

Z – OVĚŘENÁ TECHNOLOGIE

HODNOCENÍ NADZEMNÍ BIOMASY DŘEVINNÉHO PATRA LESNÍCH EKOSYSTÉMŮ PLOŠNÝM PŘÍSTUPEM

Technická dokumentace výsledku – Popis technologie, popis způsobu testování a
testovací protokol

Autorský kolektiv:

Ústav výzkumu globální změny AV ČR, v.v.i., Oddělení dálkového průzkumu Země

Ing. Olga Brovkina, CSc; Ing. Jan Novotný, Ph.D.; Ing. Barbora Navrátilová; Ing. Jan Hanuš.

IFER – Ústav pro výzkum lesních ekosystémů, s.r.o.

doc. Ing. Emil Cienciala, Ph.D.; Ing. et Ing. Jan Albert.

PODĚKOVÁNÍ:

Tato ověřená technologie byla zpracována v rámci řešení projektu Programu aplikovaného výzkumu Ministerstva zemědělství na období 2017–2025, ZEMĚ „Průběžné hodnocení nadzemní biomasy dřevinného patra lesních ekosystémů pomocí pokročilých metod dálkového průzkumu Země“ (č. projektu QK1910150).

Smlouva o uplatnění ověřené technologie byla uzavřena se Stora Enso Wood Products
Ždírec s.r.o., dne 26.9.2022

RECENZOVALI:

Ing. Tomáš Čihák, Ph.D., Výzkumný ústav lesního hospodářství a myslivosti v.v.i.

doc. Ing. Peter Surový, Ph.D., Česká zemědělská univerzita v Praze

Ústav výzkumu globální změny AV ČR, v.v.i.

Hodnocení nadzemní biomasy dřevinného patra lesních ekosystémů plošným přístupem

Brno 2022

ISBN: 978-80-263-1737-1

OBSAH

1	Shrnutí	4
2	Úvod. Potřebnost a využití ověřené technologie	4
3	Technologie pro hodnocení lesní nadzemní biomasy pomocí plošného přístupu	7
3.1	Definice plošného přístupu	7
3.2	Data leteckého laserového skenování pro plošný přístup	8
3.3	Typ terénních dat pro plošný přístup	12
3.4	Modelování biomasy postupy strojového učení	19
4	Testování technologie	21
4.1	Lesní plocha Těšínské Beskydy	21
4.2	Lesní plocha Ždírec nad Doubravou	27
5	Ekonomické aspekty použití ověřené technologie	36
6	Závěr	39
	Seznam zkratk	40
	Použitá literatura	41

1 Shrnutí

Dokumentace ověřené technologie zahrnuje Úvod, tři tematické kapitoly a Závěr. Dále seznam zkratk a seznam referencí.

Úvod se zaměřuje na potřebnost technologie pro odhad dřevinné nadzemní biomasy v podmínkách lesních porostů České republiky a střední Evropy.

Kapitola 3 popisuje technologii odhadu nadzemní biomasy lesních porostů pomocí plošného přístupu, konkrétně zahrnuje definici plošného přístupu, popis potřebných dat leteckého laserového skenování, doplňková pozemní data a proces modelování metodami strojového učení.

Kapitola 4 ilustruje technologický postup vývoje a aplikaci modelu pro zájmové území Těšínských Beskyd a ověření modelu pro zájmové území Ždírec nad Doubravou.

Kapitola 5 porovnává časové nároky odhadu nadzemní biomasy lesních porostů klasickou cestou pozemní inventarizace a plošným přístupem z dat leteckého laserového skenování.

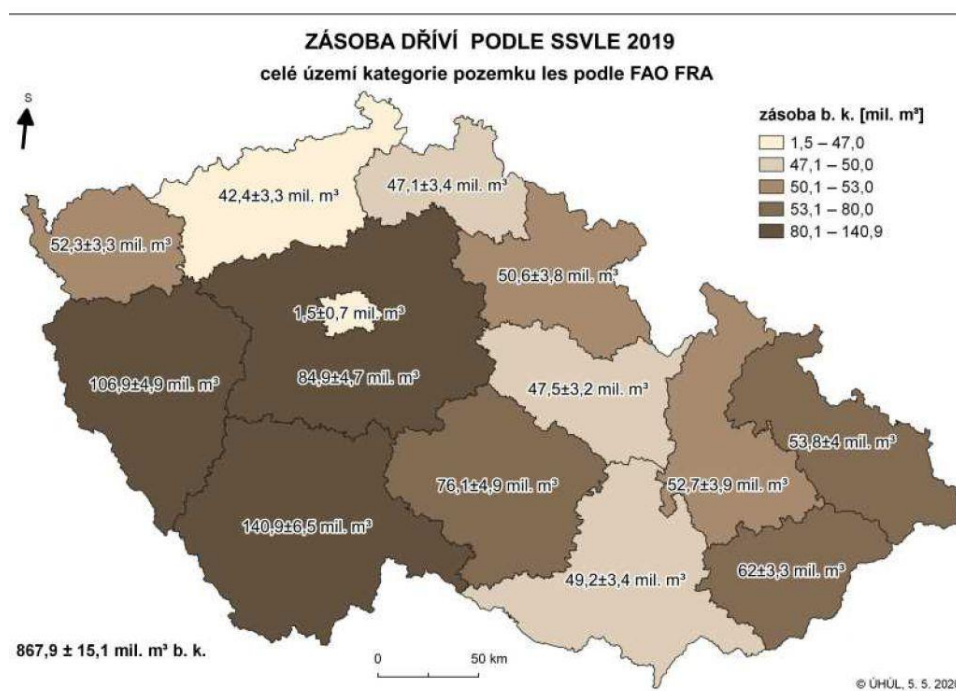
Závěr rekapituluje zásadní poznatky a dílčí prvky technologie a doplňuje doporučení pro její využití v praxi.

2 Úvod. Potřebnost a využití ověřené technologie

Odhad množství nadzemní biomasy dřevinného patra lesních ekosystémů (dále jen biomasy) je klíčový pro udržitelné lesní hospodaření a pro lepší pochopení příspěvku lesních ekosystémů v globálním uhlíkovém cyklu. Mapy biomasy, v jejich plošném zobrazení, jsou také důležitým údajem pro mitigační strategie, které reagují na změny klimatu. Nadzemní biomasa je definována jako množství živé či mrtvé hmoty stromového a křovinného patra a vyjadřuje se nejčastěji v jednotkách hmotnosti na plochu, například v tunách na hektar (Duncanson et al. 2021). Odhad biomasy se využívá ke stanovení změn zásob uhlíku uloženého v lese nejčastěji aplikací převodního koeficientu 0.5 (50 % obsah uhlíku v sušině) nebo přesněji podle kategorií dřevin (Martin et al. 2011, Petersson et al. 2012).

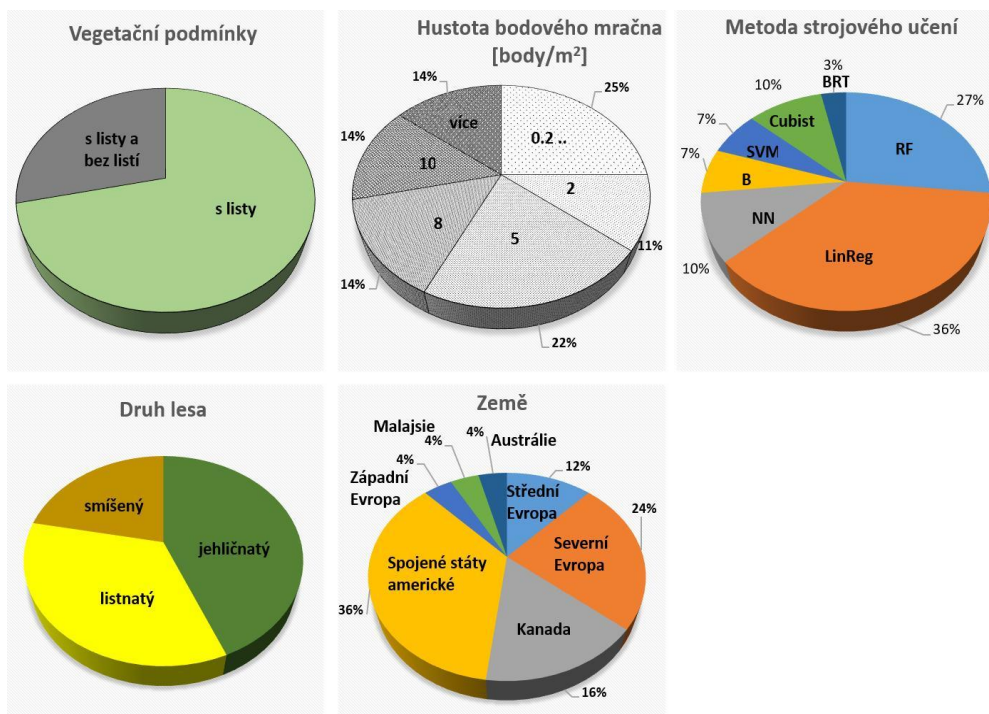
Biomasa může být odhadována pomocí vzorkovacích postupů, které bývají destruktivní nebo nedestruktivní. Destruktivní postupy se obecně používají pouze pro sestavení tzv. alometrických rovnic jednotlivých druhů dřevin, a to na základě destruktivního vzorování jednotlivých stromů. Tyto rovnice pak představují empirické vztahy pro kvantifikaci nadzemní biomasy na bázi měřitelných parametrů, jako je výčetní tloušťka a výška stromu. Je evidentní, že destruktivní vzorkování všech stromů v konkrétní lokalitě by bylo nepraktické a nereálné z hlediska vysokých nákladů takového postupu (Henry et al. 2010). Z těchto důvodů se odhady biomasy lesních ekosystémů lokálním a regionálním měřítku

provádí na bázi výběrového šetření lesnických inventarizací (např. Kučera a Adolt 2019) a zobecněných alometrických rovnic. V České republice je typicky odhadována zásoba dříví (v kubických metrech hroubí), a to pro jednotlivé regiony a pro jednotlivé druhy dřevin (smrk, borovice, další jehličnaté a listnaté druhy) (Obr. 1). Na úrovni operativního lesnictví se pak běžně používají robustnější, ale méně přesné odhady zásob na porostní úrovni pro lesní hospodářské plánování. Plošné mapování biomasy v detailu porostních celků není v české lesnické praxi dosud využíváno.



