

VYUŽITÍ PLOŠNÉHO PŘÍSTUPU KE ZPRACOVÁNÍ DAT LETECKÉHO LASEROVÉHO SKENOVÁNÍ V INVENTARIZACI LESA

Zdeněk PATOČKA

Ústav hospodářské úpravy lesů a aplikované geoinformatiky, Lesnická a dřevařská fakulta, Mendelova univerzita v Brně, Zemědělská 1, 613 00, Brno – Černá Pole, Česká republika
xpatock2@mendelu.cz

Abstrakt

Letecké laserové skenování představuje v poslední době vhodnou alternativu ke konvenčním metodám inventarizace lesa. Umožňuje omezit čas použitý pro sběr terénních dat a tím snížit celkové náklady na inventarizaci lesa. Při inventarizaci lesa pomocí leteckého laserového skenování se využívají dvě základní metody – individuální detekce jednotlivých stromů (individual tree detection - ITD) a plošný přístup (area-based approach - ABA). V této studii byla využita metoda ABA, přičemž regresní modely pro tuto metodu nebyly vytvořeny pouze pomocí lineární regrese, ale také pomocí vícevrstevných perceptronových neuronových sítí, regresní analýzy MARSpline a dataminingové techniky Random Forests. Vytvořené modely byly aplikovány na celé bodové mračno, čímž byly vytvořeny rastry zásob, které byly porovnány zonální statistikou s údaji o zásobách v lesní hospodářské knize. Nejlepších výsledků bylo dosaženo použitím kolekce 100 neuronových sítí vyhledávaných automatizovaně v softwaru Statistica. Na základě této metody byla vypočítána zásoba s maximální odchylkou od LHP do 15 % v šedesáti procentech plochy všech analyzovaných porostů s různou dřevinnou skladbou, s různým věkem a strukturou.

Abstract

Airborne laser scanning represents a suitable alternative to conventional methods of forest inventory at the last time. It allows to limit the time used to collect field data and thereby reduce the total cost of the forest inventory. There are two basic approaches to process the airborne laser scanning data for forest inventory - individual tree detection - ITD and area-based approach - ABA. In this study, it was used an ABA method, wherein the regression models for this method were created by using linear regression, multilayer perceptron neural networks, MARSplines regression analysis and data mining technique Random Forests. Produced models were applied to the entire point cloud, thus creating forest stand volume rasters that were compared with forest stand volume data in forest management plan using zonal statistics. The best results were achieved by using a collection of 100 neural networks. Based on this method, it was calculated volume with a maximum deviation from LHP to 15% in sixty percent of all analyzed stand area of various species composition, with different age and structure.

Klíčová slova: inventarizace lesa; LiDAR; letecké laserové skenování; plošný přístup; lineární regrese; neuronové sítě; MARSplines; Random Forests

Keywords: forest inventory; LiDAR; airborne laser scanning; area-based approach; linear regression; neural networks; MARSplines; Random Forests

ÚVOD

Letecké laserové skenování již našlo své uplatnění v inventarizaci lesa v boreálních lesích Skandinávie a Kanady, kde se již v praxi využívá více než deset let. Ve střední Evropě byl však rozvoj této technologie pro účely lesnictví doposud velmi pomalý. Na základě multiplikace odrazů při průletu paprsku lesním ekosystémem je však možné odhadnout některé parametry lesních porostů či jednotlivých stromů, např. objem korun jednotlivých stromů, počet stromů v porostu, šířku koruny a její nasazení, velikost zápoje, odhady objemu dřevní hmoty a biomasy, či dokonce dřevinnou skladbu (NÆSSET et al. 2004; HYYPPÄ et al. 2008; KORPELA et al. 2009).

Ve světě existují dva základní přístupy ke zpracování dat leteckého laserového skenování (LLS) pro účely inventarizace lesa (1) individuální detekce jednotlivých stromů (individual tree detection – ITD) (HYYPPÄ,

INKINEN 1999) a (2) plošný přístup (area-based approach – ABA) (NÆSSET 2002). Při detekci jednotlivých stromů v případě první metody se pracuje s mračnem bodů LLS s vyšší hustotou (4–12 bodů na m²) a využívají se různé metody identifikace lokálního maxima, např. technika segmentace inverzního povodí (VINCENT, SOILLE 1991), která je založena na nástrojích hydrologického modelování, dále pak metoda minimové sítě (GOUGEON 1995) či metoda růstového algoritmu – Seed Region Growing (NOVOTNÝ 2014) a řada dalších. Nejjednodušeji implementovaná do prostředí GIS je metoda segmentace inverzních povodí, kdy je na základě rozdílu digitálního modelu povrchu (DMP) a digitálního modelu terénu (DMT) vytvářen tzv. výškový model korun (Canopy Height Model – CHM). Vynásobením CHM hodnotou -1 vznikne převrácený model, kde každá bezodtoká propadlina reprezentuje korunu stromu. Bezodtoká propadlina je zároveň lokálním povodím. Poté se výpočtem směru a délky odtoku detekují lokální minima, která reprezentují jednotlivé vrcholky stromů. Výška každého stromu se pak získá extrakcí z výškového modelu korun. Výčetní tloušťka se pak vypočítá na základě regresního vztahu ve výškových funkcích, např. Michajlovova výšková funkce (MICHAILOFF 1943), Nāslundova výšková funkce (NÅSLUND 1947), dle HALAJE (1959), dle ŠMELKA et al. (1987). Objem jednotlivých stromů se pak vypočítá podle objemových rovnic, např. PETRÁŠE, PAJTÍKA (1991). Metoda ITD se používá v případě vysoké hustoty bodů LLS (HYYPÄ, INKINEN 1999) a byla široce studována, ale stále přetrvává mnoho problémů, které souvisí zejména s detekcí stromů (KAARTINEN, HYYPÄ 2008).

