Kučera et Dobesova, 2021).

3.1.3 Silniční ochranná pásma

Důležitou součástí jsou také silniční ochranná pásma, která jsou přímo definovaná zákonem č. 13/1997 Sb., o pozemních komunikacích, která slouží k ochraně dálnic, silnic a místních komunikací I. nebo II. třídy a provozu na nich. Tato silniční ochranná pásma se ale nevztahují na zastavěné území v obcích. Podle zákona se těmito ochrannými pásmy rozumí prostor, který je ohraničený svislými plochami vedenými do výšky 50 m a ve vzdálenosti lišící se podle typu provozní plochy, kde se podle vzdálenosti rozlišuje dálnice; silnice I. třídy nebo místní komunikace I. třídy; silnice II. třídy nebo III. třídy a místní komunikace II. třídy (Zákon č. 13/1997 Sb., o pozemních komunikacích, § 30).

3.2 Typy dat dálkového průzkumu Země (DPZ)

Dálkový průzkum Země lze definovat například podle NOAA (z angl. National Oceanic and Atmospheric Administration), kde uvádí, že: „DPZ je věda o získávání informací o objektech z určité vzdálenosti typicky z letadel a družic“. Jedná se o velmi širokou definici, která zahrnuje leteckou fotografii, družicovou altimetrii a laserové skenování (Kropáček et al., 2020). Data dálkového průzkumu Země (DPZ) lze získávat několika způsoby, mezi hlavní formy těchto dat patří obrazová data, která jsou reprezentována snímkem, který zobrazuje určitou oblast. Neobrazovou formou se rozumí například grafy, které byly sestaveny z různých typů měření. Zařízení schopná zaznamenávat intenzitu elektromagnetického záření lze umístit na několik typů nosičů (Lillesand et

al., c2008) jako jsou například družicové systémy, letadla, či bezpilotní prostředky (UAV, z angl. Unmanned Aerial Vehicle).

Data DPZ lze následně dělit například podle částí spektra, které jsou senzory schopny pořizovat. Jedná se o senzory, které zachycují pouze viditelnou část spektra (RGB – Red, Green, Blue), ale existují i multispektrální senzory, které umožňují snímat v řádu desítek pásem. Dalším typem senzorů podle spektrálního rozlišení jsou senzory hyperspektrální, které zachycují desítky až stovky pásem elektromagnetického spektra (Maletínská, 2022).

3.3 Mapování vegetace pomocí DPZ

Dálkový průzkum Země se podle mnoho výzkumů ukázal být velmi vhodným nástrojem pro mapování vegetace (Neyns et Canters, 2022). Podle výzkumů Shima et al. (1976), nebo Adam et al. (2010) byla jako první metoda v historii dálkového průzkumu pro mapování vegetace využita letecká fotografie. Z těchto studií vychází, že nejužitečnější metodou pro mapování vegetace je zejména díky své minimální mapovací jednotce (MMU) právě zmíněná letecká fotografie (Govender et al., 2019). Ale v současnosti s rozvojem v oblasti družic a bezpilotních prostředků se stále více začínají prosazovat právě přístupy pro mapování vegetace a její klasifikaci. DPZ může nahradit v úlohách zaměřených na mapování a monitoring vegetace časově a finančně náročný terénní průzkum a automatické vyhodnocení DPZ dat může nahradit vizuální interpretaci dat, která je také časově a finančně náročná (Govender et al., 2019).

Využití letecké fotografie pro mapování vegetace ale není velmi vhodné v regionálním měřítku nebo dlouhodobém monitoringu, protože letecká fotografie je pro takový monitoring vyžadující průběžné ověřování informací nákladná a časově náročná (Adam et al., 2010). V takových úlohách naopak vyniká družicový DPZ, který nabízí řadu produktů s různým prostorovým, spektrálním i časovým rozlišením (Kropáček et al., 2020). Zejména z pohledu spektrálního rozlišení pro mapování vegetace existuje řada snímků pořízených pomocí metod DPZ, které mají charakter jak RGB, tak multispektrálních, nebo hyperspektrálních dat s různým prostorovým rozlišením, které může být například v řádu jednotek centimetrů až několika kilometrů. Časová frekvence pro taková data je velmi různorodá, pohybuje se od desítek minut po týdny či měsíce, a to vždy s ohledem na použitou DPZ platformu (Adam et al., 2010).

Využitím multispektrálních technologií lze v rámci jednoho pozorování shromáždit data do několika spektrálních pásem, které reprezentují viditelné a blízké infračervené části elektromagnetického spektra (Kropáček et al., 2020). Naopak hyperspektrální

senzory jsou oproti multispektrálním schopny snímat ve více jak stovkách spektrálních pásmech zejména z následujících částí elektromagnetického spektra: viditelné, blízké infračervené, střední infračervené a krátkovlnné infračervené (Horák, 2014), což umožňuje tvorbu téměř souvislé spektrální odrazové signatury (tzv. spektrální křivky odrazivosti). Díky úzké šířce těchto pásem je navíc možné zkoumat vlastnosti zemského povrchu, které by jinak byly ztraceny v relativně širokém spektrálním pásmu (Govender et al., 2019).

Velmi důležitou součástí pro analýzu vegetace pomocí dat DPZ je canopy height model (CHM). Jedná se o velmi užitečný produkt, který lze využít k určení výšky jednotlivých objektů na zemském povrchu, jako například stromů, budov a ostatních staveb. Lze ho využívat především v lesnictví, kde může spolehlivě sledovat výšku vegetace a odhadovat množství biomasy (Lisein et al., 2013).

Jeho výpočet je poměrně jednoduchý, CHM lze vytvořit odečtením digitálního modelu terénu od digitálního modelu povrchu (Balenić et al., 2017). Tento produkt lze vytvořit jak pomocí lidarových dat, tak i pomocí optických UAV prostředků.

3.3.1 Vegetační indexy

Vegetační indexy jsou spektrální indexy tvořené z dat DPZ uzpůsobené pro studium vegetace, které vychází z kombinace několika pásem. Na základě způsobů výpočtu je možné vegetační indexy rozdělit na rozdílové, poměrové a ortogonální (Huete, 1988). Vegetační indexy tak umožňují zkoumání vegetace a jejich vlastností pomocí pasivních senzorů pořizujících data především v optické části elektromagnetického spektra (Broge et Leblanc, 2001). V dnešní době existuje mnoho spektrálních vegetačních indexů, které jsou velmi vhodné pro monitoring stavu vegetace. Mezi často používané a poměrně jednoduché indexy patří například Normalized Difference Vegetation Index (NDVI), Normalized Difference Water index (NDWI), Moisture Stress Index (MSI) a jiné (Maletínská, 2022).

Normalizovaný diferenciální vegetační index (NDVI)

Normalizovaný diferenciální vegetační index (NDVI) je velmi používaný vegetační index, který je pro dálkový průzkum Země velmi užitečný a lze ho univerzálně použít v mnoha různých oborech (Moravec et al., 2021). Tímto indexem je možné zobrazovat množství biomasy, která je zelená a je také vhodný pro monitoring zdravotního stavu vegetace nebo obsahu chlorofylu. Také ho lze využít pro charakteristiku růstu korun stromů (Xue et Su, 2017). Jedná se o normalizovaný poměr dvou pásem, konkrétně o poměr mezi červeným pásmem (RED) a blízkým

infračerveným (NIR), výpočet NDVI udává Rovnice 1. Rozsah jeho výsledných hodnot je -1 až 1 (Maletínská, 2022).

Rovnice 1: Výpočet normalizovaného diferenciálního vegetačního indexu (NDVI)

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$$

Moisture Stress Index (MSI)

Moisture Stress Index (MSI) je spektrální vegetační index měřící odrazivost, která reaguje na vzrůst obsahu vody v listech měřené vegetace a analýza tohoto indexu se především zaměřuje na stres vegetace (Welikhe et al., 2017). Na rozdíl od jiných spektrálních indexů (například NDVI) mají jeho hodnoty inverzní charakter, tedy že vyšší hodnota vycházející z tohoto indexu indikuje větší stres vegetace. Limitní výsledné hodnoty jsou v rozsahu od 0 do 3 (Maletínská, 2022). Vzorec pro výpočet MSI ukazuje Rovnice 2.

Rovnice 2: Výpočet moisture stress indexu (MSI)

$$MSI = \frac{(SWIR)}{(NIR)}$$

Normalized Difference Red Edge Index (NDRE)

Normalizovaný diferenciální Red Edge index využívá rozdíly v odrazivosti mezi Red Edge (RE) a blízkým infračerveným pásmem (NIR) ke zjišťování hustoty vegetace a jiných parametrů, jako je například obsah chlorofylu (Broge et Leblanc, 2001). Výpočet tohoto indexu zobrazuje Rovnice 3. Vzhledem k rozdílné odrazivosti světla různých vlnových délek rostlinami se NDRE a podobné vegetační indexy využívají k zjišťování růstu a vývoje plodin (63). Nejlepší doba pro využití tohoto indexu je polovina až konec vegetačního období, kdy jsou plodiny zralé a připravené ke sklizni. V tomto okamžiku je využití NDRE indexu účinnější než v případě jiných vegetačních indexů. Stejně jako NDVI dosahuje hodnot od -1 do 1, kdy hodnoty vyšší než 0,6 poukazují na zdravou vegetaci a zralé a dozrávající plodiny (EOS Data Analytics, 2024).

Rovnice 3: Výpočet normalizovaného diferenciálního Red Edge indexu (NDRE)

$$NDRE = \frac{(NIR - Red\ Edge)}{(NIR + Red\ Edge)}$$

3.4 Měření výšky stromů

Jednou z nejdůležitějších charakteristik lesního porostu pro praktické či vědecké využití je výška stromů. Přesnost této charakteristiky se ale může lišit v závislosti na mnoha faktorech (Stereńczak et al., 2019). Podle (Schreuder et al., 1993) je celková výška stromu definována jako vertikální vzdálenost od úrovně země až k jeho nejvyššímu bodu. Výška stromů patří mezi klíčový funkční znak, který je ovlivňován reakcemi na různé environmentální faktory a může mít potenciální vliv na vlastnosti ekosystému (Cornelissen et al., 2003). Jedná se o hlavní faktor, který jedincům určuje schopnost soutěžit o světlo. Výška jedinců přináší značnou výhodu ve formě přístupu ke světlu a jeho potenciálnímu zachycení. Světlo je jedním z nejdůležitějších abiotických zdrojů ovlivňující vývoj a růst stromů (Stereńczak et al., 2019). Výška stromu tedy ukazuje jeho postavení v populaci, čímž je velmi užitečná pro předpovídání vývoje porostu a sukcese (Purves et Pacala, 2008).

Výška stromů je také velmi důležitým ukazatelem, který je nejčastěji používán při hodnocení produktivity daných stanovišť nejen pro výzkum ekologie lesa, ale hlavně v lesním hospodářství. Například lesnická inventarizace, která se zabývá objemem porostu, biomasou a uhlíku, vyžaduje pro odhad objemu kmene výšku stromu a změřenou tloušťku v prsní výšce (DBH, z angl. Diameter at Breast Height) (Stereńczak et al., 2019). Měření výšky stromů je komplikovaná a časově náročná činnost, navíc výsledky naměřených výšek stromů se mohou velmi lišit v souvislosti s použitými přístroji a technikami (Pariyar et Mandal, 2019). Získané informace z inventarizace lesů jsou velmi důležité pro lesní hospodářství. Pro trvale udržitelné hospodaření v lesích je navíc třeba více informací, které jsou důležité nejen pro plánování budoucích způsobů hospodaření v lesích, ale také pro evidenci předchozího stavu lesních porostů (Koch et al., 2006). Informace o lesích jsou na úrovni jednotlivých stromů zásadní a nezbytné pro lesnické aplikace, jako je inventarizace lesů, hodnocení poškození lesů a sledování obnovy lesa. Takové informace, jako je například počet stromů, jejich výška a výška základny koruny, průměr v prsní výšce a lesní biomasa jsou zásadní pro efektivní správu a kvantitativní analýzu lesů (Kwak et al., 2017).

V dnešní době se tak nabízí využití dvou metodicky odlišných přístupů, a to pozemního měření přímo v terénu, anebo využití metod DPZ. V posledních letech se pro odhad výšky stromů a hustoty korunového patra lesních porostů používají snímky z bezpilotních letadel (UAV) a LiDAR (z angl. Light Detection And Ranging) (Jin et al., 2020).

3.4.1 Pozemní měření standardními lesnickými technikami

Pozemní měření probíhá pomocí nepřímých metod přímo v terénu a je již víceméně standardem pro řadu ekologických studií či při praktické inventarizaci lesních porostů. Měřit lze například pomocí ručního klinometru, který může mít podobu buď analogového klinometru, nebo laserovém dálkoměru (Stereńczak et al., 2019). Odhady výšky stromů za použití ručního klinometru jsou ale zatíženy chybami měření, které jsou způsobeny například následujícími faktory: struktura lesa a stromů, druh stromu, výška stromu, topografie, měřicí vzdálenost, chyby přístroje a lidského faktoru. I přes tyto negativní faktory je ale terénní měření výšek stromů za použití vyškolených terénních pracovníků považováno za nejpřesnější dostupný odhad výšky stromů (Jurjević et al., 2020). Případně pro měření lze použít ultrazvukový hypsometr, který je spolu s laserovým dálkoměrem zobrazen na Obrázek 1. Pro měření jsou využity trigonometrické principy založené na měření vertikálních úhlů, konkrétně se jedná o úhly pro základnu stromu, vrchol a vzdálenost ke stromu (Stereńczak et al., 2019). Je to tangenciální metoda, u které je uváděna malá systematická chyba a vysoká náhodná chyba (Jurjević et al., 2020).



Obrázek 1: Ultrazvukový hypsometr Haglöh Vertex 5 (vlevo) s laserovým dálkoměrem Haglöh Laser Geo (vpravo) (<https://1url.cz/iun4j>, <https://1url.cz/pun4d>)

Měření pomocí elektronických zařízení, jako je laserový dálkoměr a ultrazvukový hypsometr, je považováno za technologicky sofistikované a pokročilé vzhledem k použitým technologiím. Ultrazvukové přístroje patří mezi snadno použitelné a schopné nabídnout přesné, precizní a rychlé měření (Mielcarek et al., 2020).

Hypsometr má tu výhodu, že je možné s ním měřit v hustých porostech, kde se vyskytuje i křovinatý podrost. Při použití ultrazvukových technologií pro měření stromů nepředstavuje nedostatečný rozhled na patu a vrchol stromu velký problém, což dává těmto metodám velkou výhodu. Některé výzkumy ukazují, že při měření solitérních

stromů za specifických podmínek (jasný výhled do koruny) použití ultrazvukových přístrojů přináší velmi přesné měření, jehož chyby jsou okolo 0,2-0,3 metru (Stereńczak et al., 2019).

3.4.2 Měření pomocí metod DPZ

Vedle pozemního měření běžnými lesnickými technikami lze výšky stromů měřit pomocí metod dálkového průzkumu Země. V současné době se vede mnoho diskusí o tom, zda je měření výšek stromů pomocí pozemního měření v terénu dostatečně spolehlivé a jaký je rozdíl mezi pozemním měřením a měřením například pomocí bezpilotních prostředků osazených optickými senzory či pomocí leteckého laserového skenování (Jurjević et al., 2020).