Obrázek 1. Odhady zásob dříví v roce 2019 (zdroj: Ústav pro hospodářskou úpravu lesů (ÚHÚL), <http://www.uhul.cz/kdo-jsme/aktuality/974-zasoby-drivi-v-roce-2019>)

Letecké laserové skenování (airboren laser scanning, ALS) je postup dálkového průzkumu, který je stále častěji využíván v teoretických i praktických úlohách lesnické praxe (Maltamo et al. 2014). Zpracováním dat ALS lze posuzovat biomasu (a další veličiny) efektivně, a to v kvalitě srovnatelné s klasickou pozemní inventarizací (Melville et al. 2015, Noordermeer et al. 2019, Novotný et al. 2021). Pro modelování biomasy se nejčastěji používá tzv. plošný přístup (ABA - area based approach) (White et al. 2013, Brubaker et al. 2018, Pears et al. 2019, Davison et al. 2020). V literatuře je popsána řada postupů, jak analyzovat vztah mezi biomasou a metrikami z dat ALS, pro různé podmínky a parametry skenování, strukturu a typ lesa, různými metodami strojového učení (Obr. 2).

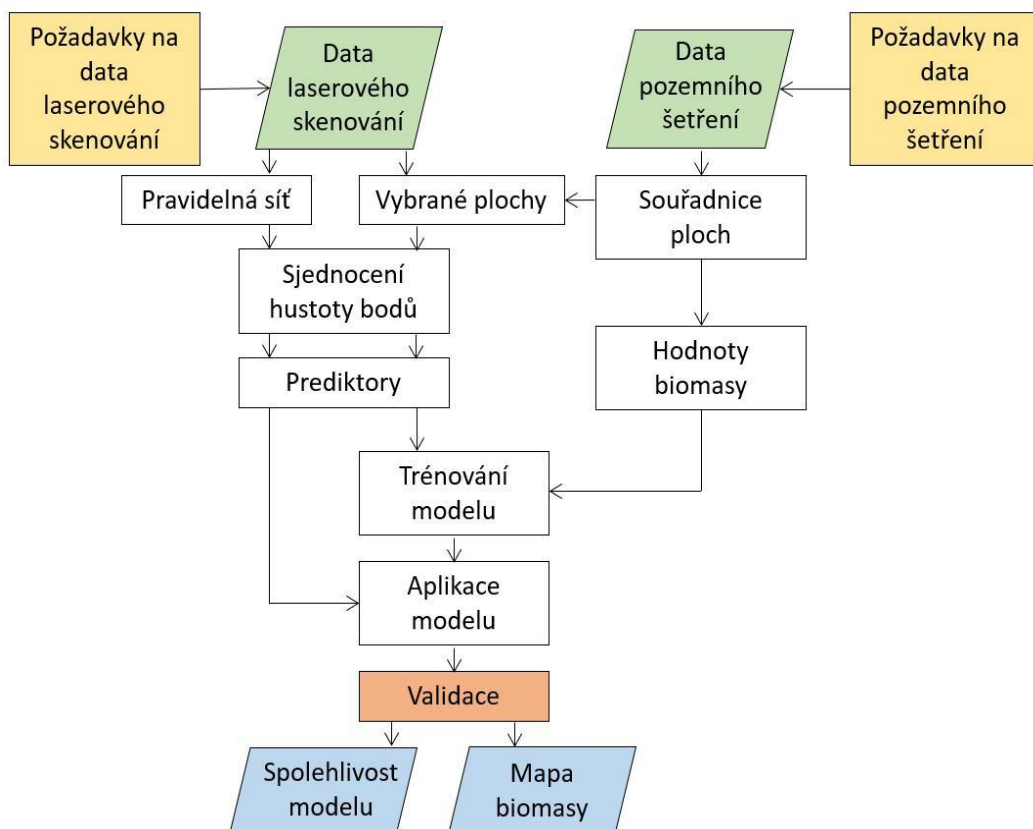


Obrázek 2. Shrnutí klíčových charakteristik nedávných studií pro odhad lesní nadzemní biomasy z dat leteckého laserového skenování (ALS) plošným přístupem. B = Bayesian model, BRT = boosted regression trees, LinReg = linear regression, ML = machine learning, NN = neural network, RF = random forest, SVR = support vector regression, Cubist[®] = komerčně dostupný rule-based software (Walton 2008).

Jakkoliv je plošný přístup k odhadování biomasy předmětem výzkumu již déle než 30 let (Naesset 2002, Nelson 2013, White et al. 2017), využití v lesnické praxi ve středoevropském prostoru je dosud zanedbatelné v porovnání se zkušenostmi ze Skandinávie (např. Naesset 2005, Villika et al. 2012, Kankare et al. 2013, Bouvier 2015), Kanady (např. White et al. 2015, Tompalski et al. 2019) a USA (např. Anderson et al. 2013, Blackburn et al. 2021) (Obr. 2). Jen několik autorů se zabývalo středoevropskými lesy a plošným odhadem biomasy z ALS dat (Patočka et al. 2016, Hawryto et al. 2017, Parkitna et al. 2021), přičemž studie Patočky je jediná autorům známá, která řeší plošný odhad biomasy v lesích v České republice. Chybí tak praktická doporučení, jak tento zavedený postup v kontextu českého lesnictví používat, ať už se jedná o nastavení parametrů pořizování dat, období pro pořízení leteckých dat, postupu pro sběr pozemních dat, či algoritmů modelování. Tato technologie si klade za cíl na výše uvedené otázky odpovědět, byla vyvinuta a ověřena pro podmínky českého lesnictví.

3 Technologie pro hodnocení lesní nadzemní biomasy pomocí plošného přístupu

Technologický postup odhadu nadzemní biomasy lesa má tři základní fáze: pořízení a předzpracování leteckých a pozemních dat, modelování biomasy plošným přístupem a validování výsledné mapy. Klíčové dílčí prvky úspěšné implementace jsou především naplnění požadavků z hlediska kvality vstupních dat, pečlivá příprava trénovací databáze pro modelování a vyhodnocení věrohodnosti modelů (Obr. 3).




Obrázek 3. Schéma technologie pro hodnocení lesní nadzemní biomasy.

3.1 Definice plošného přístupu

Základní princip plošného přístupu vychází z předpokladu, že bodové mračno získané laserovým skenováním nese informaci o 3D struktuře terénu a všech vegetačních vrstev nad ním. Body vegetace a jejich výška jsou využity ke kvantifikaci specifických metrik, mezi které patří veličiny popisné statistiky (průměr, kvantily, ad.) a veličiny související s hustotou mračna, respektive s prostupností korunové vrstvy. Všechny tyto informace, v kombinaci s pozemním šetřením o vysvětlované proměnné (biomase), jsou podkladem

pro sestavení predikčních modelů (Naesset 2002, Vastaranta et al. 2013, Maltamo et al. 2014) (Obr. 4). Hlavním přínosem modelování z leteckých dat je velkoplošná predikce, která je na úrovni porostního celku logicky kvalitnější než extrapolace z jednotlivých inventarizačních ploch.



Obrázek 4. Hlavní součásti plošného přístupu hodnocení biomasy.


3.2 Data leteckého laserového skenování pro plošný přístup

V této podkapitole budou rozebrány obvyklé parametry bodového mračna potřebné pro technologický postup a jednotlivé kroky přípravy dat.

3.2.1 Parametry bodového mračna

Základním předpokladem plošného odhadu biomasy je pokrytí zájmového území leteckým laserovým skenováním. Dle závěrů uvedených v Brovkina et al. (2022, v revizi) a dalších studiích je pro tuto technologii ideální bodová hustota mračna okolo 7 bodů na m^2 , nicméně, použitelná je i bodová hustota od 2 bodů na m^2 (Obr. 5).

Brovkina et al. (2022) také uvádí, že pro kvalitu modelů není zásadní roční období pořízení leteckých dat. Nicméně, v závislosti na druhovém složení v zájmovém území a cílové veličině (hroubí vs. kompletní nadzemní biomasa) může být vhodnější pořídit data v období s olistěním nebo bez olistění dřevin.




Obrázek 5. Výřez z bodového mračka o měnící se hustotě.

3.2.2 Příprava leteckých dat pro modelování

První krokem zpracování dat je dekompozice vln a geometrické korekce na základě trajektorie letadla. Tato fáze je specifická dle typu zařízení a provádí se v software od výrobce laserového skeneru. Základním vstupem pro tuto technologii je sesazené bodové mračno celého zájmového území ve formátu LAS.

Ve druhém kroku je třeba dosáhnout následujícího: odstranit z mračka šumové body (pokud je obsahuje), klasifikovat body mračka na terén, budovy, vyšší vegetaci a ostatní (nebo minimálně na terén a ostatní) a přepočítat Z-souřadnici bodů z výšky nadmořské na výšku nad terénem. K tomu je možné využít řadu algoritmů a softwarových řešení, například balík skriptů lastools (<http://lastools.org/>). Ukázka ilustrující tuto část postupu je na Obr. 6.



Obrázek 6. Ilustrace klasifikace bodového mračna a přepočtu na výšku nad terénem. V horní části je zobrazen řez mračnem v jeho původní podobě, kdy Z-souřadnice odpovídá nadmořské výšce, a tedy vidíme, že les a chatky stojí v mírném svahu. Body mračna jsou obarveny podle pořadí odrazu v rámci jednoho laserového pulzu. Je tak zdůrazněn fakt, že tam, kde se laserový paprsek odráží od pevných povrchů (střecha, louka), odráží se jednou, zatímco v porostu lesa dochází v rámci jednoho vystřeleného paprsku k odrazům vícenásobným. Ve spodní části je zobrazen stejný řez mračnem po zpracování, kdy Z-souřadnice odpovídá výšce nad terénem. Jednotlivé body jsou obarveny podle zařazení do tříd: hnědá = terén, zelená = vyšší vegetace, červená = budovy, šedá = nezařazené body nad terénem.

Teoretickým východiskem plošného přístupu je vztah mezi hodnotou inventarizační veličiny (nadzemní biomasy) a statistickými veličinami popisujícími strukturu lesa prostřednictvím bodového mračna. Tyto veličiny v dalším textu nazýváme prediktory.


Pro fázi trénování modelu jsou klíčové zjištěné hodnoty biomasy z terénu (in situ), které jsou vázané ke konkrétnímu místu (souřadnice X a Y) a jeho určitému okolí. V dalším kroku předpokládáme, že základní jednotkou pozemního šetření i plošného přístupu je kruhová

plocha o výměře 500 m². Nicméně, z metodického pohledu lze postup snadno upravit pro jiné, analogické situace.

Při aplikaci modelu nejčastěji pracujeme s pravidelnou bodovou sítí zvoleného prostorového kroku (například 20 metrů), kdy souřadnice jednotlivých bodů plní stejnou roli jako souřadnice ploch pozemního šetření ve fázi trénování. V níže popsaných krocích nebudeme tyto dvě situace rozlišovat.