Metoda ABA, určená pro nízkou hustotu bodů LLS (přibližně 1–2 body/m²) se ve Skandinávii používá již od roku 2002 pro inventarizaci lesů. V této metodě se jako nezávislých proměnných využívá prvků odvozených z povrchových modelů a z mračen bodů leteckého laserového skenování, které jsou dále přímo použity pro odhad taxačních veličin, většinou formou parametrické regrese nebo metodou k-nejbližších sousedů (k-nearest neighbor – kNN) (NÆSSET 2002). Tato metoda patří mezi neparametrické a využívá klasifikaci do shluků, kdy do daného shluku přiřadíme hodnotu, která je shluku nejpodobnější, a to na základě vzdálenosti v Euklidovské metrice. Predikcí neznámé hodnoty pak je průměr hodnot naměřených na nejbližších *k*-trénovacích případech (Pošík 2003). Ve Finsku se touto metodou zabýval SUVANTO et al. (2005). MALTAMO et al. (2006) k této metodě přidal prvky odvozené z leteckých snímků a využil metodu *k*-nejvíce podobných sousedů (k-Most Similar Neighbor – k-MSN). V některých případech může metodu k-MSN překonat moderní data-miningová technika Random Forests (RF) (HUDAK et al. 2008). Je to kolekce jednoduchých regresních stromů, kde každý regresní strom je modelem s více nezávislými proměnnými a jedním výstupem (závislá proměnná). RF se skládá z libovolného počtu (kolekce) regresních stromů, jejichž výstupy se průměrují. RF náhodně vybírá podmnožiny příznaků (prediktorů, proměnných) z původní množiny dat. Optimální velikost podmnožiny příznaků je $\log_2 M + 1$, kde *M* je počet vstupů. Na rozdíl od použití jednotlivého regresního stromu, je tato metoda stabilnější a přesnější. Random Forest si poradí i s chybějícími, případně špatnými hodnotami (BREIMAN 2001). Další možností je použití Bayesovské statistiky (JUNTTILA et al. 2008). Metody ITD a ABA lze samozřejmě kombinovat. Tímto se zabývali např. BREIDENBACH et al. (2010) nebo VASTARANTA et al. (2012).

V této práci byly využity další dvě techniky Další technikou tvorby regresních modelů – MARSplines a neuronová síť. MARSplines je neparametrická metoda, která nepředpokládá předem daný funkční vztah mezi závislou a nezávislými proměnnými. Tento vztah mezi závislou a nezávislými proměnnými se vytváří pomocí koeficientů a bázových funkcí určených na základě analýzy dat. Jedná se vlastně o po částech lineární regresi, kde hranice jsou určeny také automaticky z dat členy (vážené bázové funkce) se postupně do modelu přidávají (dopředná fáze). Následně se málo významné členy odebírají (pruning), přičemž se využívá zobecněná křížová validace (Generalized cross-validation - GCV) (FRIEDMAN 1991).

Neuronová síť je výpočetní model, jehož vzorem je činnost lidského mozku. Inspiruje se biologickou neuronovou sítí, ve které je základním stavebním kamenem nervová buňka – neuron. Jednotlivé neurony jsou vzájemně propojeny spoji ohodnocenými vahami. Hlavní předností neuronové sítě je schopnost učit se a zapamatovat si kombinace, které vedly k požadovanému výstupu, a na základě zkušeností odhadovat nový výsledek na nových datech. Neuronové sítě mají schopnost řešit i silně nelineární úlohy. V některých případech se stává, že není možné najít nějakou jednoduchou matematickou funkci, která by vhodně postihla všechny vlivy, které variabilitu sledované proměnné ovlivňují. Tuto situaci dovedou právě řešit neuronové sítě (JIŘINA 2003).