Velmi často využívanou metodou dálkového průzkumu Země jsou lidarová data, která se v lesnictví využívají při inventarizaci výšek stromů. Velkou výhodou této metody je vysoká průchodnost laserových paprsků lesními korunami (Roşca et al., 2018). Data lze použít pro následnou tvorbu velmi přesného digitálního modelu terénu (DTM), a digitálního modelu povrchu (DSM). Odečtením DTM od DSM vzniká tzv. canopy height model (CHM), který reprezentuje v každém svém pixelu výšku koruny a její prostorové umístění (Jurjević et al., 2020).

Použití lidarových dat pořízených jak pomocí letecké (ALS, z angl. Airborne Laser Scanning), tak UAV (ULS, z angl. Unmanned Laser Scanning) laserového skenování je ale často omezeno vysokými pořizovacími náklady, a proto se čím dál častěji začíná používat CHM založených na přístupech stereoskopické snímkování využívajícího optických senzorů s vysokým prostorovým rozlišením. Tato metoda se v současnosti těší velké pozornosti zejména díky rozvoji bezpilotních prostředků a zpracovatelských metod jako je například Structure from Motion (SfM), které přináší oproti ALS/ULS velmi slibné nízkonákladové řešení (Goodbody et al., 2019). Získané mračno bodů ze stereoskopických snímků UAV je složeno z výšek korun stromů v lesním porostu a zemského povrchu, tyto dva parametry je pro změření výšky stromu potřeba oddělit, což je výrazně snazší u řídkých porostů s nízkým pokryvem a zapojením korun nebo v oblastech na rovinatém terénu. Současné studie prokazují, že v mladých lesních porostech je například mračno bodů vzniklé ze stereoskopických snímků srovnatelné s mračnem bodů z lidarů (Yu et al., 2023).

3.5 Statistické metody

3.5.1 Mean Absolute Error (MAE)

Jednou z velmi užitečných statistických metod pro hodnocení kvality modelů výšky vegetace je mean absolute error (MAE), která slouží pro určení aritmetického průměru absolutního rozdílu mezi předpokládanými a skutečnými hodnotami (Kulkarni et Rodd, 2020). V případě tohoto výzkumu byl porovnáván rozdíl mezi referenčními daty změřenými v terénu a odhadovanými parametry z UAV modelů.

Výpočet MAE znázorňuje Rovnice 4, která spočívá v tom, že se nejprve sečtou absolutní hodnoty chyb pro získání celkové chyby a tato hodnota se následně vydělí n , které představuje počet měření (Willmott et Matsuura, 2005).

Rovnice 4: Výpočet mean absolute erroru (MAE)

$$\text{MAE} = \frac{\sum_{i=1}^n |y_i - x_i|}{n}$$

3.5.2 Root Mean Squared Error (RMSE)

Root mean square error (RMSE) je ve statistice standardní metoda pro hodnocení přesnosti modelů. Jedná se o druhou odmocninou střední kvadratické chyby (mean squared error – MSE). Vzetí odmocniny nemá značný vliv na relativní pořadí modelů, ale vhodně tím představuje standardní chybu pro normálně rozdělené chyby (Hodson, 2022). Tato metoda má oproti MAE tu vlastnost, že znevýhodňuje velké chyby a nepopisuje pouze průměrnou chybu (Nasiri et al., 2021).

Vypočítat RMSE se skládá ze tří kroků. Nejprve je potřeba získat celkovou kvadratickou chybu, to znamená, že celková chyba je ovlivňována každou chybou úměrně svému čtverci, nikoliv své velikosti. Díky tomuto postupu mají velké chyby relativně větší vliv na celkovou kvadratickou chybu oproti menším chybám. Celková kvadratická chyba se následně vydělí n , čímž se získá střední kvadratická chyba a posledním krokem je stanovení RMSE jako odmocniny ze střední kvadratické chyby (Willmott et Matsuura, 2005). Tento postup znázorňuje Rovnice 5.

Rovnice 5: Výpočet root mean square erroru (RMSE)

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}}$$

3.5.3 Lineární regrese

Hlavním úkolem regresní analýzy je vystihnout průběh závislosti dvou proměnných pomocí regresní funkce na základě dvojic empirických hodnot x_i a y_i . To umožňuje odhadnutí hodnot závisle proměnné y na základě hodnot, které jsou zvolené pro nezávisle proměnnou x . Při určování regresních funkcí je nutné zvolit vhodný typ regresní funkce, který umí nejlépe vystihnout danou závislost. Pro regresní analýzu je zvolení vhodného typu regresní funkce klíčové, protože na základě správného výběru této funkce závisí úspěšnost provedeného regresního odhadu (Hindls, 2007).

Jednoduchá lineární regrese je nejjednodušší formou regrese, která předpokládá lineární závislost mezi dvěma veličinami. Jednou z veličin je nezávisle proměnná x , která by měla ovlivňovat druhou veličinu, konkrétně závisle proměnnou y . U těchto dvou veličin je předpoklad, že jsou spojitě. Pro ověření, zda mezi veličinami existuje závislost, se data vynášejí do bodového grafu, kde je zkoumáno, zda mezi nimi existuje závislost (regrese). Koeficient determinace dále popisuje míru kvality regresního modelu, díky kterému je možné zjistit, jak je závisle proměnná vysvětlena modelem (Lepš, Šmilauer, 2016).

3.6 Současný stav řešené problematiky

Pro odhad výšky stromů na základě dat z bezpilotních prostředků existuje několik výzkumů a článků, avšak jen minimum z nich se zaměřuje právě na kombinaci DSM leaf-on a DTM leaf-off, která by podle Moudrý et al., (2019) mohla mít potenciál nahradit nákladné LiDARové letecké snímkování pro aplikace, které vyžadují informace o výšce vegetace či vegetačním krytu. Kombinací těchto dat se ve své studii zabývají například Dietersberger et al. (2023), kteří se pomocí těchto datových produktů SfM (Structure from Motion) snažili přesně detekovat kmeny stromů a vymezit jejich koruny v hustých listnatých lesích. V tomto výzkumu extrahovali polohu kmene z leaf-off dat. Z jejich výsledků je zřejmé, že zahrnutí polohy z dat leaf-off mělo pozitivní vliv na zlepšení vymezení korun. Nicméně i přes tyto dílčí úspěchy zůstává nadále vymezení korun stromů v hustých lesních porostech nadále náročným úkolem. Z dosažených výsledků je navíc patrné, že opravdové množství kmenů a korun stromů bývá ve skutečnosti vyšší, než kolik je odhadováno z dat dálkového průzkumu Země. Na druhou stranu ale Dietersberger et al. (2023) uvádí, že kombinování leaf-on a leaf-off modelů poskytuje cenné poznatky o struktuře lesa, na jejichž základě je možné lépe pochopit koruny a kmeny stromů, lesní půdu a extrakci dalších parametrů lesa.

Dále se extrakcí výšky stromů z UAV dat zabývali například Hao et al. (2021), kteří ke svému výzkumu využívali zejména levné bezpilotní prostředky, pomocí kterých

následně tvořili digitální model povrchu (DSM), na kterém identifikovali jednotlivé stromy a následně odhadovali jejich výšku. Ve svém výzkumu dosáhli velmi kvalitních výsledků, koeficient determinace na úrovni jednotlivých stromů činí hodnotu 0,89 a RMSE 0,22 metru v porovnání s pozemním měřením. Na základě výsledků této studie je proto patrné, že monitoring parametrů lesa pomocí UAV má velký potenciál, a to jak při doplňování, tak možném úplném nahrazování terénní inventarizace.

Wang et al. (2019) porovnávali výšky stromů získané prostřednictvím konvenčního měření v terénu s výškami stromů získanými za použití nejnovějších technologií dálkového průzkumu Země, které reprezentovalo zejména pozemní laserové skenování (TLS, z angl. Terrestrial Laser Scanning) a UAV laserové skenování (ULS, z angl. Unmanned Laser Scanning). Tento výzkum probíhal v severských boreálních lesích a bylo zjištěno, že data z terénního měření často vykazují systematickou chybu, která nadhodnocuje výšky vysokých stromů. TLS vykazuje vyšší citlivost na složitost porostu, druhy stromů a třídy korun, ale má horší výsledky u nižších stromů v hustých porostech. Oproti tomu metoda ULS dosahuje věrohodných výsledků ve všech typech porostu. Zajímavým zjištěním je navíc fakt, že s výškou stromu se spolehlivost měření zvyšovala (Wang et al., 2019).

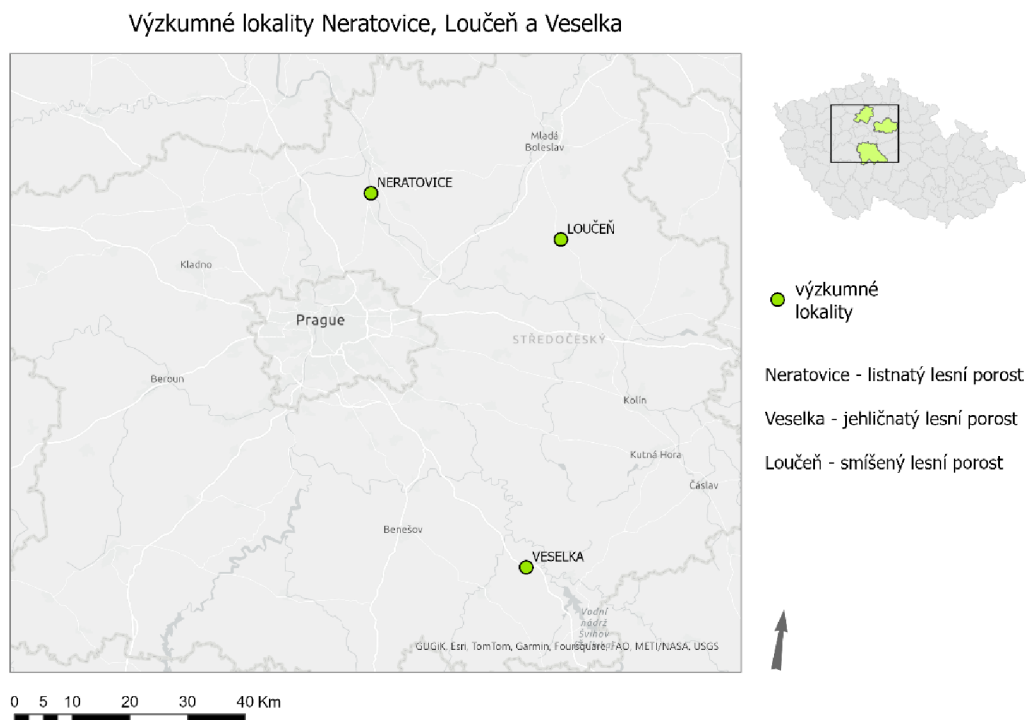
Mnohdy je jako informace o terénu využíván digitální model terénu z dat LiDAR, avšak ne tolik výzkumů se zaměřuje na využití pouze stereoskopických snímků pořízených bezpilotním letadlem pro získání výšky stromů (Yu et al., 2023). Náročným úkolem je odhad výšky stromů v horských oblastech se strmým terénem pouze za použití optických dat z bezpilotních prostředků. Na tuto problematiku se ve svém výzkumu zaměřili Yu et al. (2023), kteří vytvořili algoritmus AGAR (z angl. Approximation of Ground using Allometric Relationship), který je navržen pro odhad výšky jednotlivých viditelných stromů ze stereoskopických UAV snímků v horských přírodních lesích. Výzkum byl aplikován na pěti lokalitách s různými terénními podmínkami a jako reference byla použita data z terénního průzkumu a také data ICESat-2. Algoritmus byl porovnáván s klasickým algoritmem PTF (z angl. Progressive Triangulation Filter), který je citlivý na terénní nerovnosti a lesní struktury. Hodnocený algoritmus AGAR v porovnání s PTF přinesl významné snížení odchylky RMSE a relativní RMSE, díky čemuž je možné jeho využívat pro extrakci výšek stromů v oblastech s absencí přesných dat o výšce terénu.

Komárek et al. (2024) porovnávali přesnost CHM modelů vytvořených pouze z optických UAV dat v kombinaci s celostátními řídkými daty leteckého laserového skenování (angl. Airborne Laser Scanning; ALS) na šesti různých lokalitách. Byly zde

porovnávají UAV leaf-on a leaf-off modely a jejich kombinace, dále pak kombinace ALS DTM a UAV DSM pro leaf-on a leaf-off modely. Nejlepší přesnosti dosahoval UAV leaf-on model s MAE 1,77 metrů. V porovnání výškové přesnosti těchto modelů pro jehličnaté stromy měl opět nejlepší výsledky UAV leaf-on model, který činil MAE 1,84 metrů a pro jehličnaté druhy se jako nejlepší model jevil UAV leaf-off, který měl odchylku MAE 1,58 metrů. Z výzkumu vyplývá, že CHM založená na UAV mají samo o sobě velmi dobrou a dostatečnou přesnost, kterou nezvyšuje kombinace s daty ALS. Komárek et al. (2024) dále uvádí, že UAV leaf-on modely by mohly být dostatečné pro každodenní lesnickou praxi a mohly by v blízké budoucnosti nahrazovat časově náročné terénní měření. S tímto tvrzením souhlasí například i Nasiri et al. (2021), kteří považují CHM vytvořené z dat UAV za dostatečně věrohodný datový zdroj pro odhad výšek stromů a jejich průměrů korun pro lesnickou praxi.

4 Charakteristika studijního území

Výzkum v této diplomové práci se odehrával na třech typologicky odlišných zájmových lokalitách. Každá z lokalit reprezentovala určitý typ lesního porostu. Konkrétně se jedná o lokalitu Loučeň (smíšený les), Neratovice (opadavý listnatý les) a Veselka (jehličnatý les). Všechny zmíněné lokality se nachází na území Středočeského kraje. Umístění jednotlivých lokalit v rámci České republiky lze vidět na Obrázek 2.



Obrázek 2: Lokality reprezentující zájmové území pro výzkum: Neratovice, Loučeň a Veselka, vlastní zpracování

4.1 Smíšený les

Výzkumnou plochu pro smíšený les reprezentuje lokalita s názvem Loučeň, která se nachází u silnice vedoucí mezi obcemi Vlčava a Jizbice ve Středočeském kraji, okres Mladá Boleslav. Poblíž se nachází obec Loučeň, která leží na okraji Nymburského okresu. Vyskytuje se na naplaveninách řeky Jizery, kde Jizera dříve protékala směrem k Lysé nad Labem. Tento kraj lze svým původem řadit do druhohor do období křídly a úrodná rovina je tvořená podstatnou částí labské oblasti české křídové pánve, která je tvořena usazeninami několika moří sahajícími do doby před 120 miliony let (Loučeň, 2024).