Okolo souřadnic X-Y vytyčujeme kruhový buffer o poloměru 12,61 m a vybíráme z bodového mračka podmnožinu bodů, které leží uvnitř. Ukázka získaného dílčího mračka je na Obr. 5.

V pokrytí většího zájmového území mozaikou jednotlivých letových linií běžně dochází k nehomogenitě bodového mračka ve smyslu jeho hustoty. Nechceme-li, aby tento jev vnášel nehomogenitu též do vypočítávaných prediktorů, doporučuje se sjednocení hustoty na dílčích výřezech mračka. To provádíme tak, že z mračka náhodně vypustíme vhodné množství bodů tak, aby počet takzvaných prvních odrazů (které odpovídají počtu vyslaných laserových pulzů) byl pro všechna dílčí mračka totožný. (Například 2500, což odpovídá hustotě 5 pulzů/m² pro kruh 500 m².) Body dílčího mračka (po sjednocení hustoty nebo bez něj) jsou vstupem pro výpočet prediktorů. Ukázka ilustrující tuto část postupu je na Obr. 7.



Obrázek 7. Ilustrace rozmístění dílčích výřezů bodového mračka pro fázi trénování (vlevo) a pro fázi aplikace (vpravo). Naznačené kruhy mají plochu 500 m², v pravém panelu jsou rozmístěny v pravidelné síti s krokem 20 m. Podkladem je model korunové výšky (*canopy height model*), který v odstínech šedi zobrazuje výšku porostu.

Dostupná literatura k problematice plošného přístupu doporučuje řadu statistických veličin, které charakterizují (dílčí) bodové mračko, jeho strukturu, a které mají vztah k nadzemní biomase. Bodové mračko je vnímáno jako statistický soubor hodnot výšky

jednotlivých bodů nad terénem, nad ním počítáme charakteristiky polohy (průměr, medián, kvantily) a charakteristiky variability (směrodatná odchylka a vyšší statistické momenty). Specifikem laserového skenování lesa jsou pak charakteristiky propustnosti počítané nejčastěji jako poměr počtu bodů prostřelených pod určitou výšku vůči počtu všech bodů.

Do výše popsaného výpočtu většinou vstupuje část mračna, která odpovídá cílové veličině, jejíž biomasu řešíme. Může se jednat například o všechny body klasifikované jak nad-terénní, nebo všechny body, jejichž Z souřadnice (výška) překračuje stanovený minimální práh (například 1,3 m).

Všechny napočítané prediktory jsou pro fázi trénování spárovány s pozemní hodnotou cílové veličiny a vstupují do procesu strojového učení, který popisuje kapitola 3.4. Specifické otázky redukce počtu prediktorů se věnuje odstavce 3.4.1. Pro fázi aplikace modelu jsou relevantní prediktory vstupem, z něhož je vypočítána cílová veličina pro každý uzel pravidelné sítě.

V úvodu této kapitoly byla zmíněna klasifikace bodového mračna na jednotlivé třídy. (Viz též Obr. 6) Body třídy *terén* jsou nezbytným předpokladem pro výpočet výšky nad terénem. Klasifikace dalších tříd - vyšší vegetace a budovy - může (a nemusí) být využita jako pomocná informace, kdy například pouze body třídy *vyšší vegetace* bereme do výpočtu prediktorů, nebo naopak uzly pravidelné sítě, v jejichž okolí se vyskytuje nadlimitní množství bodů třídy *budovy*, vyřazujeme z modelování, protože se nejedná o les.

3.3 Typ terénních dat pro plošný přístup


Měřená terénní data slouží jako kalibrační a validační materiál pro odhady nadzemní biomasy pomocí produktů dalkového průzkumu Země (DPZ). Pro kvantifikaci nadzemní biomasy jsou využívány klasické postupy statistické lesní inventarizace, které jsou založena na plošné extrapolaci údajů sítě inventarizačních ploch (Tomppo et al. 2010). Inventarizační plochy mohou mít různý tvar a uspořádání, nejčastější jsou přitom kruhové koncentrické plochy (viz níže), které se využívají v národních inventarizacích lesních ekosystémů země v boreálním, mírném i tropickém vegetačním pásmu (Tomppo et al. 2010). Nadzemní biomasu nelze v přímo měřit – kvantifikuje se na základě měřitelných údajů lesních porostů, které vstupují do empirických modelů pro kvantifikaci objemu hroubí nebo přímo nadzemní biomasy a jejich jednotlivých komponentů. Cílovým produktem je hodnota nadzemní biomasy vyjádřená na plochu, tj. nejčastěji tunách sušiny na hektar. Variantními postupy kvantifikace nadzemní biomasy podle typu vstupních údajů se detailně věnuje Somogyi et al. (2007).

Vlastní sběr dat v terénu využívá běžné lesnické metodami s využitím moderní měřičské technologie. Vhodným nástrojem pro komplexní sběr a vyhodnocení inventarizačních dat lesa je technologie Field-Map (např. Cienciala et al. 2017, www.field-map.com). Kruhové plochy se v zájmovém území rozmístí tak, aby výsledkem byl statisticky reprezentativní náhodný výběr. Území lze stratifikovat dle věkových tříd či typu lesa a tím dosáhnout rovnoměrnějšího pokrytí škály porostů. Mohou být využity stávající trvalé inventarizační plochy nebo být založeny plochy dočasné.

3.3.1 Tvar a velikost inventarizačních ploch

Všechny inventarizační plochy mají kruhový tvar s poloměrem $r = 12,62 \text{ m}$ (500 m^2). Pro optimalizaci terénního šetření je pro měření slabších stromů využíván soustředný kruh o poloměru 7 m , na kterém se měří všechny stromy od výčetní tloušťky 7 cm . Na celé ploše se pak měří stromy s výčetní tloušťkou 12 cm a více.

Pro měření obnovy (stromy od výšky 0.1 m do výčetní tloušťky 6.9 cm) se využívá kruh o poloměru 2 m , který je umístěný 7 m na sever od středu plochy (Obr. 8). Lesní obnova je pro svůj zanedbatelný kvantitativní příspěvek často opomíjena pro verifikaci a validaci údajů nadzemní biomasy pomocí produktů DPZ, ale pro dynamiku ekosystému a lesnickou praxi je významnou informací.



Obrázek 8. Schéma inventarizační plochy se soustřednými kruhy

Praktický postup založení a měření inventarizační plochy sestává z několika na sebe bezprostředně navazujících kroků (Tab. 1). Prvním krokem je vyhledání středu inventarizační plochy a jeho zabezpečení. Následuje samotný popis plochy, měření a popis jednotlivých objektů. Všechna měřená a popisná data jsou posílána a zapisována do

terénní aplikace Field-Map Data Collector. Pro zvýšení kvality dat je nezbytnou činností před odchodem z inventarizační plochy její kontrola (kontrola zaplněnosti databáze a grafická kontrola výšek).

Tabulka 1. Postupové kroky založení a měření inventarizační plochy

Dílčí činnosti
Vyhledání středu inventarizační plochy
Zabezpečení středu inventarizační plochy
Měření a popis stromů
Popis obnovy
Kontrola databáze

Vyhledání středu inventarizační plochy

Při vyhledávání středu inventarizační plochy v terénu se používá satelitní navigace GNSS (Global Navigation Satellite System) a pod korunovým zápojem, kde je přesnost GNSS nižší, je možné použít navigaci laserovým dálkoměrem, kombinující elektronický kompas. K navigaci do blízkosti inventarizační plochy se využijí existující mapové podklady a letecké snímky.

Zabezpečení středu inventarizační plochy

Střed každé inventarizační plochy se v terénu musí zajistit tak, aby jej bylo možno zpětně dohledat (při opakovaném nebo kontrolním šetření). K tomu se používají tzv. označené body, které leží mimo inventarizační plochu a které jsou přesně zaměřeny ze středu plochy. Zpětným měřením od označeného bodu je tak možné rychle a přesně dohledat původní střed plochy. Jako označené body se nejčastěji používají stromy, které jsou v porostu výrazné (např. málo zastoupená dřevina, dominantní strom apod.). Označený bod se v terénu zvýrazní ekologickou barvou (v případě stromu ve výšce očí a na kořenových náběžích).

Popis základních charakteristik inventarizační plochy

Základní informace o inventarizační ploše se zapisují do vrstvy „Plochy“ (Tab. 2).

Tabulka 2. Atributy vrstvy „Plocha“

Název atributu	Typ pole	Jednotky
Identifikační číslo inv. plochy	číslo	-
Souřadnice středu plochy	číslo	m
Magnetická deklinace	číslo	stupeň
Datum měření	datum	-
Zodpovědný pracovník	text	-
Poznámka	text	-

3.3.3 Měření a popis stromů

Veškerá měření a popisy se uskuteční jen na stromech, jejich střed kmene ve výčetní výšce se v okamžiku šetření nachází na inventarizační ploše a které v jednotlivých inventarizačních kruzích překročily stanovenou hranici pro měření (Tab. 3).

Tabulka 3. Parametry inventarizačních kruhů

Poloměr inventarizačního kruhu (m)	Rozloha inventarizačního kruhu (m ²)	Výčetní tloušťky stromů měřené na jednotlivých inventarizačních kruzích
2.00	12.6	Stromy od 0.1 m výšky do 6.9 cm sk. (obnova)
7.00	153.9	Stromy s výčetní tloušťkou $\geq 7,0$ cm s kůrou
12.62	500.0	Stromy s výčetní tloušťkou $\geq 12,0$ cm s kůrou


Princip inventarizačních kruhů představuje značnou úsporu času při vlastním venkovním šetření. Díky tomuto uspořádání se vyšetří znaky stromů všech velikostí, které se na ploše nacházejí, přitom ale dojde k výraznému snížení pracnosti při měření slabých stromů a obnovy. Velikost soustředných kruhů lze upravit při úpravě navázaných kroků a přepočtů na celkovou velikost plochy.

Na jednotlivých stromech s minimální výčetní tloušťkou 7 cm se zjišťují a měří parametry uvedené v Tab. 4.

Tabulka 4. Atributy vrstvy „Stromy“

Název atributu	Typ pole	Jednotky	Hodnoceno / nehodnoceno	
			Živý strom	Stojící souš
Identifikační číslo stromu	číslo	-	ano	ano
Pozice stromu (X, Y, (Z) nebo polární souř.)	číslo	m	ano	ano
Výčetní tloušťka	číslo	mm	ano	ano
Výška stromu*	číslo	m	ano	ne
Dřevina	číselník	-	ano	ano
Věk stromu	číslo	roky	ano	ano
Dvoják	číselník	-	ano	ne
Souše	číselník	-	ano	ano
Zlom kmene	číselník	-	ano	ne

* ... pouze na vybraných vzorníkových stromech



Obrázek 9. Měření pozice stromů na inventarizační ploše s příkladem pravidel pro zaujaté stromy dle pozice a výčetní tloušťky

Technologie a technické postupy měření atributů šetřených stromů na inventarizační ploše vycházejí z metodických standardů měření lesnické inventarizace (Černý et al. 2010).