Podle Ústavu pro hospodářskou úpravu lesů (ÚHUL) se jedná částečně o státní lesy Lesů České republiky a církevní lesy. Podle druhové skladby zde velmi často

dominantně borovice s příměsí dubu, jilmu, lípy, modřínu, smrku a jiných listnatých druhů. Pro referenční měření na této lokalitě bylo náhodně vybráno a změřeno celkem 18 stromů. Mezi vybranými druhy se nejčastěji vyskytoval dub a borovice a dále v menším množství bříza, osika a smrk.

4.2 Opadavý listnatý les

Opadavý listnatý les v této závěrečné práci reprezentuje lokalita s názvem Neratovice, která leží severně od stejnojmenného města. Oblast se nachází ve Středočeském kraji v Přírodní rezervaci Úpor – Černínovsko, která se rozkládá u soutoku Labe s Vltavou. Tato přírodní rezervace je charakteristická lužními komplexy a tvrdými luhy, kde dominuje dub letní. Nachází se zde také smíšené jasanovo-olšové lužní lesy, smíšené lužní lesy s dubem letním, kde lze také nalézt jilm vaz, jilm habrolistý, jasan ztepilý nebo jasan úzkolistý. Jedná se o velmi variabilní a rozsáhlé prostředí, které umožňuje výskyt biotopů s vlhkostními společenstvy, které nalézají svůj domov v nížinách horského až alpínského stupně a nivních loukách (Hubáčková, 2023).

Pro výzkum zde bylo v terénu náhodně změřeno 17 stromů, které byly dále porovnávány s měřeními odhadnutými z UAV dat. Jednalo se bez výjimky o listnaté druhy stromů, kde je nejčastěji zastoupen dub, dále olše, jasan, buk, bříza, jilm a kaštan.

4.3 Jehličnatý les

Poslední z výzkumných lokalit se nachází podél dálnice D1 severně od města Trhový Štěpánov v okrese Benešov, Středočeský kraj. Tato lokalita se nazývá Veselka a byla pro potřeby diplomové práce zvolena jednak z důvodu převažujícího zastoupení jehličnatých dřevin a dále pak z důvodu jejich zhoršeného zdravotního stavu způsobeného zejména působením kůrovcovitého hmyzu. Lokalita tak reprezentuje typickou dálnici, jejíž okolní vegetace a její zhoršený zdravotní stav může představovat zásadní riziko pro bezpečnost dopravy.

Na této lokalitě se nachází celkem 19 náhodně vybraných stromů, které byly změřeny pro referenční vrstvu. Jedná se primárně o jehličnaté druhy stromů, avšak nachází se zde i několik listnatých druhů. Nejčastějším druhem na této lokalitě je borovice, která činí 50 procent změřených stromů. Dále pak byly změřeny druhy stromů jako je smrk a modřín a z listnatých druhů habr a bříza.


5 Metodika

5.1 Porovnání výškové přesnosti UAV modelů vegetace s referenčními daty

5.1.1 Pozemní měření výšky vegetace

Na všech již výše zmíněných zájmových oblastech proběhlo vlastní důkladné pozemní měření výšky stromů pomocí postupu, při kterém byly použity dva běžné využívané laserové výškoměry. Konkrétně se jedná o japonský přístroj Laser Forestry Pro II od značky Nikon a dále o švédský Laser Geo od společnosti Haglöf.

V rámci každé studijní lokality bylo autorkou práce pečlivě změřeno 13-19 náhodně vybraných stromů, kdy každý strom byl změřen pětkrát oběma přístroji, hodnoty z výsledků měření byly ke každému stromu zapisovány. Takto zvolená metodika měření je zárukou věrohodných a spolehlivých výsledků, které jsou nezbytné pro vstup do dalších analýz a statistického porovnávání. Obrázek 3 znázorňuje autorku práce při poctivém měření výšky jednotlivých stromů na zájmových lokalitách.



Obrázek 3: Autorka práce při měření výšky stromů na zájmových lokalitách

Pro identifikaci polohy naměřených stromů byl v terénu použit GNSS přijímač Trimble R8s s kontrolní jednotkou TSC3. V rámci terénního měření byly navíc preferovány takové stromy, které byly snadno identifikovatelné z dostupné detailní ortofotomozaiky pořízeného v rámci předcházejícího mapování pracovníky Laboratoře GIS a DPZ (FŽP ČZU v Praze). Takto zvolený metodický postup navíc

sloužil pro kontrolu, zda polohy náhodně vybraných stromů opravdu odpovídají polohám stromů změřených přímo v terénu.

Naměřená data laserovým dálkoměrem spolu s dalšími informacemi získanými přímo v terénu pro každý zájmový strom obsahovala následující atributy: souřadnice, číslo bodu, druh stromu, název lokality, jednotlivá měření od každého z výškoměrů (celkem deset) a typ porostu. Z této tabulky následně vznikla bodová Shapefile vrstva, kdy každý strom byl znázorněn jedním bodem. Polohy stromů byly následně zkontrolovány a případně upraveny podle zákresů do ortofoto vzniklých přímo v terénu. Tato vrstva sloužila jako referenční měření pro následující zhodnocení výškové přesnosti UAV modelů vegetace, které je popsáno v následujících kapitolách. Referenční data pozemního měření byla pro všechny tři lokality pořízena řešitelkou diplomové práce v říjnu roku 2022.

5.1.2 Zpracování UAV dat

V rámci výzkumu pro porovnávání výškové přesnosti vegetačních modelů byla využita data z letových misí bezpilotních prostředků UAV. Byly uskutečněné mise ve dvou obdobích, a to ve vegetační sezóně pro získání leaf-on dat a dále mimo vegetační sezónu pro leaf-off data. Tabulka 1 zobrazuje datum, kdy byly mise uskutečněny. Surová UAV data byla pořízena v rámci projektu *Monitoring a vyhodnocení rizikových jevů v okolí dopravní infrastruktury s využitím DPZ* (CK02000203) podpořeného Technologickou agenturou ČR.

Tabulka 1: Datum pořízení dat pro jednotlivé lokality

Lokalita	Typ porostu	Pořízení leaf-on	Pořízení leaf-off
Loučeň	smíšený	20.07.2022	04.02.2022
Neratovice	listnatý	20.07.2022	04.02.2022
Veselka	jehličnatý	01.09.2022	24.10.2021


Výška letu pevného křídla senseFly eBee byla zhruba 100 metrů nad zemí s pravidelným 80% bočním a předním překryvem. Pro každou lokalitu bylo umístěno 8–14 vlíčovacích bodů, jejichž poloha byla přesně změřena pomocí GNSS přijímače R8s s kontrolní jednotkou TSC3. Vlícovací body byly měřeny v souřadnicovém systému S-JTSK/Krovak East North (EPSG: 5514) a výškovém systému Baltic 1977 height (EPSG: 5705).

Leaf-on data byla pořízena UAV pevným křídlem senseFly eBee X s multispektrální kamerou MicaSense RedEdge-MX. Tato kamera umožňuje snímání v pěti pásmech a kromě R, G a B snímá také v RedEdge a blízkém infračerveném (NIR) pásmu. Surová data nasnímaná z této mise byla následně zpracována autorkou práce v softwaru Pix4D Mapper, kde byly vytvořeny digitální modely terénu, povrchu a multispektrální ortomozaiky. Digitální modely dále vstoupily do výpočtů pro CHM a ortofoto posloužilo pro zhodnocení zdravotního stavu vegetace pomocí vybraných vegetačních indexů.

Období mimo vegetační sezónu (leaf-off) bylo snímáno taktéž UAV pevným křídlem senseFly eBee X, avšak s RGB kamerou Aeria X. Oproti leaf-on datům, které byly počínaje surovými daty kompletně zpracovávány autorkou práce, byly produkty z těchto dat (konkrétně ortofoto a digitální model povrchu a terénu) poskytnuty Katedrou prostorových věd (KPV) ČZU a posloužily pro další zpracování a analýzy. Z těchto dat byl dále autorkou práce vytvořen Canopy Height Model pro každou z lokalit reprezentujících zájmové území.

Ortomozaika

Pro každou z výzkumných lokalit vznikla ortomozaika, která je dostupná jak pro leaf-on, tak leaf-off období. Jak již bylo zmíněno v předešlé kapitole, oblasti v letním období, tedy leaf-on, byly snímány multispektrální kamerou, díky které je výsledná ortomozaika multispektrální (kromě R, G a B obsahuje také RedEdge a NIR pásma) a lze na ní zkoumat další parametry, jako je například zdravotní stav vegetace. Právě tento typ ortomozaiky vstupuje v dalších kapitolách do zhodnocení zdravotního stavu stromů podél dopravní infrastruktury. Pro leaf-off období je dostupná pouze RGB ortomozaika, která má ale na rozdíl od leaf-on lepší rozlišení, které činí cca 0,03 m. Oproti tomu multispektrální ortomozaika má rozlišení cca 0,1–0,2 m. Obrázek 4 zobrazuje multispektrální leaf-on ortomozaiku pro lokalitu Veselka v pravých barvách (vlevo) a nepravých barvách (vpravo), která byla autorkou práce vytvořena v software Pix4D Mapper.



Obrázek 4: Multispektrální leaf-on Ortomozaika z lokality Veselka v pravých barvách (vlevo) a nepravých barvách (vpravo), vlastní zpracování

Surová UAV data z letové mise vstoupila do software Pix4D Mapper, kde byla podrobena dalšímu zpracování, které spočívalo v několika klíčových krocích. Po importu snímků konkrétního území byly do software nainportovány také snímky kalibračního terče, který slouží pro radiometrickou kalibraci multispektrálních dat. Díky použití tohoto kalibračního terče může software korigovat a kalibrovat odrazivost jednotlivých snímků podle laboratorně změřených hodnot, které jsou uvedené v metadatech příslušného kalibračního terče.

Jedním z prvních kroků v softwaru Pix4D je počáteční zpracování dat, při kterém software nejprve vypočítá klíčové body na jednotlivých snímcích, které byly vybrány pro zpracování. Díky těmto klíčovým bodům je možné nalézt shody na jednotlivých

snímcích, díky kterým software provede automatickou leteckou triangulaci (AAT) a blokové vyrovnání svazků (BBA) (Pix4D Documentation, 2021).

Po počátečním zpracování dat byla do software naimportována tabulka obsahující informace o vlíčovacích bodech, jako je název bodů a jejich souřadnice (x , y , z), které mají souřadnicový systém S-JTSK/Krovak East North (EPSG: 5514) a výškový systém Baltic 1977 height (EPSG: 5705). Každý vlíčovací bod byl následně identifikován a označen na šesti až osmi snímcích.

Dalším krokem ve zpracování UAV dat je tvorba bodového mračna a 3D meshe, které jsou následně klíčové pro tvorbu dalších produktů, jako je digitální model povrchu/terénu a ortomozaiky. Tímto krokem je zvýšena hustota bodů ve 3D modelu, který byl vypočten v prvním kroku počátečního zpracování, a to vede k vyšší přesnosti ortomozaiky a digitálního modelu povrchu (Pix4D Documentation, 2021).

Posledním krokem je výpočet a tvorba výsledných produktů, jako je ortomozaika a digitální modely terénu a povrchu. Jelikož se jedná o zpracování multispektrálních dat, pro všechna jednotlivá pásma (R, G, B, RedEdge a NIR) byla vytvořena jejich vlastní ortomozaika, která byla následně pomocí software ArcGIS Pro sloučena do jedné. Informace o jednotlivých pásmech byly zachovány a ortomozaiku je možné zobrazovat jak v pravých, tak nepravých barvách.

Digitální model povrchu a terénu (DSM a DTM)

Dalšími a také velmi důležitými produkty pro výzkum v této práci je DSM a DTM, které stejně jako ortomozaika vznikly díky zpracování UAV dat v software Pix4D Mapper. Jedná se o digitální modely, které reprezentují buď vyfiltrovaný samotný terén, nebo celkový povrch zájmové oblasti obsahující informace o přesné výšce korun stromů. Digitální model povrchu a terénu jsou velmi důležité zejména kvůli tomu, že vstupují do výpočtu pro tvorbu canopy height modelu, který je popsán v následující kapitole.

Canopy height model (CHM)

Pro výzkum byly vytvořeny tři canopy height modely, konkrétně CHM pro leaf-on, dále pro leaf-off a posledním modelem byla jejich kombinace, pro kterou byl použit leaf-on DSM a leaf-off DTM. Tato kombinace se ve výzkumu jeví jako atraktivní možnost, protože by mohla mít pozitivní vliv na zpřesnění odhadu výšky stromů.

Rozlišení pro jednotlivé CHM se liší v závislosti na tom, zda vychází z leaf-on, nebo leaf-off dat. Jelikož leaf-on data jsou pořízena multispektrální kamerou s o něco horším rozlišením, mají horší rozlišení i výsledné CHM produkty, které je cca 0,2–

0,3 m. Oproti tomu leaf-off data byla nasnímána RGB kamerou s lepším rozlišením, výsledné CHM mají tedy také lepší rozlišení, které je cca 0,06–0,08 m. CHM vytvořený kombinací leaf-on a leaf-off má také horší rozlišení, jelikož vychází z leaf-on DSM, tudíž nese stejné rozlišení jako CHM pro leaf-on období.

Výšky stromů odhadnuté z těchto CHM dále vstoupily do statistických analýz, kde byly porovnávány s referenčními daty změřenými v terénu. Kolem každého bodu stromu změřeného v terénu byl v software ArcGIS Pro vytvořen buffer o velikosti 1,5 metru, ve kterém byl pomocí zonální statistiky nalezen pixel s nejvyšší hodnotou, který dále ve statistickém zpracování reprezentoval výšku stromu odhadnutou z daného CHM.

5.1.3 Statistické zpracování dat

Vyhodnocení výškové přesnosti pro data vycházející z UAV modelů je klíčové pro určení správnosti a vhodnosti metod, které byly pro zjišťování výšky stromů v této diplomové práci využity. Pro zjištění vztahu mezi daty změřenými v terénu a odhadovanými parametry z UAV dat byly použity celkem tři následující statistické metody: lineární regrese, mean absolute error (MAE) a root mean square error (RMSE). Kombinací těchto tří metod lze objektivně vyhodnotit kvalitu odhadovaných parametrů z UAV dat v porovnání s terénním měřením.

Statistické zhodnocení výškové přesnosti probíhalo na více úrovních. MAE, RMSE a lineární regrese byly vypočteny pro všechny stromy najednou, tedy že byly porovnávány nejlepší výsledky mezi daty z pozemního měření a leaf-on/leaf-off a jejich kombinace. Dále bylo statistické zhodnocení provedeno pro jednotlivé lokality, konkrétně lokalita Veselka (jehličnatý les), Loučeň (smíšený les) a Neratovice (listnatý les). Na těchto lokalitách bylo celkem hodnoceno 53 stromů, které byly napříč lokalitami početně poměrně rovnoměrně zastoupeny, každá lokalita obsahovala 17-19 stromů, které vstoupily do statistického zhodnocení.

Statistická analýza pro další úroveň obsahovala dvě kategorie ve formě jehličnatý/listnatý druh stromu, kdy do těchto dvou kategorií byly rozřazeny stromy ze všech lokalit. Celkem bylo hodnoceno 32 listnatých a 21 jehličnatých stromů.