3.3.4 Popis obnovy (pokud je součástí metodických požadavků)

Na každé ploše se hodnotí obnova na tzv. obnovním kruhu ($r = 2.0$ m o rozloze $12,57$ m²). Protože se při mapování a měření velkých stromů pracovníci pohybují nejvíce ve středu inventarizační plochy, je umístění obnovního kruhu situováno 7 m na sever od tohoto středu plochy. Hodnocení obnovy se týká všech jedinců obnovy porostu od výšky 0.1 m až po stromky s výčetní tloušťkou 6.9 cm s kůrou.

Jestliže se na obnovním kruhu nenachází žádný jedinec od 0.1 m výšky do výčetní tloušťky 6.9 cm s kůrou, pak se obnova na ploše nehodnotí, a to ani v případě, že by se jedinci výše uvedených rozměrů nacházeli v samé blízkosti obnovního kruhu.

Základem pro hodnocení obnovy na obnovním kruhu je zařazení jedinců obnovy do tzv. výškových tříd obnovy, které jsou definovány výškou stromku a dřevinou. Pro jednotlivé třídy obnovy se pak určuje počet jedinců v této třídě, druh dřeviny, věk, průměrná výčetní tloušťka a průměrná výška.

Tabulka 5. Atributy vrstvy Obnova

Název atributu	Typ pole	Jednotka
Výšková třída obnovy	číselník	-
Dřevina	číselník	-
Počet jedinců	číslo	ks
Průměrný věk	číslo	Roky
Průměrná tloušťka	číslo	Cm
Průměrná výška	číslo	m

Jedinci obnovy každé dřeviny, kteří se nacházejí na obnovním kruhu, se pro sledování parametrů obnovy podle své výšky zařadí do následujících výškových tříd.


1. Výška od 0.1 m do 0.5 m
2. Výška od 0.5 m do 1.3 m
3. Výška od 1.3 m výšky do výčetní tloušťky 6.9 cm s kůrou.

3.3.5 Vyhodnocení měření a výpočet biomasy

Po sběru dat v terénu následuje vyhodnocení dat pro jednotlivé inventarizační plochy. Vhodným nástrojem pro vyhodnocení sebraných dat může být aplikace Inventory Analyst, která je součástí technologie Field-Map (www.field-map.com).

Pro výpočty biomasy je nutné znát pro všechny zahrnuté stromy jejich výčetní tloušťku a výšku. Z důvodu redukovaného měření výšek pouze na vzorníky je nutné dopočítat modelovou výšku pro všechny stromy. Příkladem může být parametrizace

exponenciálního modelu ve výškovém grafikonu (Obr.10). Nejpřesnějšího výsledku se dosáhne parametrizací výškového modelu na úrovni skupiny dřevin a jednotlivé inventarizační plochy.



Obrázek 10. Příklad výškového grafikonu s proloženou modelovou výškou a parametry exponenciálního modelu. Modré body: výšky změřené v terénu, žluté body: dopočítané modelové výšky.

Následuje výpočet nadzemní biomasy dle publikovaných alometrických vztahů (Tab. 6) s využitím změřené výčetní tloušťky a vypočtené modelové výšky. Pro zaznamenané stromy s výčetní tloušťkou 7–12 cm z částečné plochy (soustředného kruhu) je nutné použít expanzní faktor, tedy přepočet na celou rozlohu inventarizační plochy dle poměru plochy soustředných kruhů. Konkrétně $153.94 \text{ m}^2 / 500 \text{ m}^2 = 3.25$.

Tabulka 6. Reference pro alometrické vztahy výpočtu biomasy dle skupin dřevin

Dřevina	Reference
Smrk (všechny druhy)	Vonderach a kol. 2018
Jedle	Vonderach a kol. 2018
Douglaska	Vonderach a kol. 2018
Borovice (všechny druhy)	Cienciala a kol. 2006

Dřevina	Reference
Modřín	Wirth a kol. 2004
Dub (všechny druhy)	Cienciala a kol. 2008
Javor klen	Vonderach a kol. 2018
Jasan	Vonderach a kol. 2018
Bříza	Bronisz a kol. 2016
Lípa	Čihák a kol. 2014
Olše	Johansson 2000
Buk a ostatní listnáče	Wutzler a kol. 2008

Nadzemní biomasu stromů s korunovým a silnějším zlomem je nutné dle jeho výšky redukovat odpovídajícím koeficientem. Součtem hodnot biomasy všech dřevin na inventarizační ploše je tak možné získat souhrnnou nadzemní biomasu pro celou kruhovou plochu o velikosti 500 m². Pro následnou kalibraci a verifikaci s produkty DPZ je následně využíván specifický výběr souboru měřených údajů nadzemní biomasy jednotlivých inventarizačních ploch, a to podle zaměření studie a statistických požadavků kalibrace a/nebo verifikace.

3.4 Modelování biomasy postupy strojového učení

Prostorová informace z bodového mračka do procesu modelování vstupuje pomocí napočítaných statistických veličin - prediktorů, jejichž kombinaci vždy odpovídá hodnota biomasy stanovená dle pozemního šetření.

3.4.1 Redukce počtu prediktorů

Před samotným procesem tvorby modelu by měla proběhnout fáze redukce počtu prediktorů, které do modelování vstupují. Důvodem je zachování či posílení predikční schopnosti modelu odstraněním nadbytečných či méně přínosných informací vzhledem k vysvětlované veličině. Pro zachování co největší nezávislosti prediktorů vůči sobě lze provést prahování na základě vzájemné korelace. Další možností je využití metod založených na rekursivním výběru či uspořádání jednotlivých prediktorů vzhledem k jejich vzájemné F-hodnotě. Výběr vstupních prediktorů může být nezávislý na algoritmu strojového učení použitým při trénování.

3.4.2 Stratifikace datové sady

Pro samotné modelování je vhodné využít train/test přístupu. Datová sada je rozdělena na sadu určenou pro trénování a část na testování. Tímto rozdělením se úmyslně zúží

dataset, na kterém by se mohl model natrénovat, ovšem výhodou tohoto přístupu je schopnost nezávisle posoudit úspěšnost modelu na datech stojící zcela mimo proces trénování.

Pro co nejreprezentativnější zastoupení datasetu v obou uvažovaných setech přichází na řadu náhodné, ale stratifikované rozdělení vůči vysvětlované proměnné. Vycházíme-li čistě z informací, které nám může poskytnout bodové mračno, informaci jako je druhové složení neobdržíme, a tedy nám jako případný prediktor nebude figurovat, i přesto je vhodné druhové složení, máme-li tuto informaci z pozemního šetření, zahrnout minimálně do procesu stratifikace, aby bylo zajištěno, že případné trénování neproběhne pouze na jednom typu lesního porostu. Používaná varianta je jak na úrovni základní klasifikace listnatý/jehličnatý/smíšený, tak na základě převládajícího druhu (smrk/borovice). Další používanou a osvědčenou stratifikací je mimo zohlednění druhového složení zahrnutí atributu věk porostu. Je vhodné volit stratifikaci odpovídající lokálním podmínkám, případně promítnout do ní prvek, u kterého očekáváme, že na vysvětlovanou proměnnou může mít vliv.

Rozdělení do sad pro modelování je vhodné provést vícekrát. Mezi jednotlivými takto vzniklými modely, lze posoudit vliv tohoto rozdělení na výslednou predikci a případně odstranit model, jenž nezvládl podchytit a vhodně predikovat svou danou sadu.

3.4.3 Proces strojového učení

Pro samotné modelování lze použít přístupu parametrického či využít neparametrických metod. Z hlediska interpretace a pochopení základního vztahu mezi vysvětlovanou proměnou a danými prediktory je parametrický přístup vhodnější, ovšem klade větší požadavky na vstupní data. Menší nároky, ovšem horší interpretovatelnost sebou nese použití neparametrických metod, které dosahují z pravidla vyšší přesnosti predikce. V tomto případě se naskytuje i možnost kombinovat spojitě a kategorické proměnné vstupující do procesu učení.

Při využití metod strojového učení v procesu trénování, lze spoléhat na defaultní vnitřní nastavení parametrů metody, zvolit si nějaké konkrétní, případně určit množinu přípustných hodnot pro jednotlivé tzv. hyperparametry modelu a nechat si vybrat optimální nastavení těchto parametrů vzhledem k trénovací množině.

3.4.4 Výběr nejlepšího modelu a jeho aplikace

Z hlediska jedné metody dostaneme sadu potenciálních predikcí. Její velikost je dána počtem uvažovaných rozdělení na train/test sadu. Aby bylo možné z dané množiny vybrat ten nejlepší, který vysvětlovanou veličinu co nejlépe vystihuje, je potřeba stanovit kritérium či bodové ohodnocení modelu. V literatuře se nejčastěji vyskytuje ohodnocení

na základě R^2 , RMSE, Bias, případně jejich relativní forma. Lze i stanovit komplexnější ohodnocení, které bude součtem dílčích bodově ohodnocených charakteristik jako v případě (Brovkina a kol. 2022). Meze pro bodové ohodnocení jednotlivých charakteristik, případně prahové hodnoty, je žádoucí stanovit co nejvíce objektivně. Tuto záležitost by mohlo z části umožnit vymezení se na základě kvantilů vybraných charakteristik. Ze sady ohodnocených modelů můžeme poté vybrat ten „nejlepší“ nebo několik nejlepších a výslednou predikci mít danou jako průměr z tohoto výběru. Ač mohou být jednotlivé modely z hlediska bodového ohodnocení sobě blízká, jejich predikční schopnost se může na určitém typu porostu různit. Přístup daný predikcí na základě více modelů umožňuje k výsledné mapě přiložit i mapu rozdílnosti predikce jednotlivých modelů a tímto získat přehled, v jakých oblastech může být odchylka modelové hodnoty větší.