Poslední úroveň je srovnání pro nejčastěji zastoupené druhy stromů, které se napříč lokalitami vyskytovaly. Konkrétně se jedná o čtyři kategorie: borovice (15 stromů), smrk (6 stromů), dub (17 stromů) a poslední kategorii zastupují všechny ostatní listnaté druhy, které se na lokalitách nevyskytovaly tak četně, aby mohly jednotlivě tvořit své vlastní kategorie (15 stromů).

Metoda MAE byla spočítána pro čtyři výše zmíněné úrovně, kdy u každé z nich bylo porovnáváno, který z canopy height modelů a výšek z něj odvozených (tedy leaf-on, leaf-off a jejich kombinace) má pro danou kategorii nejlepší výsledky. Výpočty MAE, stejně jako všechny následující statistické metody, byly vytvořeny v software RStudio. Metoda RMSE byla stejně jako MAE také spočítána pro čtyři výše zmíněné úrovně, kdy u každé z nich bylo porovnáváno, který z canopy height modelů a výšek z nich odvozených má pro danou kategorii nejlepší výsledky. Lineární regrese, stejně jako MAE a RMSE, byla vypočtena pro všechny čtyři úrovně, které v této diplomové práci vstupují do statistické analýzy.

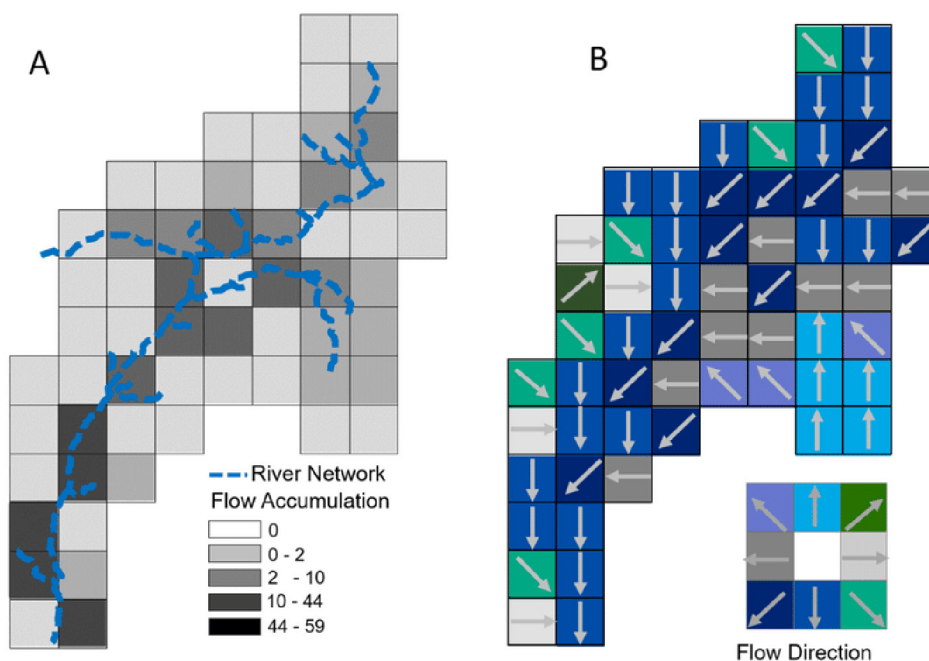
5.2 Zhodnocení zdravotního stavu vegetace podél dopravní infrastruktury

Další částí této diplomové práce je zhodnocení zdravotního stavu stromů, které se nachází v bezprostřední blízkosti dopravní infrastruktury, jako je dálnice a silnice s vysokým provozem. Monitoring zdravotního stavu vegetace na takto rizikových místech může mít zásadní vliv pro bezpečnost, protože včasné odhalení nezdravé vegetace může být klíčové pro minimalizaci dopravních nehod na základě popadaných stromů, větví a jejich jiných částí. Jedná se o poloautomatické procesy, které do budoucna mohou usnadňovat pravidelný monitoring této problematiky bez složitých a čistě manuálních postupů.

Toto zhodnocení se skládá z poloautomatické detekce jednotlivých stromů a dále vymezením korun stromů na základě výstupu z předchozí detekce. Z těchto výstupů pak vychází zhodnocení zdravotního stavu stromů pomocí vegetačních indexů. Postup detekce vrcholků a korun stromů je tvořen podle Certifikované metodiky (Komárek et al., 2024), jejíž spoluautorkou je i autorka této diplomové práce.

5.2.1 Poloautomatická detekce stromů

V prvním kroku analýzy zdravotního stavu vegetace bylo nutné nejprve pomocí bodů vymezit jednotlivé stromy, které sloužily jako vstupní data do dalších analýz. Tato poloautomatická detekce vrcholků stromů byla založena na vlastní konsekvenci vhodných nástrojů a funkcí hydrologických analýz v softwaru ArcGIS Pro.



Obrázek 5: Hydrologické funkce použité v algoritmu pro detekci vrcholku stromů (A): Flow Accumulation, (B): Flow Direction (<https://1url.cz/Aun4h>)

Vstupem do tohoto algoritmu je canopy height model, který lze vytvořit odečtením digitálního modelu terénu od digitálního modelu povrchu. Tato vrstva reprezentuje výšky objektů, které se v zájmové oblasti nachází, v tomto případě se jednalo o jednotlivé stromy a jejich vrcholky. Jelikož se jedná o analýzy hydrologického modelování, tento canopy height model byl nejprve invertován, tedy že místa, která měla být nejvyšší (jednotlivé vrcholky stromů) byla po této inverzi reprezentována nejhlubšími/nejnižšími místy v daném modelu. To je velmi důležité pro následující postup, protože dalším krokem je použití funkce flow direction, která určuje, jakým směrem tok proudí. To znamená, že směr toku směřuje k nejhlubšímu místu, tedy k místu, které by mělo reprezentovat vrchol koruny stromu. Na základě informace o tom, jakým směrem toky z pixelů proudí, je použita funkce flow accumulation, která udává, ve kterém pixelu se akumuluje nejvíce toků zároveň (počet pixelů, které do něj proudí). Pixely s nejvyšším počtem v rastru flow accumulation by měly reprezentovat jednotlivé vrcholky stromů, pixely s nižšími hodnotami okolo by dále měly

reprezentovat okolí koruny daného stromu. Princip použitých funkcí Flow Accumulation a Flow Direction zobrazuje Obrázek 5.

Doposud se jednalo o rastrové produkty, ale pro následující práci byly tyto produkty převedeny na vektorové vrstvy, aby bylo možné s nimi dále pracovat. Jednotlivé pixely z rastru reprezentující Flow accumulation byly převedeny na body, takže každý bod reprezentoval jeden pixel a nesl jeho hodnotu. Dále byl tento rastr převeden na polygonovou vrstvu, kdy jeden polygon reprezentuje jednu detekovanou korunu stromu. Tyto dvě vektorové vrstvy dále vstoupily do nástroje intersect, jehož výsledkem jsou body, které obsahují jak hodnotu Flow accumulation, tak informaci o daném stromu jako celku.

Dále bylo nutné najít bod, který v sobě nese nejvyšší hodnotu Flow accumulation, tedy hodnotu, která reprezentuje nejvyšší vrchol stromu. Toho bylo dosaženo pomocí funkce Summary Statistics. Všechny hodnoty, které z daných korun reprezentují nejvyšší vrchol stromu byly následně vyexportovány do nové a finální vrstvy, která už ve formě bodů reprezentuje jednotlivé vrcholky stromů.

5.2.2 Definování oblasti koruny stromu

Pro zhodnocení zdravotního stavu vegetace v bezprostřední blízkosti dopravní infrastruktury je nutné nejprve vymežit jednotlivé koruny stromů, které budou následně vstupovat do výpočtů. Tato vrstva korun stromů, která mimo jiné vstoupila jako prvotní vstup do tohoto algoritmu, byla vytvořena na základě výsledného produktu z předchozí kapitoly, tedy detekované vrcholky jednotlivých stromů. Stejně jako předchozí metoda i tento poloautomatický algoritmus pracuje s analýzami hydrologického modelování, jejichž vstupem je canopy height model v podobě rastru reprezentující vybranou zájmovou lokalitu. Tento postup, stejně jako v předešlé kapitole, vznikl podle postupů Certifikované metodiky (Komárek, et al., 2024).

První vrstva, která vstoupila do tohoto algoritmu je tedy vybraný canopy height model, který byl stejně jako v předchozím algoritmu pro detekci vrcholku stromů invertován – tedy že nejhlubší místa v invertovaném rastru reprezentují vrcholky korun stromů.

Další funkcí vstupující do výpočtu koruny stromu je Focal Flow, která identifikuje pixely, které mají nejvyšší hodnotu odtoku. Pro výpočet hodnot pixelů používá okno o velikosti 3x3 pixely, kdy uprostřed je pixel, jehož hodnota je aktuálně počítána. Pro výpočet hodnoty středové buňky je odečtena hodnota každé z vedlejších pixelů od pixelu, který je aktuálně zpracováván. Pokud do středového pixelu proudí všechny okolní pixely, středový pixel nese hodnotu 225.

Výstup z funkce Focal Flow vstupuje s produktem z funkce Flow direction (která je popsána v předchozí kapitole) do další funkce, která se nazývá Watershed. Výstupem z této funkce jsou po úpravě polygony, které tvoří „hranici povodí“, v tomto případě tedy oblasti jednotlivých korun stromů. Jelikož byly koruny vycházející z tohoto hydrologického nástroje rozděleny do několika menších oblastí, byly sjednoceny na základě toho, jak blízko se od nich vyskytuje vektorový bod reprezentující vrchol koruny stromu. Díky tomu vznikla vrstva, která má méně polygonů, tedy sjednocenější polygony lépe reprezentující jednotlivé koruny stromů. V poslední řadě byly odstraněny polygony reprezentující koruny stromů s nevhodnými rozměry, tedy že by byla oblast detekované koruny stromu příliš malá/velká.


5.2.3 Analýza zdravotního stavu vegetace pomocí spektrálních vegetačních indexů

Vektorová vrstva jednotlivých korun stromů detekovaných pomocí algoritmu z předchozí kapitoly dále vstoupila jako podklad reprezentující stromy do zhodnocení zdravotního stavu vegetace podél dopravní infrastruktury. Další důležitou součástí pro takovou analýzu byla multispektrální ortomozaika pořízená multispektrální UAV kamerou z leaf-on období, která obsahuje pásma vhodná pro tvorbu spektrálních vegetačních indexů. Za použití červeného a blízkého infračerveného pásma byl pro jednotlivé oblasti (Loučeň, Neratovice a Veselka) vypočten vegetační index NDVI v software ArcGIS Pro, který byl následně oříznut vektorovou vrstvou reprezentující koruny stromů. Každý detekovaný strom v podobě kruhů obsahuje informace o hodnotách NDVI, které udávají zdravotní stav jednotlivých stromů. Výsledný rastr reprezentující NDVI pro jednotlivé koruny stromů znázorňuje Obrázek 6. Dalším použitým spektrálním vegetačním indexem pro zhodnocení zdravotního stavu byl použit Normalized Difference Red Edge Index (NDRE), který byl stejně jako NDVI oříznut vektorovou vrstvou korun stromů.

Rastrové vrstvy reprezentující NDVI a NDRE velmi detailně zobrazují informace o zdravotním stavu jednotlivých stromů díky svému prostorovému rozlišení, které činí zhruba 1800 pixelů pro jednu korunu stromu. Z důvodu takto obsáhlých informací a dat bylo vytvořeno zjednodušení pro výsledné zhodnocení zdravotního stavu stromů v podobě tvorby jedné průměrné hodnoty NDVI a NDRE pro každý strom. Zprůměrování těchto dvou rastrových vrstev a extrakcí jejich hodnot k jednotlivým stromům bylo dosaženo v software RStudio pomocí funkce extract z balíčku terra. Ve vektorové vrstvě reprezentující koruny stromů byly vytvořeny dva nové sloupce pro průměrné hodnoty NDVI a NDRE, které byly pomocí výše zmíněné funkce extract naplněny průměrnými hodnotami odpovídajícího indexu. Tímto způsobem pak každý

strom obsahoval jednu hodnotu NDVI a NDRE, která reprezentuje průměr těchto indexů v dané oblasti koruny stromu.

Rastr reprezentující hodnoty NDVI pro jednotlivě detekované koruny stromů



Obrázek 6: Rastr NDVI pro jednotlivé koruny stromů, které vznikly na základě poloautomatických algoritmů, vlastní zpracování

6 Výsledky

6.1 Porovnání výškové přesnosti

V této kapitole jsou zobrazeny výsledky detailního porovnávání výškové přesnosti UAV modelů vegetace s referenčními daty. Do porovnání vstoupily čtyři úrovně, které jsou detailněji popsány v kapitole *Statistické zpracování dat*. Výsledky jednotlivých úrovní jsou rozepsány v následujících kapitolách.

Byly zde porovnávány metody leaf-on, leaf-off a jejich kombinace, která reprezentuje CHM vytvořený z leaf-on DSM a leaf-off DTM. Pro porovnání byly použity statistické metody MAE, RMSE a koeficient determinace.

6.1.1 Všechny stromy

Do nejméně specializovaného porovnání výškové přesnosti vstoupily všechny stromy z datasetu, které reprezentují jak jehličnaté, tak listnaté druhy stromů a objevují se na všech lokalitách.

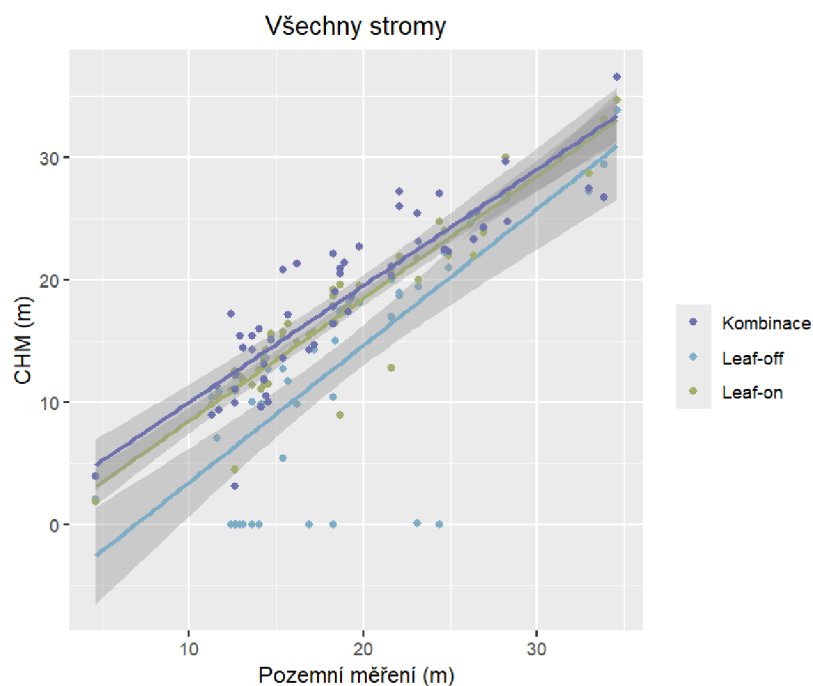
Tabulka 2: Statistické vyhodnocení modelů vegetace pro všechny stromy

		Leaf-on	Leaf-off	Kombinace
Všechny stromy	MAE (m)	1,76	5,53	2,51
	RMSE (m)	2,68	8,05	3,10
	R ²	0,89	0,59	0,79

Tabulka 2 zobrazuje statistické porovnání pro leaf-on, leaf-off a jejich kombinaci. Konkrétně se jedná o statistické metody MAE, RMSE a R², které mohou spolehlivě rozlišit odchylky v datech a přesnost výšek odhadovaných z UAV dat. Nejlepší výsledky má pro MAE, RMSE a R² jednoznačně leaf-on, která vykazuje nejmenší odchylky a nejvyšší koeficient determinace.

Nejhorší výsledky naopak vykazuje leaf-off, kdy je hodnota RMSE vyšší než 8, což je mnohonásobně horší než u zbylých dvou metod. MAE má zde také nejvyšší odchylku, která činí 5.53 m. Koeficient determinace (R²) má hodnotu z porovnávaných metod nejnižší hodnotu (0.59), tedy že míra kvality regresního modelu je oproti ostatním metodám nízká. Kombinace leaf-on a leaf-off zde nepřináší lepší výsledky než leaf-on, tudíž lze říci, že pro odhadování výšky pro kombinaci jehličnatých a listnatých druhů stromů z CHM není nutné kombinovat leaf-on DSM a leaf-off DTM, protože tato metoda výsledky nezpřesňuje.

Výsledky lze i vizuálně porovnat pomocí grafu lineární regrese, kde jsou v grafu 1 zobrazeny hodnocené modely leaf-on, leaf-off a jejich kombinace. Pro všechny stromy dohromady má slabší lineární závislost metoda leaf-off, u které lze vidět všechny stromy, které měly odhadnutou výšku 0, což značně zhoršuje přesnost této metody. Podle dalších výsledků lze určit, že se jedná primárně o listnaté druhy stromů, které pro tuto metodu očividně nebudou tak vhodné jako jehličnaté stromy. Detailnější informace o charakteru a rozmístění naměřených dat nabízí příloha 1.



Graf 1: Zobrazení lineární závislosti pomocí lineárního regresního modelu pro všechny stromy

6.1.2 Srovnání lokalit Loučeň, Veselka a Neratovice

Jednotlivé lokality zde primárně zastupují konkrétní typ lesního porostu, a právě díky tomu je vhodné je porovnávat mezi sebou, protože každá zájmová lokalita je svým typem porostu specifická. Byly porovnávány tři lokality, kdy každá z nich zastupuje buď listnatý, jehličnatý, nebo smíšený typ lesního porostu. Nutno podotknout, že na lokalitách se nevyskytují čistě jehličnaté/listnaté druhy, ale jedná se o jejich převážné zastoupení.

Tabulka 3: Statistické vyhodnocení modelů vegetace pro jednotlivé lokality

Lokalita		Leaf-on	Leaf-off	Kombinace
Veselka	MAE (m)	1,53	2,01	2,76
	RMSE (m)	1,99	2,45	3,61
	R ²	0,94	0,95	0,86
Loučeň	MAE (m)	2,29	5,83	2,09
	RMSE (m)	3,49	8,85	2,45
	R ²	0,53	-0,01	0,85
Neratovice	MAE (m)	1,46	9,16	2,67
	RMSE (m)	2,32	10,78	3,10
	R ²	0,89	0,33	0,83


V tabulce 2 je možné vidět nejlepší výsledky jednoznačně u leaf-on, ovšem v tabulce 3 nejsou výsledky tak jednoznačné. Pro listnatou lokalitu Neratovice vykazuje jednoznačně nejlepší výsledky leaf-on, naopak leaf-off model se kvůli velkým chybám zdá být pro odhadování výšek stromů zcela nevhodný a napříč lokalitami má nejvyšší chyby. Rozsahy a porovnání výšek pro jednotlivé modely s pozemním měřením pro lokalitu Neratovice lze vidět v příloze 4.

Lokalita Loučeň reprezentující smíšený lesní porost jako jediná vykazuje nejlepší výsledky a nejmenší chyby pro kombinaci DSM leaf-on a DTM leaf-off, ovšem výsledky pro leaf-on jsou jen nepatrně horší. Jelikož se jedná o smíšený porost, tak listnaté stromy pravděpodobně ztlačí zhoršují kvalitu leaf-off modelu, který se opět pro odhadování výšky stromů jeví jako nejméně vhodný. Detailnější informace o charakteru výšek stromů z lokality Loučeň nabízí příloha 3.

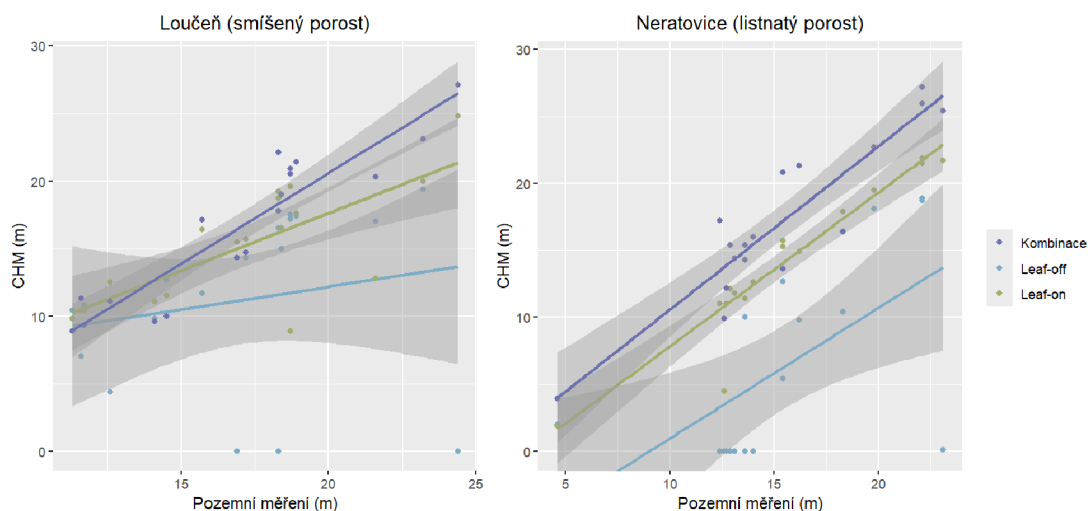
Jehličnatý les na lokalitě Veselka má ze všech lokalit pro všechny tři modely v průměru nejmenší odchylky odhadovaných výšek ve srovnání s referenčními daty. R kvadrát má dokonce nejlepší výsledky pro leaf-off a neznatelně horší hodnotu pro leaf-on. U MAE a RMSE jsou nejmenší odchylky pro leaf-on model, stejně jako u listnaté lokality Neratovice. Nutno ale podotknout, že leaf-off má ze všech tří lokalit

jednoznačně pro lokalitu Veselka, tedy jehličnatý porost, tedy nejlepší výsledky. Boxplot zobrazující porovnání modelů s pozemním referenčním měřením pro lokalitu Veselka zobrazuje příloha 2.

Dále lze lokality mezi sebou porovnat pomocí lineární regrese, kde je možné výsledky opticky zhodnotit také v podobě grafů. Nejlepší výsledky opět podle vizuálního zhodnocení vykazuje oblast, kde jsou nejčetněji zastoupené jehličnaté stromy, tedy lokalita Veselka (graf 2), kdy žádná z metod nevykazuje významně horší výsledky. Naopak u dalších dvou lokalit (graf 3) má leaf-off ztelně horší lineární závislost odhadovaných výšek s referenčním pozemním měřením.



Graf 2: Zobrazení lineární závislosti pomocí lineárního regresního modelu pro lokalitu Veselka



Graf 3: Zobrazení lineární závislosti pomocí lineárního regresního modelu pro lokalitu Loučeň (vlevo) a Neratovice (vpravo)

Pro odhadování výšky stromů má podle výsledků v tomto výzkumu v průměru nejlepší výsledky leaf-on metoda, která je velmi vhodná pro výzkum jehličnatých i listnatých stromů. Dále pak kombinace leaf-on a leaf-off vykazuje nejlepší hodnoty pro smíšený porost a obecně je v průměru jen o něco málo horší než leaf-on. V poslední řadě se leaf-off zdá být zcela nevhodný pro výzkum výšky listnatých a smíšených porostů, naopak má velmi kvalitní výsledky u čistě jehličnatých stromů.

6.1.3 Jehličnaté a listnaté druhy

Všechny stromy v datasetu byly rozřazeny podle toho, zda se jedná o jehličnatý, či listnatý druh stromu a podle toho byly stromy statisticky vyhodnocovány. Tabulka 4 zobrazuje výsledky, kterých bylo při zkoumání dosaženo.

Tabulka 4: Statistické vyhodnocení modelů vegetace pro jehličnatý a listnatý typ porostu

Typ porostu		Leaf-on	Leaf-off	Kombinace
Listnatý	MAE (m)	1,45	7,81	2,49
	RMSE (m)	2,40	10,22	3,13
	R ²	0,82	0,17	0,76
Jehličnatý	MAE (m)	2,12	2,19	2,51
	RMSE (m)	2,96	2,64	3,06
	R ²	0,91	0,95	0,89


Jak už vyplývá z předešlých analýz a výsledků, pro listnatý typ porostu má jednoznačně nejlepší výsledky leaf-on, který dominuje jak u MAE a RMSE, tak u R². Míra lineární závislosti je zde nejlépe vysvětlena a odchylky jsou také nejmenší. Leaf-

off má oproti zbylým dvěma modelům velmi špatné výsledky, u RMSE je odchylka dokonce vyšší než 10 metrů, což je pro přesné měření výšky stromu zcela nepřijatelné a MAE má chybu o něco málo nižší než RMSE, ale stále je chyba vyšší než 7 metrů. Kombinace zde nepřináší zlepšení výsledků, ale výška chyby není tak kritická jako u leaf-off modelu.

Jehličnaté stromy mají u všech tří modelů velmi srovnatelné výsledky, kdy nejmenší chybu pro MAE činí leaf-on model, který má hodnotu 2,12 m. Ovšem leaf-off je se svou hodnotou nejlepšímu výsledku velmi blízko, chyba je jen o 7 cm vyšší. Jejich kombinace má zde nejhorší výsledky, i když jen neznatelně. Pro RMSE je nejnižší odchylka pro leaf-off, dále pak leaf-on a nejhorších výsledků dosahuje u jejich kombinace. R kvadrát je stejně jako RMSE nejlepší u leaf-off modelu, nejhorší u kombinace leaf-on a leaf-off.

Graf 4 znázorňuje zobrazení lineární závislosti pro jehličnaté a listnaté druhy mezi pozemním měřením (referenční data) a třemi odhadovanými výškami stromů z CHM, konkrétně leaf-on, leaf-off a jejich kombinace. Už jen z těchto grafů vyplývá, že jehličnaté druhy mají mnohem lepší závislost odvozených výšek ze všech CHM s referenčními daty oproti listnatým druhům.

U listnatých druhů stromů je patrné, že leaf-off bude mít značně horší výsledky, protože se zde u výšek odhadovaných z CHM vyskytuje mnoho stromů, které mají výšku 0 a obecně zde nejsou hodnoty příliš vysoké.



Graf 4: Zobrazení lineární závislosti pomoci lineárního regresního modelu pro jehličnaté druhy (vlevo) a listnaté druhy stromů (vpravo)

Obecně lze tedy prohlásit, že pro mapování čistě listnatých stromů je vhodné použít leaf-on a zcela nevhodné naopak použít leaf-off, jejich kombinace zlepšení výsledků nepřináší. Pro jehličnaté stromy je vhodné použití jak leaf-on, tak leaf-off modelů, i

když leaf-off vykazuje nepatrně lepší výsledky. Jejich kombinace, stejně jako u listnatých stromů, zlepšení výsledků nepřináší. Detailnější charakter a rozmístění výšek stromů odhadnutých z vybraných modelů v porovnání s pozemním měřením pro jehličnaté stromy zobrazuje příloha 5, pro listnaté stromy pak příloha 6.

6.1.4 Vybrané druhy stromů

Na poslední úrovni byly hodnoceny vybrané druhy stromů, které se na lokalitách při měření vyskytovaly nejčastěji. Jedná se o dva jehličnaté druhy, konkrétně smrk a borovice a dále listnatý druh dub. Poslední kategorii reprezentují ostatní listnaté druhy stromů, které se při měření nevyskytovaly dostatečně častě aby tvořily vlastní kategorii. Jednotlivé výsledky lze vidět v tabulce 5.

Tabulka 5: Statistické vyhodnocení modelů vegetace pro jednotlivé druhy stromů

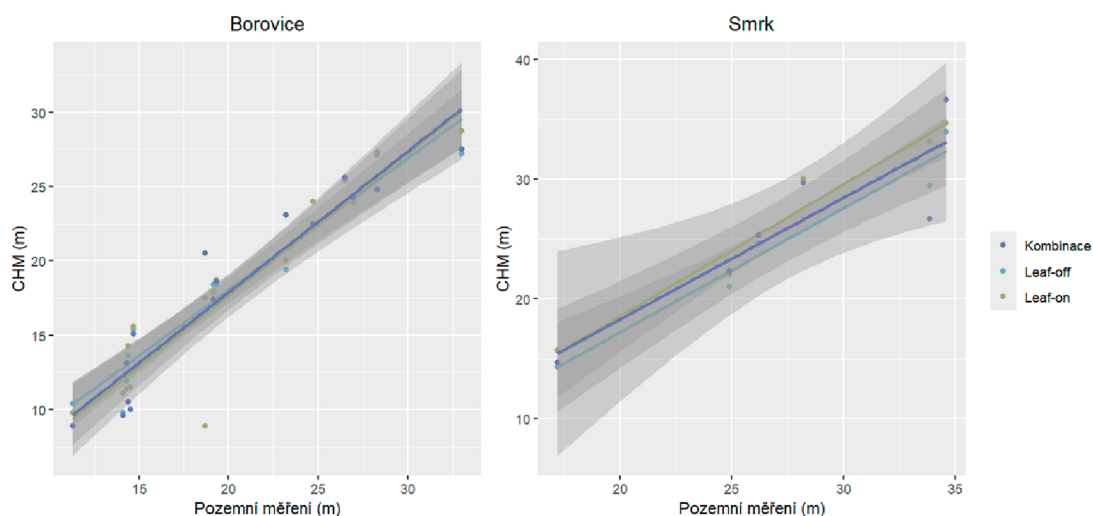
Druh		Leaf-on	Leaf-off	Kombinace
ostatní listnaté	MAE (m)	1,44	5,51	2,84
	RMSE (m)	2,38	7,01	3,70
	R ²	0,88	0,54	0,69
Dub	MAE (m)	1,46	9,84	2,19
	RMSE (m)	2,41	12,38	2,52
	R ²	0,68	0,04	0,78
Borovice	MAE (m)	2,31	1,79	2,40
	RMSE (m)	3,35	2,54	2,89
	R ²	0,85	0,93	0,90
Smrk	MAE (m)	1,33	5,53	2,78
	RMSE (m)	1,60	2,86	3,44
	R ²	0,95	0,94	0,74

Smrk ze všech srovnávaných druhů vykazuje pro leaf-on nejlepší výsledky, kde u MAE a RMSE nejsou odchylky v měření vyšší než dva metry a koeficient determinace má zde také nejlepší hodnotu. Smrk má u MAE nejhorší chybu pro leaf-off, která činí 5,53 metrů, pro kombinaci je nižší, zhruba necelé tři metry. RMSE má pro leaf-off naopak lepší výsledky než MAE, chyba nedosahuje ani tří metrů. Obecně lze říci, že pro smrk má ze všech porovnávaných metod nejlepší výsledky leaf-on. Porovnání výšek stromů z leaf-on, leaf-off a jejich kombinace s pozemním měřením pro smrk zobrazuje příloha 7.