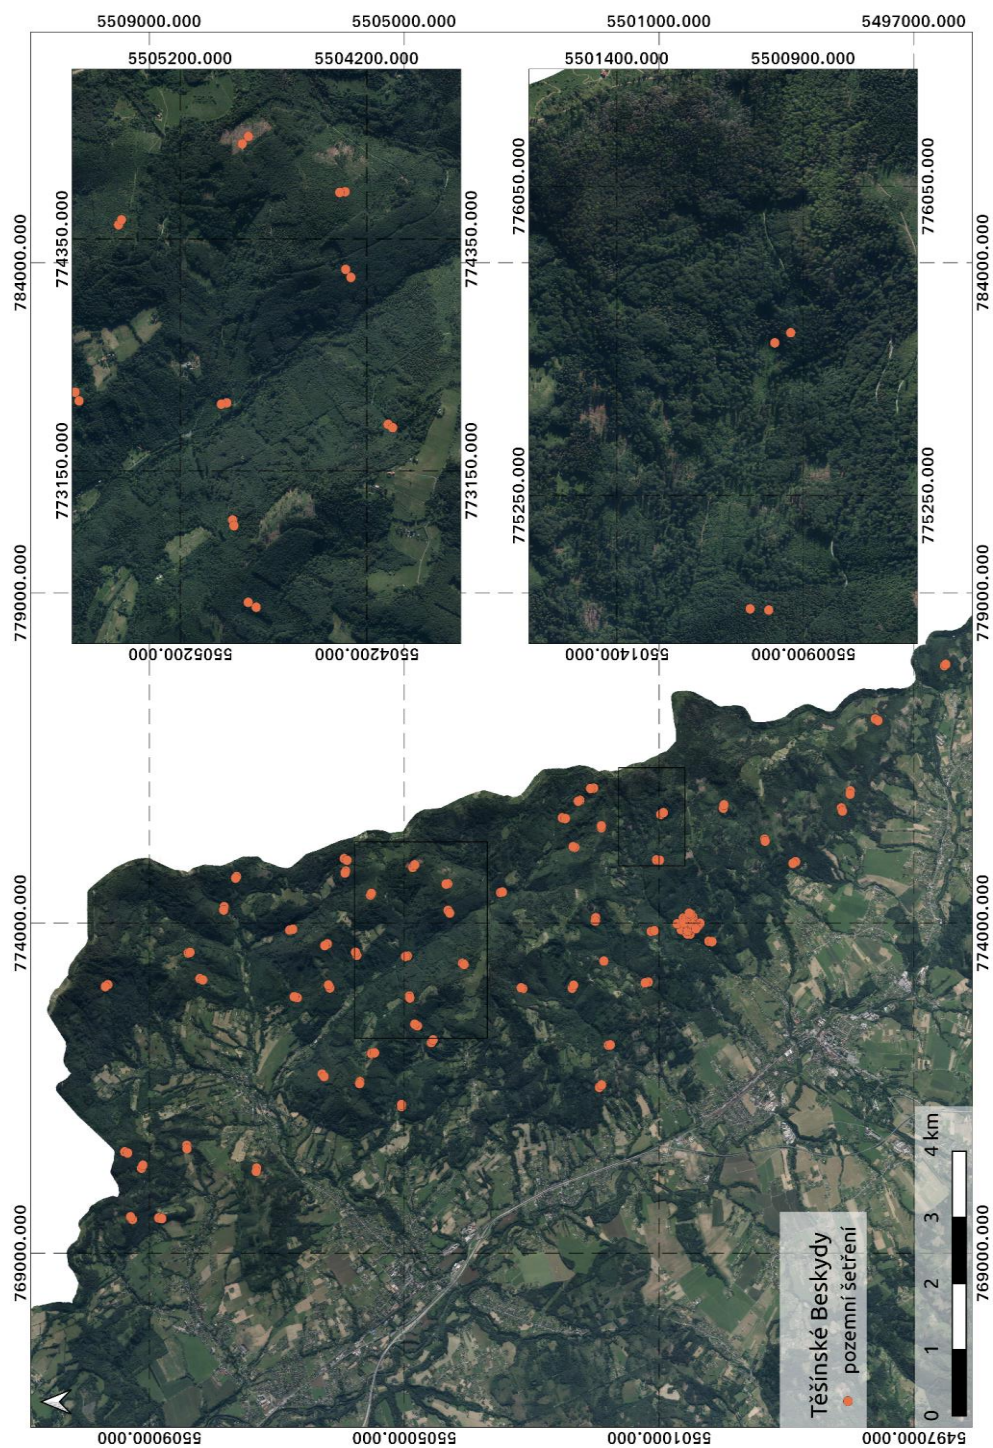
Aplikací modelu rozumíme výpočet hodnot biomasy na základě prediktorů napočítaných nejčastěji v pravidelné bodové síti, která může mít v principu libovolné prostorové rozlišení. Viz též výklad a ukázky v závěru odstavce 3.2.2. Aplikován může být jeden vybraný model, nebo několik modelů. V druhém případě lze generovat též mapu směrodatné odchylky dílčích modelů, která je aproximací nejistoty. Konkrétní ukázky představuje kapitola 4.

4 Testování technologie

Modely pro odhad biomasy byly vyvíjeny primárně v zájmovém území projektu (QK1910150), v lesních plochách Těšínských Beskyd. Technologie byla následně ověřena na lesních plochách v okolí města Ždírec nad Doubravou, na kterých hospodaří společnost Stora Enso (<https://www.storaenso.com/cs-cz/>).

4.1 Lesní plocha Těšínské Beskydy

Zájmové území v české části Těšínských Beskyd (49.6°N, 18.8°E) leží podél východních hranic České republiky v nadmořských výškách 500 až 900 metrů nad mořem (Obr. 11). Na ploše cca 4000 hektarů se rozkládají smíšené lesy středního pásma, s dominantním zastoupením smrku (*Picea abies* (L.) H. Karst) a buku (*Fagus sylvatica* L.), s další příměsí jedle (*Abies alba* Mill.), javoru (*Acer pseudoplatanus* L.), borovice (*Pinus sylvestris* L.), dubu (*Quercus sp.* L.), břízy (*Betula pendula* Roth) a několika dalších řídce zastoupených druhů.



Obrázek 11. Plochy pozemního šetření v území Těšínských Beskyd. (Podkladová mapa: Orthophoto TopGIS).

Pozemní data o stromech a jejich biomase byla shromážděna během vegetační sezóny v červenci 2019 na 109 vzorkovacích plochách s využitím technologie Field-Map tak, jak je popsáno v sekci 3.3. Modelová výška stromů byla dopočítána prostřednictvím exponenciální funkce fitované do měřených výšek vzorkových stromů. Nadzemní biomasa byla následně vypočítána z měřených veličin (DBH + výška / modelová výška) s využitím alometrických rovnic z literatury (Wirth et al. 2004; Cienciala et al. 2006, 2008; Wutzler et al. 2008; Vonderach et al. 2018).

Data leteckého laserového skenování byla pořízena 26. července 2019 prostřednictvím skeneru RIEGL LMS-Q780. Průměrná letová hladina byla 410 metrů nad terénem. Při frekvenci laseru na úrovni 400 kHz parametry akvizice vyústily v hustotu mračna dosahující až 15 bodů na metr čtvereční. Předzpracování těchto dat je popsáno v odstavci 3.2.2.

Pro eliminaci prediktorů byly vybrány tři metody. První z metod uspořádá jednotlivé prediktory vzhledem k jejich vzájemné F-hodnotě. Vybírá se pevně daný počet prediktorů s nejlepším ohodnocením. Další zvolená varianta se zabývá tzv. rekurzivním výběrem s křížovou validací. Odhad je založen na metodě support vector machine s lineárním jádrem. Minimální počet takto vybraných prediktorů je čtyři, horní hranice omezena není. Poslední uvažovaná možnost výběru je dána korelací s vysvětlovanou proměnnou. Tímto způsobem bylo obdrženo sedm prediktorů, pro body nad terénem: průměrná výška; kvantily Q30, Q70, pro body s prahem 2 m: směrodatná odchylka výšky, šikmost, propustnost P40, a oblast pokrytí korunou. Výběr vstupních prediktorů probíhal nezávisle na algoritmu strojového učení použitém při trénování.


Pro modelování bylo využito train/test přístupu. Datová sada byla stratifikovaně rozdělena na sadu určenou pro trénování (75%) a část na testování (25%). Stratifikace byla vedena vzhledem k typu lesního porostu a rovnoměrnému zastoupení biomasy. Dle poměrného zastoupení jehličnanů na měřené ploše jsme rozlišovali tři typy lesního porostu: ≥ 0.65 jehličnatý, ≤ 0.35 listnatý, zbytek je považován na smíšenou plochu.

Samotné modelování probíhalo v prostředí python za použití knihovny scikit-learn (Pedregosa a kol. 2011). Optimální nastavení hyperparametrů použitých metod probíhalo přes funkci GridSearchCV. Metoda Random Forest či metoda Multi-layer Perceptron vykazaly dobrou predikční schopnost.


Výběr nejlepších modelů byl proveden na základě více charakteristik. Kromě základních veličin typu R^2 (koeficient determinace, R kvadrát) a RMSE (střední kvadratická chyba, Root Mean Square Error), bylo zavedeno tzv. Class score a regression score. Úkolem Class score bylo ohodnocení z hlediska odchylky od pozemním šetřením získané hodnoty. Byla-li odchylka menší než 25t/ha, byl odhad ohodnocen tři body, s každými dalšími 25t/ha bylo

o bod méně. Výsledná hodnota class score byl průměr z jednotlivých ohodnocení. Regression score mělo za úkol zhodnotit náchylnost k diskretizaci hodnot modelem a dávalo do spojitosti počet unikátních hodnot predikce a pozemního šetření. Aby se předcházelo přetrénování modelu, nebyla připuštěna hodnota R^2 trénovací sady rovna jedné. Minimální (maximální) hodnota jednotlivých charakteristik byla stanovena na základě Q75 každé z veličin. Na takto vzniklé množině modelů proběhlo sestupné seřazení vzhledem ke class score, následně k R^2 a vztupně k RMSE. Prvních deset modelů bylo prohlášeno za konečný výběr. Model disponuje hodnotami $R^2 = 0.87$ na úrovni trénovací sady, $R^2=0.85$ na úrovni testovací sady, tedy můžeme považovat model za vyrovnaný a schopný predikovat s danou přesností danou oblast. Dále model charakterizují hodnoty RMSE = 54 t/ha, class score = 1.94. Na základě regression score lze model prohlásit za nenáchylný k diskretizaci predikce.