Borovice vykazuje o něco jiné výsledky než smrk, protože zde se jeví jako nejvíce přesná metoda pro odhadnutí výšky stromů leaf-off model, který má nejlepší výsledky jak pro MAE a RMSE, tak pro R² koeficient determinace. Výsledky jsou u borovice o něco přesnější než u smrku, ale tato skutečnost může být zapříčiněna tím, že smrk má ze všech druhů stromů nejméně měření. V příloze 8 lze vidět detailnější charakter naměřených dat borovice v podobě boxplotů pro pozemní měření a jednotlivé modely.

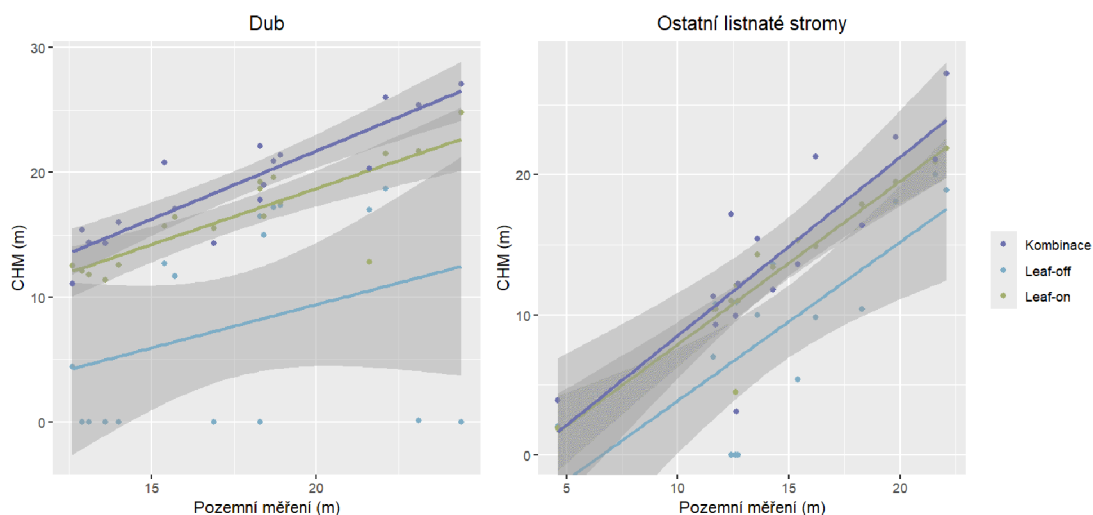
Pro dub je jednoznačně nejhorší leaf-off model, který má pro RMSE odchylku 12,38 metrů, dále MAE se odchyluje o necelých 10 metrů. Lepší výsledky lze pozorovat u kombinace leaf-on a leaf-off, kde chyby nepřesahují 3 metry a koeficient determinace je zde ze všech tří metod nejvyšší, tudíž nejlepší. Pro MAE a RMSE je možné zpozorovat nejlepší výsledky pro leaf-on, což koresponduje i s výsledky u listnatých druhů stromů v tabulce 5. Další informace o rozmístění výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro dub zobrazuje příloha 10, pro ostatní listnaté stromy pak příloha 9. Ostatní listnaté druhy stromů mají nejmenší chyby pro leaf-on, dále pak o pár metrů horší pro kombinaci a nejvyšší chyby lze opět zpozorovat u leaf-off, kde je chyba pro RMSE v průměru 7 metrů a pro MAE 5,51 metrů.

Lineární závislost mezi proměnnými lze sledovat také pomocí lineární regrese vynesené do grafu, což je znázorněno v grafu 5. Borovice má velmi silnou lineární závislost odhadovaných výšek na pozemním měření, zatímco smrk má o něco větší odchylky jednotlivých výšek stromů, ale ani jedna ze tří metod pro odhad výšky u tohoto druhu nevykazuje významně odlišné výsledky.



Graf 5: Zobrazení lineární závislosti pomocí lineárního regresního modelu pro borovici (vlevo) a smrk (vpravo)

Lineární závislost pro dub a ostatní listnaté druhy stromů zobrazuje graf 6. U listnatých druhů se lineární závislost jeví jako podstatně horší, zvláště u leaf-off se vyskytuje mnoho stromů, které zde mají odhadnutou výšku 0, což podstatně zhoršuje výsledky. Ostatní listnaté stromy mají u metody leaf-off o něco lepší výsledky, ale stále to nedosahuje kvality jehličnatých stromů.



Graf 6: Zobrazení lineární závislosti pomocí lineárního regresního modelu pro dub (vlevo) a ostatní listnaté druhy stromů (vpravo)

6.2 Zhodnocení zdravotního stavu vegetace


Analýza zdravotního stavu vegetace podél dopravní infrastruktury vycházející z poloautomatických algoritmů pro detekci jednotlivých vrcholů stromů a jejich korun přináší výsledky na několika úrovních. Při této analýze byly pro jednotlivé koruny stromů na zájmových lokalitách vypočteny detailní rastry v podobě spektrálních indexů, které díky svému vysokému rozlišení udávají informace o zdravotním stavu jednotlivých částí koruny stromu. Tyto rastry lze brát jako výsledný produkt, který slouží k individuálnímu a detailnímu posouzení zdravotního stavu jednotlivých stromů a jejich částí korun podél dopravní infrastruktury.

Pro využití těchto výsledků napříč zájmovými území je vhodnější nepracovat se všemi pixely každého stromu, ale pouze s průměrnými hodnotami vypočtených spektrálních indexů za každý strom. Takovou informaci si lze zobrazit v mapě a jednotlivé koruny stromů pomocí vhodně zvolené barevné škály reprezentovat průměrnou hodnotou vybraného spektrálního indexu, která na první pohled udává zdravotní stav ať už jednotlivých stromů, tak zvolené oblasti.

Obrázek 7 zobrazuje výslednou vrstvu reprezentující průměrnou hodnotu NDVI pro každý strom, který byl detekovaný pomocí algoritmu založeného na hydrologickém modelování. Jak lze na obrázku vidět, index se jeví jako citlivý k malým rozdílům mezi jednotlivými stromy a je schopný detekovat mrtvé či nezdravé stromy. Nevýhodou může být zjednodušený tvar koruny v podobě kružnice, který může zasahovat do


korun jiných stromů, nebo by dokonce do této plochy mohla být zahrnuta silnice, která by výsledky průměrné hodnoty NDVI značně zhoršila.

Průměrná hodnota NDVI pro detekované stromy na lokalitě Neratovice



Obrázek 7: Průměrné hodnoty NDVI pro jednotlivé koruny stromů, lokalita Neratovice, vlastní zpracování

Průměrná hodnota NDRE pro detekované stromy na lokalitě Neratovice



Obrázek 8: Průměrné hodnoty NDRE pro jednotlivé koruny stromů, lokalita Neratovice, vlastní zpracování

Obrázek 8 reprezentuje stejné území a použité metody pro analýzy jako Obrázek 7, ale tentokrát se jedná o index NDRE, který se svými výsledky oproti indexu NDVI liší v tom, že působí viditelně citlivěji na drobnější změny mezi stromy, které nejsou mrtvé či na první pohled vystresované/nezdravé. NDRE tak může pomoci k exaktnějšímu detekování změny zdravotního stavu vegetace než NDVI.

7 Diskuse

V této diplomové práci byla porovnávána výšková přesnost modelů vegetace reprezentujících leaf-on a leaf-off digitální modely vegetace vytvořené v opačných částech vegetačního období a jejich kombinace. Porovnání výškové přesnosti probíhalo na čtyřech úrovních. Nejprve byly porovnávány všechny stromy z výzkumných lokalit dohromady, v další úrovni jednotlivé lokality mezi sebou, kdy každá reprezentovala jiný typ porostu (jehličnatý, listnatý a smíšený). Dále do výzkumu vstoupilo porovnání mezi jehličnatými a listnatými druhy stromů a v poslední řadě byl zkoumán rozdíl mezi jednotlivými vybranými druhy, přesněji se jednalo o čtyři následující kategorie: smrk, borovice, dub a čtvrtou kategorií tvořily ostatní listnaté druhy.

Obecně v porovnání výškové přesnosti všech stromů dohromady s referenčními daty dosáhl nejpřesnější celkové výškové přesnosti model leaf-on, druhým byla pak kombinace leaf-on a leaf-off a nejhorších výsledků při určování výšky stromů měl leaf-off model. V diplomové práci byly pro hodnocení přesnosti použity dvě víceméně běžné metriky, a to MAE a RMSE. RMSE mělo obecně u hodnocení výškové přesnosti větší odchylky, protože je citlivější na odlehlé hodnoty, které byly ve většině případů tvořeny listnatými stromy, které nebyly na leaf-off modelu zachyceny a mnohdy udávaly velmi nízké hodnoty. Koeficient determinace byl pro hodnocení všech stromů také nejlepší u leaf-on modelu.

Pokud se zaměříme pouze na jehličnaté a listnaté druhy stromů, tak pro listnaté druhy stromů je jednoznačně nejhorší leaf-off model, který má v případě statistiky RMSE odchylku přes více než 10 metrů, u MAE pak skoro 8 metrů. To je pravděpodobně způsobené tím, že listnaté stromy nebyly na modelu reprezentujícím zimní období leaf-off dobře viditelné a mnohdy mohl být místo koruny stromu detekován jeho kmen, nebo nějaké spodní větve, případně zemský povrch. Tento výsledek potvrzují i ve svém výzkumu Huang et al. (2019), kteří také došli k závěru, že modelování výšky stromů za leaf-off podmínek přináší značné zhoršení výsledků oproti leaf-on modelům. Pro jehličnaté druhy byla výšková přesnost jednotlivých modelů téměř srovnatelná, avšak o něco lepší hodnoty u RMSE a koeficientu determinace vykazuje leaf-off model, pro MAE pak leaf-on model.

Kombinování leaf-on a leaf-off UAV modelů vegetace pro úlohy spojené se zjišťováním informací o vegetačním krytu a výšce vegetace vypadá na první pohled jako velmi slibná metoda, která by i podle Moudrý et al. (2019) mohla mít potenciál nahradit nákladné letecké laserové snímkování (LiDAR). Kombinace těchto modelů

vykazovala nepatrné zlepšení výsledků pouze při porovnání jednotlivých typů porostů u smíšeného porostu, kde byly menší odchylky a vyšší koeficient determinace než u zbylých dvou modelů. Dále dosáhl tento model ještě nejpřesnějších výsledků už jen při hodnocení výškové přesnosti dubu, kde ze všech tří hodnocených modelů vykazoval nejvyšší výsledek pro koeficient determinace Nicméně nejmenší odchylky MAE a RMSE pro dub vykazoval leaf-on model. Z výsledků, v diplomové práci provedeného výzkumu, obecně vyplývá, že kombinace těchto dvou modelů nepřináší významné zlepšení přesnosti výsledků odhadu výšky vegetace oproti použití pouze leaf-on modelu, který se tak zdá být pro praktickou aplikaci vhodnější. Podobných výsledků bylo dosaženo i ve výzkumu Komárek et al. (2024), kteří také došli k závěru, že kombinace těchto dvou modelů nepřináší významné zlepšení výsledků v porovnání pouze s leaf-on modelem.

Při hodnocení výškové přesnosti jednotlivých druhů vychází ve většině případů nejlepší přesnost pro odhad výšky stromů leaf-on model, konkrétně jednoznačně pro smrk a ostatní listnaté druhy. Dub u leaf-on modelu vykazuje nejmenší odchylky u MAE a RMSE, ale koeficient determinace je nejvyšší u kombinace leaf-on a leaf-off. Naopak leaf-off se zdá být pro hodnocení výškové přesnosti u dubu naprosto nevhodný. Pro borovici se zdá být nejvhodnějším modelem leaf-off, který zde má v porovnání s ostatními modely nejlepší výsledky. Nicméně výšková přesnost ostatních dvou je na tom velmi podobně, proto by se při odhadování výšky borovic dalo uvažovat o využití všech zmíněných modelů. Tyto výsledky ovšem mohou být zkresleny množstvím použitých vzorků pro jednotlivé druhy stromů, kdy například kategorie smrk obsahovala pouze 6 stromů, naopak borovice a ostatní listnaté druhy 15 stromů a dub pak 17 stromů. Pro dosažení lepších výsledků by bylo vhodné použít stejné množství stromů pro jednotlivé kategorie.

Výsledky naznačují, že přístupy použité v této diplomové práci k odhadnutí výšky stromů jsou porovnatelné s terénními metodami, které k měření výšky využívají laserové dálkoměry. Tento výsledek ve svém výzkumu potvrzují například i Komárek et al. (2024), kteří uvádí stejné tvrzení. Ve výzkumu Ni et al. (2019) dále navrhují, že metody extrakce výšky lesního porostu pomocí metod UAV z období leaf-on a leaf-off lze využívat pro inventarizaci nadzemní biomasy listnatých lesů. S těmito závěry souhlasí i Nasiri et al. (2021), kteří ve svém výzkumu sledují přesnost dosažených výsledků pro odhad výšek stromů a průměr korun jako slibnou a prakticky využitelnou.

Pro zlepšení výsledných hodnot extrahovaných výšek stromů pomocí metod DPZ by se namísto optických senzorů dalo uvažovat o použití technologií LiDAR, které jsou

velmi vhodné pro lesní inventarizaci a management (Lin et al., 2021). Jedná se ale o velmi nákladnou metodu, která by i na základě výsledků této diplomové práce i výše uvedených studií mohla být s dostatečnou přesností nahrazena optickým snímáním pomocí UAV.

Samotné závěry diplomové práce mohou být, mimo dalších parametrů, částečně ovlivněny odlišným typem použitého senzoru (RGB vs. multispektrální senzor) pro pořizování leaf-on a leaf-off dat, který je zmíněný v kapitole Zpracování UAV dat. Na druhou stranu stejná data použili bez větších problémů ve své studii Komárek et al. (2024).

Je dobré zmínit, že výsledky této práce, i když se o to svým výběrem odlišných zájmových lokalit snaží, nepřináší univerzálně (globálně) platné výsledky, Nicméně z povahy zájmových území budou s velkou pravděpodobností validní pro běžný vegetační pokryv vyskytující se podél dopravní infrastruktury ve střední Evropě. Výsledné odhadování výšky stromů by se tak mohly značně lišit na územích s jiným druhovým složením stromů, sklonem terénu, vertikální strukturou vegetace apod.