Pro zájmové území byla v pravidelném gridu s prostorovým rozlišením 10 m napočítána sada prediktorů, na kterou byly jednotlivé modely aplikovány. Případné záporné hodnoty predikce byly nahrazena hodnotou nula. Výsledná mapa je průměrem přes všechny vybrané predikce. Směrodatná odchylka tohoto produktu nám pak ilustruje, které části jsou náchylnější na větší nepřesnost a kde se naopak vybrané modely téměř shodnou. Z obrázku 12b je patrné, že problematickou část představují přechodové části - z výrazně nižšího porostu na vyšší, případně okrajové části lesa. Odchylka pro vyšší porost se pohybuje v rámci hodnot RMSE modelu.



a)



b)

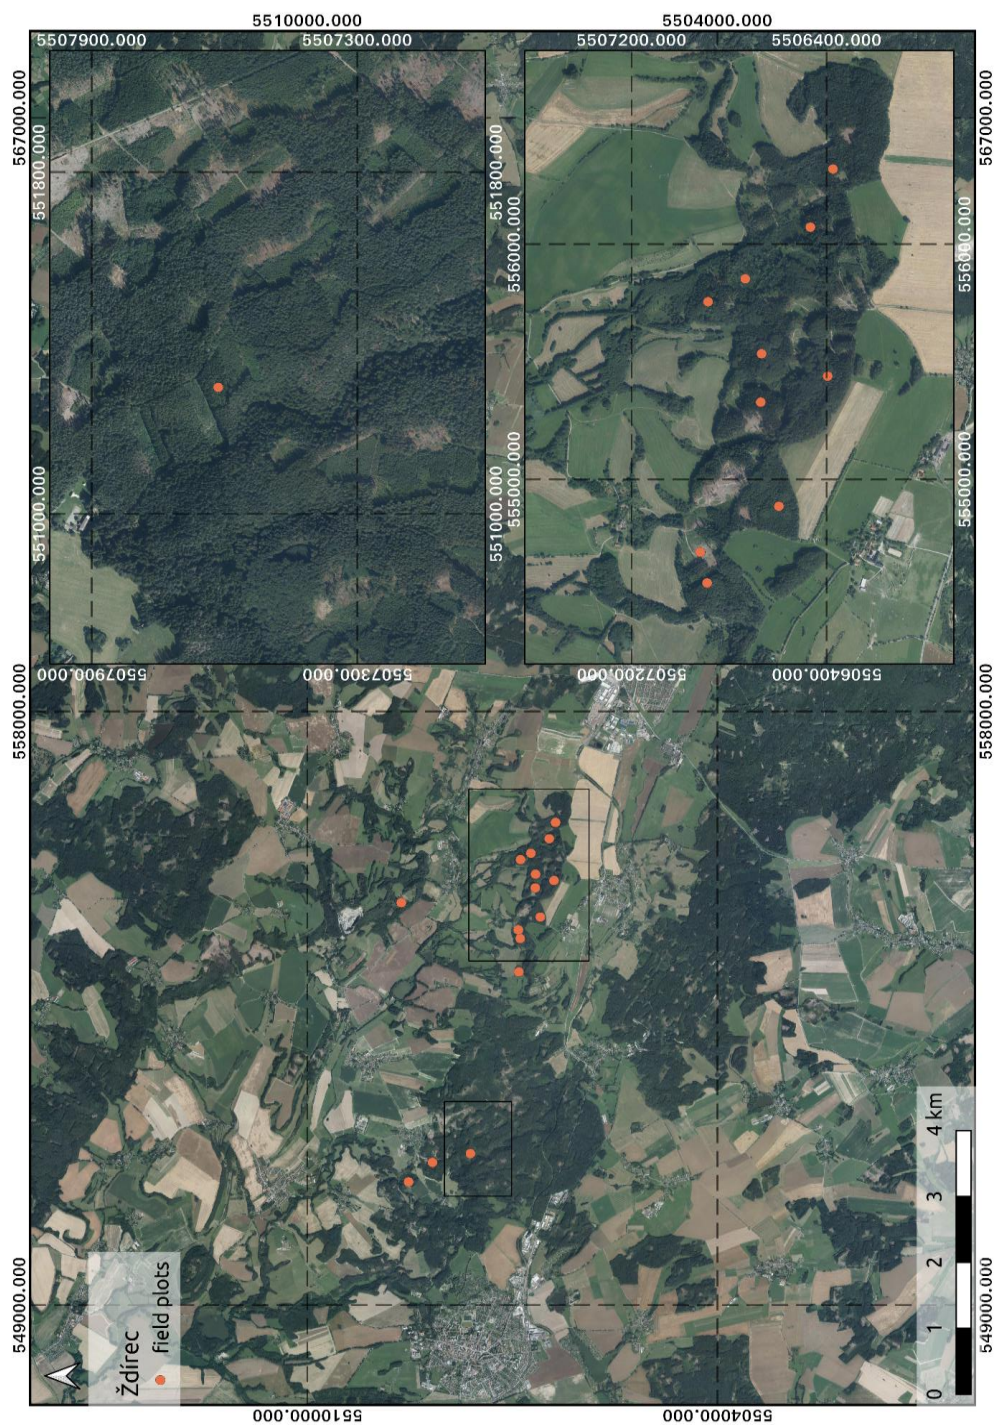


c)

Obrázek 12. Mapa nadzemní biomasy (a), směrodatná odchylka mezi dílčími modely, STD (b), a vizualizace kvality modelu (c) pro lesní plochu Těšínské Beskydy. Bodový graf je obarven podle odchylky mezi modelovanou a měřenou hodnotou biomasy: zeleně rozdíl do 25 t/ha, modře rozdíl 25 až 50 t/ha, žlutě rozdíl 50 až 75 t/ha, a červeně rozdíl více než 75t/ha.

4.2 Lesní plocha Ždírec nad Doubravou


K ověření modelu, jehož vznik je popsán v odstavci 4.1 a celé technologie (Obr. 3) byla vybrána soukromá lesní plocha u Ždírcu nad Doubravou. Jedná se o les o výměře 168 ha na pomezí Českomoravské vrchoviny a Železných hor (Obr. 13).



Obrázek 13. Plochy pozemního šetření ve Ždírci nad Doubravou. (Podkladová mapa: Orthophoto TopGIS).


Pozemní data o stromech a jejich biomase byla shromážděna během vegetační sezóny v říjnu 2021 s využitím technologie Field-Map tak, jak je popsáno v odstavci 3.3. Na 15 dílčích plochách bylo zaměřeno 454 stromů a 137 výšek. Převažovaly smrkové porosty se zásobou 0 až 628 tun.

Letecká data byla pořízena 1. října 2021 (Obr. 14) leteckého skeneru RIEGL LMS-Q780. Průměrná letová hladina byla 500 m nad terénem. Při frekvenci laseru na úrovni 400 kHz parametry akvizice vyústily v hustotu mračna dosahující až 15 bodů na metr čtvereční. Předzpracování těchto dat je popsáno v odstavci 3.2.2.




Obrázek 14. Uspořádání náletových linií v lokalitě Ždírec nad Doubravou. (Podkladová mapa: Mapy.cz (@Seznam.cz, @TopGis)).


Model vyvinutý pro Těšínské Beskydy (4.1) byl aplikován a vznikla mapa biomasy pro lesní plochy u Ždírcu nad Doubravou. Tato mapa je charakterizována hodnotami $R^2 = 0.7$ a $RMSE = 65$ [t/ha] (Obr. 15).



a)



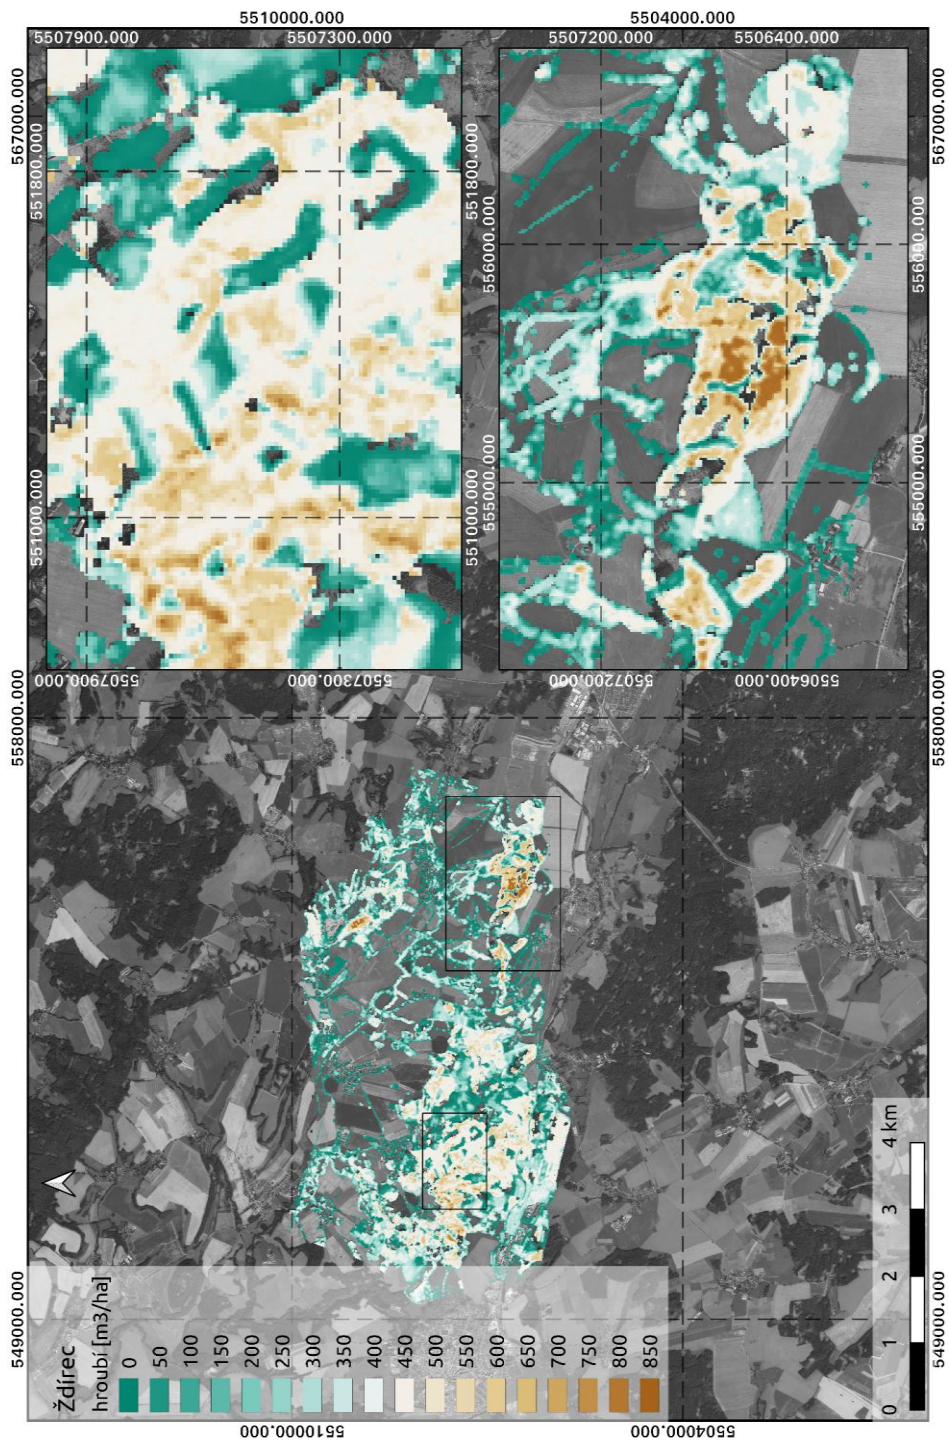
b)