Dalším předmětem výzkumu této diplomové práce bylo zhodnocení zdravotního stavu vegetace podél dopravní infrastruktury ve formě vybraných spektrálních indexů pomocí poloautomatické detekce vrcholů stromů a jejich korun. Pro zhodnocení zdravotního stavu byly využity indexy NDVI a NDRE, díky kterým lze dobře předpovídat odchylky od normálního stavu zdravé vegetace. Jelikož byl pro tento výzkum použit multispektrální senzor, který kromě pásem viditelného spektra obsahuje už jen NIR a Red-Edge pásma, byl výběr spektrálních vegetačních indexů poměrně limitovaný, protože jiné indexy pro zhodnocení zdravotního stavu vegetace (jako je např. MSI, či NDMI) využívají například krátkovlnné infračervené pásmo (SWIR, z angl. short-wave infrared). Nicméně pásmo SWIR v současnosti neměří víceméně žádné běžně dostupné UAV senzory (v literatuře lze nalézt zatím jen několik velice experimentálních řešení). Proto by se v takovém případě nabízelo využití jiných platforem, jakými jsou například letadla či družice s multispektrálním senzorem a velmi vysokým rozlišením.

Při detekci vrcholů stromů pomocí algoritmu, který byl použit v této diplomové práci, je také třeba brát ohledy na spolehlivost jeho detekce. Detekce totiž velmi závisí na zvoleném nastavení a v řadě případů není zcela jednoduché najít dostatečně vhodné parametry, které by zajišťovaly spolehlivou detekci vrcholů stromů. Dalším problematickým faktorem této automatické detekce je fakt, že při využití UAV dat pořizovaných optickými senzory není dostupná informace o jednotlivých kmenech

stromů a situaci pod jejich korunami. Proto není v řadě případů možné zejména u listnatých druhů stromů spolehlivě určit, zda se jedná o jeden strom s rozvětvenou korunou, nebo dva samostatné stromy.

Přestože v sobě stále skrývá využití UAV dat řadu neurčitostí, jedná se ale o přístup, který by mohl v budoucnu s rozvojem pokročilých zpracovatelských technologií usnadňovat či nahrazovat práci vyžadující častý terénní průzkum, a to jak v případě odhadu výšky, tak zdravotního stavu vegetace nejen podél liniové dopravní infrastruktury. Například velmi slibných výsledků v oblasti zdravotního stavu lesních porostů a jejich ovlivnění hmyzími škůdci již bylo dosaženo v bakalářské práci autorky této diplomové práce (Maletínská, 2022).

8 Závěr a přínos práce

Hlavním cílem diplomové práce bylo porovnat výškovou přesnost modelů vegetace pořízených ve (leaf-on) a mimo (leaf-off) vegetační období a jejich případnou kombinaci, oproti vlastnímu pozemnímu referenčním měřením. Dílčím cílem výzkumu bylo zjistit, zda se liší přesnost leaf-on a leaf-off modelů v různých typech porostů (listnatý, jehličnatý a smíšený) a zda navíc existují rozdíly v přesnosti pro jednotlivé druhy stromů. Dalším důležitým cílem bylo také zhodnotit to, zda kombinace leaf-on a leaf-off přináší zvýšení výškové přesnosti. Mimo hodnocení výškové přesnosti UAV dat bylo v diplomové práci dále provedeno zhodnocení zdravotního stavu stromů podél dopravní infrastruktury pomocí vybraných spektrálních vegetačních indexů a vyhodnocení, zda jsou tyto indexy vhodné k monitoringu zdravotního stavu vegetace a mohou být využity v úlohách zaměřených na bezpečnost dopravní infrastruktury. V diplomové práci dosažené výsledky jsou zejména aplikovatelné a přenositelné pro území s podobnými přírodními podmínkami jako měla zvolená zájmová území, která představují typickou střeoevropskou vegetaci, která se může nalézat podél liniové dopravní infrastruktury.

Z výsledků diplomové práce je zřejmé, že přesnost UAV modelů leaf-on a leaf-off se mezi sebou při určování výšky vegetace výrazně liší. Rozdíly mezi těmito modely při určování výšky vegetace jsou patrné pro jednotlivé typy porostu, jako jsou jehličnaté a listnaté typy lesů, tak i pro jednotlivé druhy stromů. Leaf-on je velmi vhodný pro mapování listnatých druhů stromů, kde chyba měření v podobě MAE a RMSE nebyla vyšší než 3 metry a koeficient determinace dosahoval až 82 %. Stejně tak je vhodný i pro jehličnaté druhy, kde taktéž nevykazoval chyby vyšší než 3 metry a koeficient determinace dosáhl dokonce až 91 %. Naopak pro listnaté druhy stromů je zcela nevhodné použití leaf-off modelu, na kterém mnohdy není možné zachytit vrchol

stromu reprezentující jeho výšku a jsou místo něj zachyceny spodní větve, kmen, či dokonce zemský povrch. RMSE zde byl velmi vysoký a přesáhl 10 metrů, odchylka v podobě MAE činila 7,81 metrů a koeficient determinace pro tento model byl pouhých 17 %.

Leaf-on a leaf-off UAV modely se svou přesností liší i pro jednotlivé druhy stromů. Hodnoceny byly čtyři následující kategorie: borovice, smrk, dub a ostatní listnaté druhy. Pro borovici vychází velmi kvalitní výsledky jak pro leaf-on, tak leaf-off model. Lepší hodnoty ale nepatrně přináší leaf-off model, kde koeficient determinace činí 93 %, MAE 1,79 metrů a RMSE pak 2,54 metrů. Pro odhadování výšky smrku se lépe osvědčil leaf-on model, který měl neznatelně lepší výsledky, ale leaf-off se také jeví jako vhodný pro odhad výšky tohoto druhu. Pro ostatní listnaté druhy a dub se leaf-off model ukázal být velmi nevhodným a v porovnání s ním má mnohem lepší výsledky leaf-on.

Kombinace DSM leaf-on a DTM leaf-off v tomto výzkumu nepřinesla významné vylepšení výsledků, zlepšení výsledných hodnot touto kombinací bylo dosaženo pouze u smíšeného porostu z lokality Loučeň a dále kombinace leaf-on a leaf-off vykazovala nejlepší hodnoty už jen u koeficientu determinace pro dub.

Poslední část diplomové práce prokázala využitelnost spektrálních indexů NDVI a NDRE pro hodnocení zdravotního stavu jednotlivých stromů. Oba ze zkoumaných indexů jsou schopné zobrazovat variabilitu zdravotního stavu vegetace a jejího stresu a obecně jsou ke změně těchto fyziologických stavů citlivé. Toto zjištění může svým dílkem přispět do řešení problematiky využitelnosti spektrálních indexů spočtených z UAV dat v různých úloh zaměřených na výzkum životního prostředí, například pro dlouhodobý a opakovaný monitoring zdravotního stavu vegetace, a to nejen v bezprostředním okolí dopravní infrastruktury.

Diplomová práce splňuje v zadání stanovené cíle a její výsledky odpovídají na stanovené výzkumné otázky, tedy že přesnost leaf-on a leaf-off UAV modelů vegetace se mezi sebou při určování výšek stromů liší, leaf-on je pro odhad výšky v průměru vhodnější a přesnější oproti leaf-off modelu, který dosahuje odchylek od terénního měření mnohdy přes více než 10 metrů. Dále bylo prokázáno, že existují rozdíly výškové přesnosti leaf-on a leaf-off modelů pro jednotlivé druhy stromů a kombinace leaf-on a leaf-off modelů obecně nepřináší významné zlepšení výsledků. Spektrální indexy odvozené z UAV dat se ukázaly být užitečným nástrojem pro monitoring zdravotního stavu vegetace a mohou být využity v úlohách zaměřených na bezpečnost dopravní infrastruktury.

9 Přehled literatury a použitých zdrojů

- ADAM, Elhadi; MUTANGA, Onesimo a RUGEGE, Denis, 2010. Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review. Online. *Wetlands Ecology and Management*. Roč. 18, č. 3, s. 281-296. ISSN 0923-4861. Dostupné z: <https://doi.org/10.1007/s11273-009-9169-z>.
- BALENOVIĆ, Ivan; SIMIC MILAS, Anita a MARJANOVIĆ, Hrvoje, 2017. A Comparison of Stand-Level Volume Estimates from Image-Based Canopy Height Models of Different Spatial Resolutions. Online. *Remote Sensing*. Roč. 9, č. 3. ISSN 2072-4292. Dostupné z: <https://doi.org/10.3390/rs9030205>.
- BÍL, Michal; ANDRÁŠIK, Richard; NEZVAL, Vojtěch a BÍLOVÁ, Martina, 2017. Identifying locations along railway networks with the highest tree fall hazard. Online. *Applied Geography*. Roč. 87, s. 45-53. ISSN 01436228. Dostupné z: <https://doi.org/10.1016/j.apgeog.2017.07.012>.
- BORDA-DE-ÁGUA, Luís; BARRIENTOS, Rafael; BEJA, Pedro a PEREIRA, Henrique Miguel (ed.), 2017. *Railway Ecology*. Online. Cham: Springer International Publishing. ISBN 978-3-319-57495-0. Dostupné z: <https://doi.org/10.1007/978-3-319-57496-7>.
- BROGE, N.H a LEBLANC, E, 2001. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. Online. *Remote Sensing of Environment*. Roč. 76, č. 2, s. 156-172. ISSN 00344257. Dostupné z: [https://doi.org/10.1016/S0034-4257\(00\)00197-8](https://doi.org/10.1016/S0034-4257(00)00197-8).
- CORNELISSEN, J. H. C.; LAVOREL, S.; GARNIER, E.; DÍAZ, S.; BUCHMANN, N. et al., 2003. A handbook of protocols for standardised and easy measurement of plant functional traits worldwide. Online. *Australian Journal of Botany*. Roč. 51, č. 4. ISSN 0067-1924. Dostupné z: <https://doi.org/10.1071/BT02124>.
- DIETENBERGER, Steffen; MUELLER, Marlin M.; BACHMANN, Felix; NESTLER, Maximilian; ZIEMER, Jonas et al., 2023. Tree Stem Detection and Crown Delineation in a Structurally Diverse Deciduous Forest Combining Leaf-On and Leaf-Off UAV-SfM Data. Online. *Remote Sensing*. Roč. 15, č. 18. ISSN 2072-4292. Dostupné z: <https://doi.org/10.3390/rs15184366>.
- EOS Data Analytics, 2024. NDRE: Normalized Difference Red Edge Index. Online. Dostupné z: <https://eos.com/industries/agriculture/ndre/>.
- GOODBODY, Tristan R. H.; COOPS, Nicholas C. a WHITE, Joanne C., 2019. Digital Aerial Photogrammetry for Updating Area-Based Forest Inventories: A Review of Opportunities, Challenges, and Future Directions. Online. *Current Forestry Reports*. Roč. 5, č. 2, s. 55-75. ISSN 2198-6436. Dostupné z: <https://doi.org/10.1007/s40725-019-00087-2>.
- GOVENDER, M; CHETTY, K; NAIKEN, V a BULCOCK, H, 2019. A comparison of satellite hyperspectral and multispectral remote sensing imagery for improved classification and mapping of vegetation. Online. *Water SA*. 2019-02-19, roč. 34, č. 2, s. 147-154. ISSN 0378-4738. Dostupné z: <https://doi.org/10.4314/wsa.v34i2.183634>.
- HINDLS, Richard, 2007. *Statistika pro ekonomy*. 8. vyd. Praha: Professional Publishing. ISBN 978-80-86946-43-6.

HODSON, Timothy O., 2022. Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. Online. *Geoscientific Model Development*. Roč. 15, č. 14, s. 5481-5487. ISSN 1991-9603. Dostupné z: <https://doi.org/10.5194/gmd-15-5481-2022>.

HORÁK, Jiří, 2014: Dálkový průzkum Země. VŠB-TU Ostrava, Ostrava.

HUANG, Hongyu; HE, Shaodong a CHEN, Chongcheng, 2019. Leaf Abundance Affects Tree Height Estimation Derived from UAV Images. Online. *Forests*. Roč. 10, č. 10. ISSN 1999-4907. Dostupné z: <https://doi.org/10.3390/f10100931>.

HUETE, A.R, 1988. A soil-adjusted vegetation index (SAVI). Online. *Remote Sensing of Environment*. Roč. 25, č. 3, s. 295-309. ISSN 00344257. Dostupné z: [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X).

JIN, Cheonggil; OH, Che-young; SHIN, Sanghyun; WILFRED NJUNGWI, Nkwain a CHOI, Chuluong, 2020. A Comparative Study to Evaluate Accuracy on Canopy Height and Density Using UAV, ALS, and Fieldwork. Online. *Forests*. Roč. 11, č. 2. ISSN 1999-4907. Dostupné z: <https://doi.org/10.3390/f11020241>.

JURJEVIĆ, Luka; LIANG, Xinlian; GAŠPAROVIĆ, Mateo a BALENOVIĆ, Ivan, 2020. Is field-measured tree height as reliable as believed – Part II, A comparison study of tree height estimates from conventional field measurement and low-cost close-range remote sensing in a deciduous forest. Online. *ISPRS Journal of Photogrammetry and Remote Sensing*. Roč. 169, s. 227-241. ISSN 09242716. Dostupné z: <https://doi.org/10.1016/j.isprsjprs.2020.09.014>.

KOCUR-BERA, Katarzyna & DUDZIŃSKA, Małgorzata. (2015). Roadside vegetation - The impact on safety. *Engineering for Rural Development*. 14. 594-600.

KOCH, Barbara; HEYDER, Ursula a WEINACKER, Holger, 2006. Detection of Individual Tree Crowns in Airborne Lidar Data. Online. *Photogrammetric Engineering & Remote Sensing*. 2006-04-01, roč. 72, č. 4, s. 357-363. ISSN 00991112. Dostupné z: <https://doi.org/10.14358/PERS.72.4.357>.

KOMÁREK, Jan; LAGNER, Ondřej a KLOUČEK, Tomáš, 2024. UAV leaf-on, leaf-off and ALS-aided tree height: A case study on the trees in the vicinity of roads. Online. *Urban Forestry & Urban Greening*. Roč. 93. ISSN 16188667. Dostupné z: <https://doi.org/10.1016/j.ufug.2024.128229>.

KROPÁČEK, Jan; MORAVEC, David; & KOMÁREK, Jan; 2020: Dálkový průzkum – I. Česká zemědělská univerzita v Praze, Praha.

KUČERA, M.; DOBESOVA, Z., 2021. Analysis of the Degree of Threat to Railway Infrastructure by Falling Tree Vegetation. *ISPRS Int. J. Geo-Inf.*, 10, 292. Dostupné z: <https://doi.org/10.3390/ijgi10050292>.

KULKARNI, Saurabh a RODD, Sunil F., 2020. Context Aware Recommendation Systems: A review of the state of the art techniques. Online. *Computer Science Review*. Roč. 37. ISSN 15740137. Dostupné z: <https://doi.org/10.1016/j.cosrev.2020.100255>.

KWAK, Doo-Ahn; LEE, Woo-Kyun; LEE, Jun-Hak; BIGING, Greg S. a GONG, Peng, 2017. Detection of individual trees and estimation of tree height using LiDAR data. Online. *Journal of Forest Research*. 2017-01-20, roč. 12, č. 6, s. 425-434. ISSN 1341-6979. Dostupné z: <https://doi.org/10.1007/s10310-007-0041-9>.

- LEPŠ, Jan a ŠMILAUER, Petr, 2016. *Biostatistika*. České Budějovice: Nakladatelství Jihočeské univerzity v Českých Budějovicích. ISBN 978-80-7394-587-9.
- LILLESAND, Thomas M.; KIEFER, Ralph W. a CHIPMAN, Jonathan W., c2008. *Remote sensing and image interpretation*. 6th ed. Hoboken: John Wiley. ISBN 978-0-470-05245-7.
- LIN, Yi-Chun; LIU, Jidong; FEI, Songlin a HABIB, Ayman, 2021. Leaf-Off and Leaf-On UAV LiDAR Surveys for Single-Tree Inventory in Forest Plantations. Online. *Drones*. Roč. 5, č. 4. ISSN 2504-446X. Dostupné z: <https://doi.org/10.3390/drones5040115>.
- LISEIN, Jonathan; PIERROT-DESEILLIGNY, Marc; BONNET, Stéphanie a LEJEUNE, Philippe, 2013. A Photogrammetric Workflow for the Creation of a Forest Canopy Height Model from Small Unmanned Aerial System Imagery. Online. *Forests*. Roč. 4, č. 4, s. 922-944. ISSN 1999-4907. Dostupné z: <https://doi.org/10.3390/f4040922>.
- MALETÍNSKÁ, Barbora. Monitoring šíření lýkožrouta v NPR Rejvíz z dat Landsat 8. Praha, 2022. Bakalářská práce. Česká zemědělská univerzita, Fakulta životního prostředí, Katedra prostorových věd. Vedoucí práce Ing. Tomáš Klouček, Ph.D.
- MIELCAREK, Miłosz; KAMIŃSKA, Agnieszka a STEREŃCZAK, Krzysztof, 2020. Digital Aerial Photogrammetry (DAP) and Airborne Laser Scanning (ALS) as Sources of Information about Tree Height: Comparisons of the Accuracy of Remote Sensing Methods for Tree Height Estimation. Online. *Remote Sensing*. Roč. 12, č. 11. ISSN 2072-4292. Dostupné z: <https://doi.org/10.3390/rs12111808>.
- MORAVEC, David; KOMÁREK, Jan; LÓPEZ-CUERVO MEDINA, Serafín a MOLINA, Iñigo, 2021. Effect of Atmospheric Corrections on NDVI: Intercomparability of Landsat 8, Sentinel-2, and UAV Sensors. Online. *Remote Sensing*. Roč. 13, č. 18. ISSN 2072-4292. Dostupné z: <https://doi.org/10.3390/rs13183550>.
- MOUDRÝ, Vítězslav; GDULOVÁ, Kateřina; FOGL, Michal; KLÁPŠTĚ, Petr; URBAN, Rudolf et al., 2019. Comparison of leaf-off and leaf-on combined UAV imagery and airborne LiDAR for assessment of a post-mining site terrain and vegetation structure: Prospects for monitoring hazards and restoration success. Online. *Applied Geography*. Roč. 104, s. 32-41. ISSN 01436228. Dostupné z: <https://doi.org/10.1016/j.apgeog.2019.02.002>.
- NASIRI, Vahid; DARVISHSEFAT, Ali A.; AREFI, Hossein; PIERROT-DESEILLIGNY, Marc; NAMIRANIAN, Manochehr et al., 2021. Unmanned aerial vehicles (UAV)-based canopy height modeling under leaf-on and leaf-off conditions for determining tree height and crown diameter (case study: Hyrcanian mixed forest). Online. *Canadian Journal of Forest Research*. Roč. 51, č. 7, s. 962-971. ISSN 0045-5067. Dostupné z: <https://doi.org/10.1139/cjfr-2020-0125>.
- NEYNS, Robbe a CANTERS, Frank, 2022. Mapping of Urban Vegetation with High-Resolution Remote Sensing: A Review. Online. *Remote Sensing*. Roč. 14, č. 4. ISSN 2072-4292. Dostupné z: <https://doi.org/10.3390/rs14041031>.
- NI, Wenjian; DONG, Jiachen; SUN, Guoqing; ZHANG, Zhiyu; PANG, Yong et al., 2019. Synthesis of Leaf-on and Leaf-off Unmanned Aerial Vehicle (UAV) Stereo Imagery for the Inventory of Aboveground Biomass of Deciduous Forests. Online. *Remote Sensing*. Roč. 11, č. 7. ISSN 2072-4292. Dostupné z: <https://doi.org/10.3390/rs11070889>.
- PARIYAR, Sara; MANDAL, Ram. (2019). Comparative tree height measurement using different instrument.

Pix4D Documentation [online]. © 2011-2021. [cit. 2024-02- 11]. Dostupné z: <https://support.pix4d.com/hc/en-us/articles/202559339-What-does-step-1-Initial-Processing-do-PIX4Dmapper>

PURVES, Drew a PACALA, Stephen, 2008. Predictive Models of Forest Dynamics. Online. *Science*. 2008-06-13, roč. 320, č. 5882, s. 1452-1453. ISSN 0036-8075. Dostupné z: <https://doi.org/10.1126/science.1155359>.

REA, Roy V., 2003. Modifying roadside vegetation management practices to reduce vehicular collisions with moose *Alces alces*. Online. *Wildlife Biology*. Roč. 9, č. 2, s. 81-91. ISSN 1903-220X. Dostupné z: <https://doi.org/10.2981/wlb.2003.030>.

ROŞCA, Sabina; SUOMALAINEN, Juha; BARTHOLOMEUS, Harm a HEROLD, Martin, 2018. Comparing terrestrial laser scanning and unmanned aerial vehicle structure from motion to assess top of canopy structure in tropical forests. Online. *Interface Focus*. 2018-04-06, roč. 8, č. 2. ISSN 2042-8898. Dostupné z: <https://doi.org/10.1098/rsfs.2017.0038>.

SHIMA, Lurie Jessie; ANDERSON, Richard R. a CARTER, Virginia P., 1976. The Use of Aerial Color Infrared Photography in Mapping the Vegetation of a Freshwater Marsh. Online. *Chesapeake Science*. Roč. 17, č. 2. ISSN 00093262. Dostupné z: <https://doi.org/10.2307/1351049>.

SCHREUDER, Hans T.; GREGOIRE, Timothy G. a WOOD, Geoffrey B., 1993. *Sampling Methods for Multiresource Forest Inventory*. New York: John Wiley. ISBN 0-471-55245-3.

STEREŃCZAK, Krzysztof; MIELCAREK, Miłosz; WERTZ, Bogdan; BRONISZ, Karol; ZAJĄCZKOWSKI, Grzegorz et al., 2019. Factors influencing the accuracy of ground-based tree-height measurements for major European tree species. Online. *Journal of Environmental Management*. Roč. 231, s. 1284-1292. ISSN 03014797. Dostupné z: <https://doi.org/10.1016/j.jenvman.2018.09.100>.

SUROVÝ, Peter, 2019. Aplikace dálkového průzkumu Země v lesnictví. V Praze: Česká zemědělská univerzita. ISBN 978-80-213-3008-5.

VAN TREESE II, Jeffery W.; KOESER, Andrew K.; FITZPATRICK, George E.; OLEXA, Michael T. a ALLEN, Ethan J., 2017. A review of the impact of roadway vegetation on drivers' health and well-being and the risks associated with single-vehicle crashes. Online. *Arboricultural Journal*. 2017-09-13, roč. 39, č. 3, s. 179-193. ISSN 0307-1375. Dostupné z: <https://doi.org/10.1080/03071375.2017.1374591>.

WANG, Yunsheng; LEHTOMÄKI, Matti; LIANG, Xinlian; PYÖRÄLÄ, Jiri; KUKKO, Antero et al., 2019. Is field-measured tree height as reliable as believed – A comparison study of tree height estimates from field measurement, airborne laser scanning and terrestrial laser scanning in a boreal forest. Online. *ISPRS Journal of Photogrammetry and Remote Sensing*. Roč. 147, s. 132-145. ISSN 09242716. Dostupné z: <https://doi.org/10.1016/j.isprsjprs.2018.11.008>.

WELIKHE, Pauline; QUANSAH, Joseph Essamuah; FALL, Souleymane a MCELHENNEY, Wendell, 2017. Estimation of Soil Moisture Percentage Using LANDSAT-based Moisture Stress Index. Online. *Journal of Remote Sensing & GIS*. Roč. 06, č. 02. ISSN 24694134. Dostupné z: <https://doi.org/10.4172/2469-4134.1000200>.

WILLMOTT, CJ a MATSUURA, K, 2005. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance.

Online. *Climate Research*. Roč. 30, s. 79-82. ISSN 0936-577X. Dostupné z: <https://doi.org/10.3354/cr030079>.

XUE, Jinru a SU, Baofeng, 2017. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. Online. *Journal of Sensors*. Roč. 2017, s. 1-17. ISSN 1687-725X. Dostupné z: <https://doi.org/10.1155/2017/1353691>.

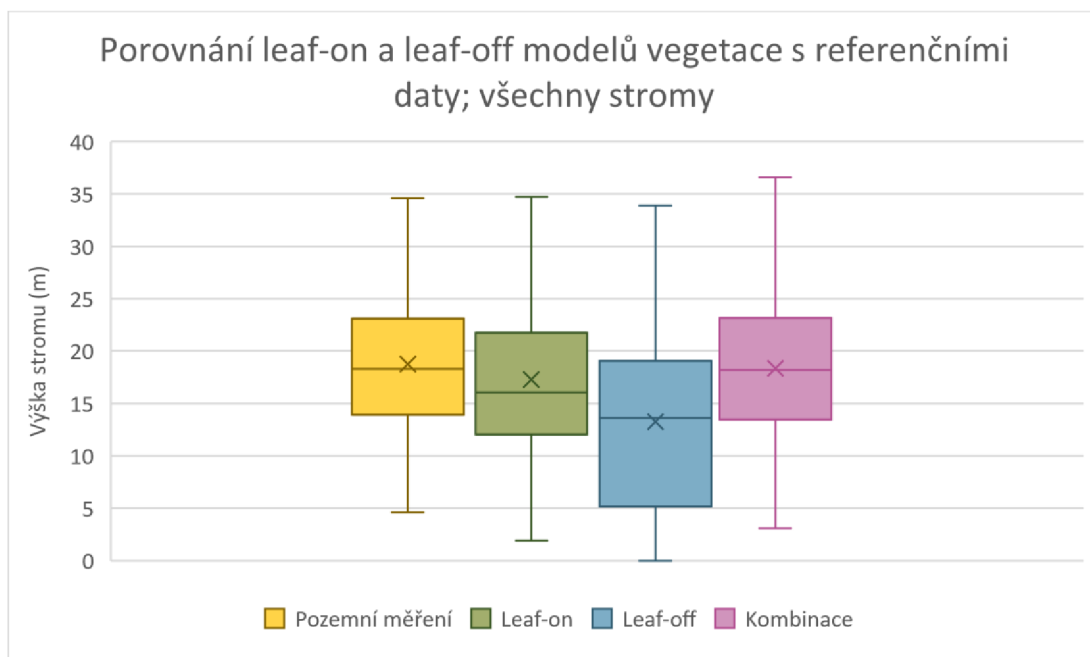
YU, Tianyu; NI, Wenjian; LIU, Jianli; ZHAO, Ruiqi; ZHANG, Zhiyu et al., 2023. Extraction of tree heights in mountainous natural forests from UAV leaf-on stereoscopic imagery based on approximation of ground surfaces. Online. *Remote Sensing of Environment*. Roč. 293. ISSN 00344257. Dostupné z: <https://doi.org/10.1016/j.rse.2023.113613>.

Zákon č. 13/1997 Sb. Zákon o pozemních komunikacích (autorský zákon). In: *Zákony pro lidi* [online]. AION CS, 2010-2024. Dostupné z: <https://www.zakonyprolidi.cz/cs/1997-13>


Zákon č. 266/1994 Sb. Zákon o dráhách (autorský zákon). In: *Zákony pro lidi* [online]. AION CS, 2010-2024. Dostupné z: <https://www.zakonyprolidi.cz/cs/1994-266>.

10 Přílohy


Příloha 1: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro všechny stromy




Příloha 2: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro lokalitu Veselka




Příloha 4: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro lokalitu Neratovice




Příloha 3: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro lokalitu Loučeň




Příloha 5: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro jehličnaté druhy stromů



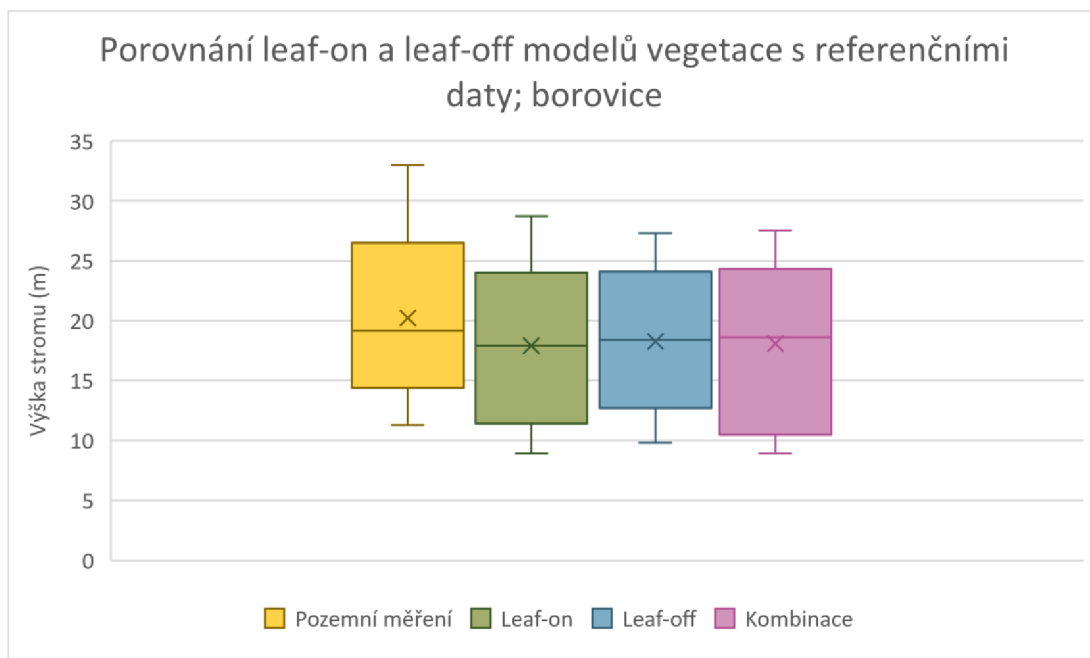
Příloha 6: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro listnaté druhy stromů




Příloha 7: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro smrk



Příloha 8: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro borovice



Příloha 10: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro dub



Příloha 9: Boxplot porovnávající hodnoty výšek stromů pro pozemní měření, leaf-on, leaf-off a jejich kombinaci pro ostatní listnaté druhy stromů