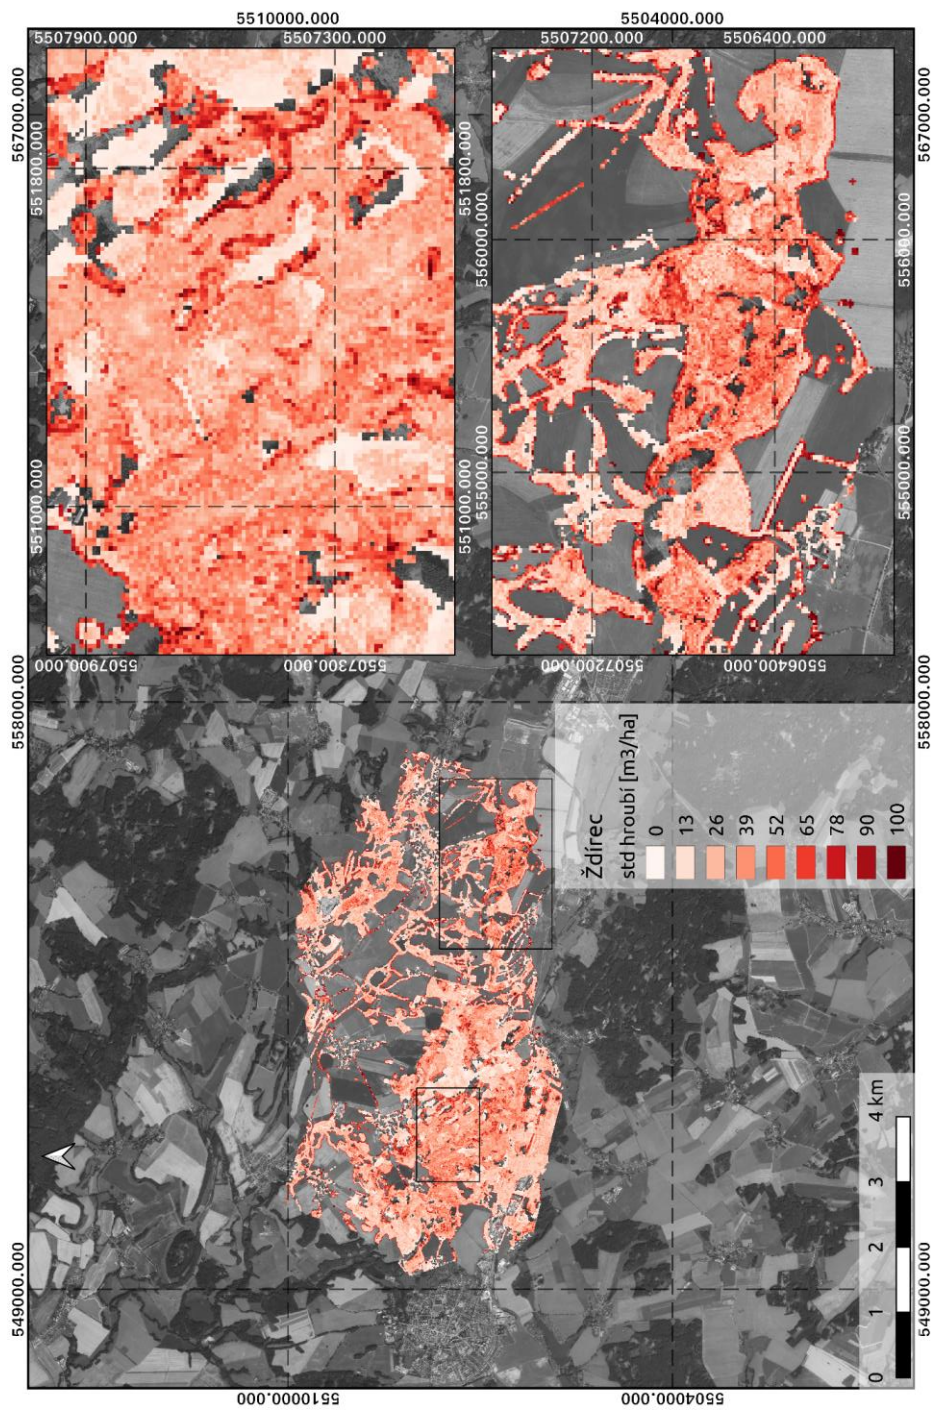
c)

Obrázek 15. Mapa nadzemní biomasy (a), směrodatná odchylka mezi dílčími modely, STD (b), a vizualizace kvality modelu (c) pro lesní plochu Ždírec nad Doubravou. Bodový graf je obarven podle odchylky mezi modelovanou a měřenou hodnotou biomasy: zeleně rozdíl do 25 t/ha, modře rozdíl 25 až 50 t/ha, žlutě rozdíl 50 až 75 t/ha, a červeně rozdíl více než 75t/ha.

Pro lokalitu Ždírec nad Doubravou byla také přístupem této technologie zpracována mapa zásoby hroubí (Obr. 16), kdy referenční hodnoty biomasy byly převedeny na objemové jednotky hroubí prostřednictvím alometrických rovnic. Objem hroubí je veličina používaná vlastníky lesů v České republice častěji než nadzemní biomasa, mají-li se vyjadřovat k zásobě a též uhlíkové bilanci. Podstata těchto dvou veličin předjímá silnou korelaci a tím i možnost kvantifikace analogickým postupem (Obr. 17, Tab. 7).




a)



b)

Obrázek 16. Hroubí (a) a směrodatná odchylka mezi dílčími modely STD (b).



Obrázek 17. Vztah hroubí a nadzemní biomasy vypočtené z terénních měření.

Tabulka 7. Nadzemní biomasa a objem hroubí pro vybrané jednotlivé stromy měřené v lesní lokalitě Ždírec nad Doubravou.

Dřeviny	Objem hroubí [m³/ha]	Lesní nadzemní biomasa [t/ha]
Smrk	448	271.6
Dub	22.8	17.4
Jedle	198.8	94.8
Smrk	4.4	2.8
Buk	59.8	63.2
Jedle	7.4	4.2
Smrk	127.4	75.2
Borovice	35.6	17.4
Buk	31.4	33.8

5 Ekonomické aspekty použití ověřené technologie

Efektivita (coby ekonomický pojem) je stanovena jako podíl hodnoty vyprodukovaného zboží či služeb a ceny práce a dalších potřebných zdrojů (Samuelson & Nordhaus, 2009). V této kapitole vyčíslujeme čas potřebný ke zpracování odhadů lesní biomasy dvěma postupy: tradiční pozemní inventarizací a plošným přístupem z lidarového mračna. Časové nároky analyzujeme ve vztahu k dosažené přesnosti, ale nehodnotíme cenu práce.

Časové náklady byly přepočteny nezávisle a byly shrnuty z hlediska obou přístupů za dílčí fáze: příprava kampaně, pořízení dat a vyhodnocení dat; dále pak byly shrnuty ve smyslu dvou typových úloh výše popsaných: pro 15 lesních ploch na lokalitě Ždírec nad Doubravou a pro 101 lesních ploch na lokalitě Těšínské Beskydy (Tab. 8). Časová náročnost sběru dat v terénu je dle zkušeností autorů v prostředí horských lesů 60 minut na jednu plochu v případě používání technologie FieldMap (Novotný et al. 2021). Nejistota počasí a dalších podmínek v případě letecké kampaně byla také zahrnuta do odhadu časové náročnosti.

Tabulka 8. Časové nároky pozemní inventarizace a práce s leteckými daty. Blok A popisuje variantu 15 lesních ploch na lokalitě Ždírec nad Doubravou a blok B popisuje 101 lesních ploch na lokalitě Těšínské Beskydy.

	Fáze	ALS		Pozemní šetření	
		A (celý porost)	B (celý porost)	A (200 stromů)	B (1400 stromů)
Příprava kampaně	Plánování	4	4	5	7
	Minimální počet pracovníků	1	1	1	1
	Celkový čas [člověko-hodiny]	4	4	5	7
Pořízení dat	Příprava a pořízení dat	2	2.5	9	100
	Minimální počet pracovníků	2	2	2	2
	Celkový čas [člověko-hodiny]	4	5	18	200
Vyhodno cení dat	Předzpracování	5	6	-	-
	Modelování biomasy	2	2	8	8
	Celkový čas [člověko-hodiny]	7	8	8	8
Celkem [člověko-hodiny]		15	16	31	215

Vidíme, že objem práce v případě leteckých dat vzroste o cca 7 procent (z 15 na 16 hodin), když počet ploch vzroste sedmkrát (z 15 na 101 ploch). Naproti tomu, v případě pozemního šetření za stejné situace vzroste objem práce přibližně sedmkrát (z 31 na 215 človeko-hodin). Technologie leteckého laserového skenování přináší stejný rozsah informací o všech stromech v zájmovém území, a tak umožňuje produkci plošných map biomasy, zatímco pozemní šetření vyhodnotí jen jednotlivé inventarizační plochy.

Odhad lesní biomasy na základě leteckých lidarových dat se tak jeví časově efektivnější v porovnání s pozemním šetřením, a to při zachování uspokojivé přesnosti. Na základě těchto výsledků vidíme, že tato technologie může sehrát důležitou roli při velkoplošné inventarizaci a lze ji doporučit do procesu udržitelného lesního hospodaření v České republice.

6 Závěr

Technologie *Hodnocení nadzemní biomasy dřevinného patra lesních ekosystémů plošným přístupem* byla vyvinuta a otestována pro podmínky českého lesnictví. Testování technologie na experimentální lesní lokalitě Ždírec nad Doubravou potvrdilo použitelnost předloženého postupu pro odhad množství a plošné distribuce nadzemní biomasy lesních porostů.

Technická dokumentace technologie popisuje postupy a praktická doporučení pro její použití v kontextu českého lesnictví. Konkrétně se jedná o nastavení parametrů pořizování dat, sezóny pro pořízení leteckých dat, sběru dat pozemního šetření a výběr algoritmů modelování.

Uvedené postupy ukazují perspektivní cestu uplatnění moderních metod leteckého laserového skenování v lesnictví, které umožní opakované snímání dat a získání aktuální prostorové distribuce nadzemní biomasy. Kvantitativní hodnocení změn biomasy tak může doplnit kritickou informací o stavu vývoji lesních zdrojů ve vazbě na uhlíkový cyklus a měnící se podmínky růstového prostředí.

Seznam zkratk:

ALS - letecké laserové skenování

DPZ - dalkový průzkum Země

RMSE - střední kvadratická chyba, Root Mean Square Error

Použitá literatura:

Anderson, R.S. 2012. Estimating Aboveground Biomass and Average Annual Wood Biomass Increment with Airborne Leaf-on and Leaf-off LiDAR in Great Lakes Forest Types. *NORTH. J. APPL. FOR.* 30(1).

Blackburn, R.C., Buscaglia, R., Sanchez Meador, A.J. 2021. Mixtures of airborne lidar-based approaches improve predictions of forest structure. *Canadian Journal of Forest Research*, 51 (8), 1106-1116.

Bouvier, M., Durrieu, S., Fournier, R.A., Renaud, J.-P. 2015. Generalizing predictive models of forest inventory attributes using an area-based approach with airborne lidar data. *Remote Sensing of Environment*, 156: 322-334.

Bronisz, K., Strub, M., Cieszewski, C. J., Bijak, S., Bronisz, A., Tomusiak, R., Wojtan, R., & Zasada, M. 2016. Empirical equations for estimating aboveground biomass of *Betula pendula* growing on former farmland in central Poland. *Silva Fennica*, 50. <https://doi.org/10.14214/sf.1559>

Brubaker, K., Johnson, Q., Kaye, M. 2018. Spatial patterns of tree and shrub biomass in a deciduous forest using leaf-off and leaf-on lidar. *Canadian Journal of Forest Research*, 48 (9). <https://doi.org/10.1139/cjfr-2018-0033>.

Cienciala, E., Apltauer, J., Exnerová, Z., Tatarinov, F. 2008. Biomass functions applicable to oak trees grown in Central-European forestry. *Journal of Forest Science* 54(3):109–20.

Cienciala, E., Černý, M., Apltauer, J., Exnerová, Z., Tatarinov, F. 2006. Biomass Functions Applicable to Scots Pine. *Trees* 20(4):483–95. doi: 10.1007/s00468-006-0064-4.

Cienciala, E., Tumajer, J., Zatloukal, V., Beranová, J., Holá, Š., Hůnová, I., & Russ, R. 2017. Recent spruce decline with biotic pathogen infestation as a result of interacting climate, deposition and soil variables. *European Journal of Forest Research*, 136(2), 307–317. <https://doi.org/10.1007/s10342-017-1032-9>

Černý, M., Kučera, M., Cienciala, E., Beranová, J. 2010. Czech Republic –Chapter 8 of Tomppo et al. (eds) *National Forest Inventories: Pathways for Common Reporting*. <https://doi.org/10.1007/978-90-481-3233-1>

Čihák, T., Hlásny, T., Stolariková, R., Vejpustková, M., Marušák, R. 2014. Functions for the aboveground woody biomass in Small-leaved lime (*Tilia cordata* Mill.). *Lesnícky časopis – Forestry Journal*. 60. 150-158.

Davison, S., Donoghue, D.N.M., Galiatsatos, N. 2020. The effect of leaf-on and leaf-off forest canopy conditions on LiDAR derived estimations of forest structural diversity. *Int J Appl Earth Obs Geoinformation*, 92.

Duncanson, L., Armston, J., Disney, M., Avitabile, V., Barbier, N. 2021. LPV Protocols. Aboveground Biomass. Good Practices for Satellite-Derived Land Product Validation: Land Product Validation Subgroup (WGCV/CEOS), doi:10.5067/doc/ceoswgcv/lpv/agb.001.

Hawryło, P., Tompalski, P., Wezyk, P. 2017. Area-based estimation of growing stock volume in Scots pine stands using ALS and airborne image-based point clouds. *Forestry*. 90. 686–696. 10.1093/forestry/cpx026.

Henry, M., Besnard, A., Asante, W.A., Eshun, J., Adu-Bredu, S., Valentini, R. et al. 2010. Wood density, phytomass variations within and among trees, and allometric equations in a tropical rainforest of Africa. *Forest Ecology and Management* 260: 1375–1388.

Johansson, T. 2000. Biomass equations for determining fractions of common and grey alders growing on abandoned farmland and some practical implications. *Biomass and Bioenergy*, 18, 147–159. [https://doi.org/10.1016/S0961-9534\(99\)00078-1](https://doi.org/10.1016/S0961-9534(99)00078-1).

Kankare, V., Vastaranta, M., Holopainen, M., Rätty, M., Yu, X., Hyypä, J., Hyypä, H., Alho, P., Viitala, R. 2013. Retrieval of Forest Aboveground Biomass and Stem Volume with Airborne Scanning LiDAR. *Remote Sens.*, 5, 2257–2274. <https://doi.org/10.3390/rs5052257>

Maltamo M., Naesset, E., Vauhkonen, J. 2014. *Forestry applications of airborne laser scanning*. Publisher Springer Netherlands, ISBN 978-94-017-8662-1.

Martin, A.R., Thomas, S.C. 2011. A reassessment of carbon content in tropical trees. *PLoS One*, 6:e23533.

Melville, G., Stone, C. & Turner, R. 2015. Application of LiDAR data to maximize the efficiency of inventory plots in softwood plantations. *N.Z. j. of For. Sci.* 45, 9. <https://doi.org/10.1186/s40490-015-0038-7>.

Naesset, E. 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sensing of Environment* 80, 88–99.

Naesset E. 2005. Assessing sensor effects and effects of leaf-off and leaf-on canopy conditions on biophysical stand properties derived from small-footprint airborne laser data. *Remote Sensing of Environment* 98(2):356–370.

Nelson, R. 2013. How did we get here? An early history of forestry LiDAR. *Canadian Journal of Remote Sensing*, 39: S1–S12.

Noordermeer, L., Bollandsås, O.M., Ørka, H.O., Næsset, E., Gobakken, T. 2019. Comparing the accuracies of forest attributes predicted from airborne laser scanning and digital aerial photogrammetry in operational forest inventories. *Remote Sensing of Environment*, 226: 26–37.

Novotny, J., Navratilova, B., Albert, J., Cienciala, E., Fajmon, L., Brovkina, O. 2021. Comparison of spruce and beech tree attributes from field data, airborne and terrestrial laser scanning using manual and automatic methods. *Remote Sensing Applications: Society and Environment*, 23.

Parkitna, K., Krok, G., Miścicki, S., Ukalski, K., Lisańczuk, M., Mitelsztedt, K., Magnussen, S., Markiewicz, A., Stereńczak, K. 2021. Modelling growing stock volume of forest stands with various ALS area-based approaches. *Forestry: An International Journal of Forest Research*. 10.1093/forestry/cpab011.

Patocka, Z., Mikita, T. 2016. Use of area-based approach to process the airborne laser scanning data in forest inventory. *Zprawy Lesnickeho Vyzkumu*. 61. 115-124.

Pearse, G., Watt, M., Dash, J., Stone, C., Caccamo, G. 2019. Comparison of models describing forest inventory attributes using standard and voxel-based lidar predictors across a range of pulse densities. *International Journal of Applied Earth Observation and Geoinformation*. 78. 10.1016/j.jag.2018.10.008.

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P. et al. 2011. Scikit-learn: Machine Learning in Python. *J. Mach. Learn. Res.* 12, null (2/1/2011), 2825–2830.

Petersson, H., Holm, S., Stahl, G., Alger, D., Fridman, J., Lehtonen, A., Lundstrom, A., Makipaa, R. 2012. Individual tree biomass equations or biomass expansion factors for assessment of carbon stock changes in living biomass - A comparative study. *Forest Ecology and Management*, 270: 78-84.

Samuelson P., Nordhaus W. 2009. *Economics*. - M.: Williams, 19th ed. 1360p. ISBN-13: 978-0-07-351129-0.

Somogyi, Z., Cienciala, E., Mäkipää, R., Muukkonen, P., Lehtonen, a., & Weiss, P. 2007. Indirect methods of large-scale forest biomass estimation. *European Journal of Forest Research*, 126(2), 197–207. <https://doi.org/10.1007/s10342-006-0125-7>.

Tompalski, P., White, J.C., Coops, N.C., Wulder, M.A. 2019. Demonstrating the transferability of forest inventory attribute models derived using airborne laser scanning data. *Remote Sensing of Environment*, 227: 110-124.

Tomppo, E., Gschwantner, T., Lawrence, M., & McRoberts, R. E. 2010. National forest inventories: Pathways for common reporting. In *National Forest Inventories: Pathways for Common Reporting*. <https://doi.org/10.1007/978-90-481-3233-1>

Vastaranta, M., Wulder, M.A., White, J.C., Pekkarinen, A., Tuominen, S., Ginzler, C. et al. 2013. Airborne laser scanning and digital stereo imagery measures of forest structure: comparative results and implications to forest mapping and inventory update. *Can.J.Remote Sens.* 39, 382-395.

Villikka, M., Packalen, P., Maltamo, M. 2012. The Suitability of Leaf-off Airborne Laser Scanning Data in an Area-based Forest Inventory of Coniferous and Deciduous Trees. *Silva Fennica*. 46. 10.14214/sf.68.

Vonderach, C., Kändler, G., Dormann, C.F. 2018. Consistent Set of Additive Biomass Functions for Eight Tree Species in Germany Fit by Nonlinear Seemingly Unrelated Regression. *Annals of Forest Science* 75(2):49. doi: 10.1007/s13595-018-0728-4.

Walton, J. T. 2008. Subpixel urban land cover estimation: Comparing cubist, random forests, and support vector regression. *Photogrammetric Engineering and Remote Sensing*, 74, 1213–1222.

White, J.C., Wulder, M.A., Varhola, A., Vastaranta, M., Coops, N.C., Cook, B.D., Pitt, D., Woods, M. 2013. A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach. Natural Resources Canada, Canadian Forest Service, Canadian Wood Fibre Centre, Victoria, BC. Information Report FI-X-010.

White, J.C., Tompalski, P., Vastaranta, M., Wulder, M.A., Saarinen, S., Stepper, C., Coops, N.C. 2017. A model development and application guide for generating an enhanced forest inventory using airborne laser scanning data and an area-based approach. CWFC Information Report FI-X-018, 38 pp.

Wirth, C., Schumacher, J., Detlef, S.E. 2004. Generic biomass functions for Norway spruce in Central Europe - A meta-analysis approach toward prediction and uncertainty estimation. *Tree physiology* 24:121–39. doi: 10.1093/treephys/24.2.121.

Wutzler, T., Wirth, C., Schumacher, J. 2008. Generic Biomass Functions for Common Beech (*Fagus Sylvatica*) in Central Europe: Predictions and Components of Uncertainty. *Canadian Journal of Forest Research*. doi: 10.1139/X07-194.