Neuronové sítě se skládají z neuronů propojených vazbami. Model neuronu se skládá ze tří částí – vstupní, výstupní a funkční. Na základě vah mohou být jednotlivé vstupy potlačeny, nebo naopak zvýhodněny. Funkční část zpracuje informace ze vstupů a vygeneruje výstup. Výstupní část potom přivede výslednou informaci na vstup jiných neuronů. Tedy výstup neuronu $f(\xi)$ je spočítán ve chvíli, když suma vstupů do neuronu x_i vynásobených jejich konkrétními vahami překročí určitou hodnotu, kterou nazýváme práh (θ). Neuron lze popsat tímto způsobem:

$$y = f(\sum_{i=1}^n x_i \cdot w_i - \theta)$$

Kde x_i je konkrétní hodnota na i -tém vstupu, w_i je potom váha tohoto vstupu, θ je prahová hodnota, n je celkový počet vstupů, f je transformační funkce a y hodnota na výstupu (Jiřina, 2003).

Jeden neuron sám o sobě není schopen vykonávat složitější funkci než regresní analýza. Neurony jsou proto uspořádány do vrstev. Mezi nejběžnější typy sítí patří tyto:

- MLP (Multi Layer Perceptron – vícevrstvá perceptronová síť) – používá se nejčastěji
- RBF – Radial Basis Function
- SOFM – Kohonenova síť
- Lineární síť
- Bayesovské sítě (PNN a GRNN)

Cílem této práce je na základě terénního měření vytvořit několik modelů pro výpočet zásoby, a to na základě lineární regrese, neuronových sítí, Random Forest a MARSplines, tyto metody mezi sebou porovnat a aplikovat je na širší území k výpočtu zásoby v celých porostních skupinách. Výsledky pak budou pomocí zonální statistiky porovnány s údaji v lesním hospodářském plánu.

METODIKA

MATERIÁL A METODIKA

LiDARová data použitá v této práci byla naskenována ve dnech 17. 9. a 18. 9. 2014 v souřadnicovém systému ETRS-89 UTM 33N a v elipsoidických výškách GRS-80.

Parametry leteckého laserového skenování:

- použitý skener: Leica ALS70-CM (SN7209)
- použitý letoun: Cessna 206 Turbo stationair OK-EKT
- skenovací úhel: 24°
- skenovací mechanismus: oscilující zrcátko
- PRF (Pulse Repetition Frequency): 301,8 kHz
- průměrná hustota bodů: 7,8 bodů/m²

Sběr terénních dat pro tvorbu modelu k výpočtu taxačních charakteristik probíhal v průběhu roku 2015 na Školním lesním podniku Masarykův les Křtiny, na polesí Habrůvka. Výběr ploch probíhal na základě stratifikace podle dat lesní hospodářské knihy. Bylo vytyčeno 43 zkusných ploch o poloměru 12,62 m a jejich střed byl zaměřen přesnou GNSS aparaturou Topcon Hiper Pro s aplikovanými RTK korekcemi ze sítě CZEPOS. GNSS měření bylo prováděno v pětisekundových intervalech po dobu dvaceti minut. Na každé ploše byly měřeny výčetní tloušťky a výšky všech stromů. Objemy jednotlivých stromů byly spočítány pomocí objemových rovnic (PETRÁŠ, PAJTIK 1991). Věk měřených porostů se pohyboval mezi 60 a 130 lety, s výraznou převahou porostů starších 100 let. Průměrné zastoupení dřevin na všech zkusných plochách je v Tab. 1.

Tab. 1 Zastoupení dřevin na zkusných plochách

Zastoupení	
smrk	90
modřín	6
borovice	2
buk	1
ostatní	1

Klasifikace dat probíhala v nadstavbě TerraSolid Terrascan softwaru Bentley Microstation. Pomocí automatického skriptu byl také odstraněn překryt bodů mezi jednotlivými letovými pásy. Zpracování klasifikovaného mračna bodů bylo provedeno v softwaru FUSION, který byl vyvinut v U. S. Department of Agriculture, Forest Service, University of Washington (MCGAUGHEY 2014). Nejprve byly příkazem *clipdata* vyříznuty zkusné plochy z mračna bodů a následně se vypočítaly pomocí příkazu *cloudmetrics* charakteristiky mračen bodů na jednotlivých zkusných plochách. Příkaz *cloudmetrics* poskytuje 87 charakteristik bodového mračna založených na attributech výška bodu a intenzita odrazu. Pomocí korelačních matic se hledaly nejvyšší závislosti mezi zásobou a jednotlivými charakteristikami mračna bodů. V softwaru QC Expert byly vytvořeny vícerozměrné lineární regresní modely tak, že do modelu vstupovala jako nezávislá proměnná vždy ta charakteristika bodového mračna, která vykazovala nejvyšší korelaci s danou taxační veličinou. Poté se přiřadila další charakteristika, která nejvíce korelovala s rezidui předchozí regresní rovnice. Takto se postupovalo, dokud se u modelů nepřestaly zvyšovat koeficienty determinace a zároveň všechny nezávislé proměnné byly významné. U finálních modelů byl otestován regresní triplet.

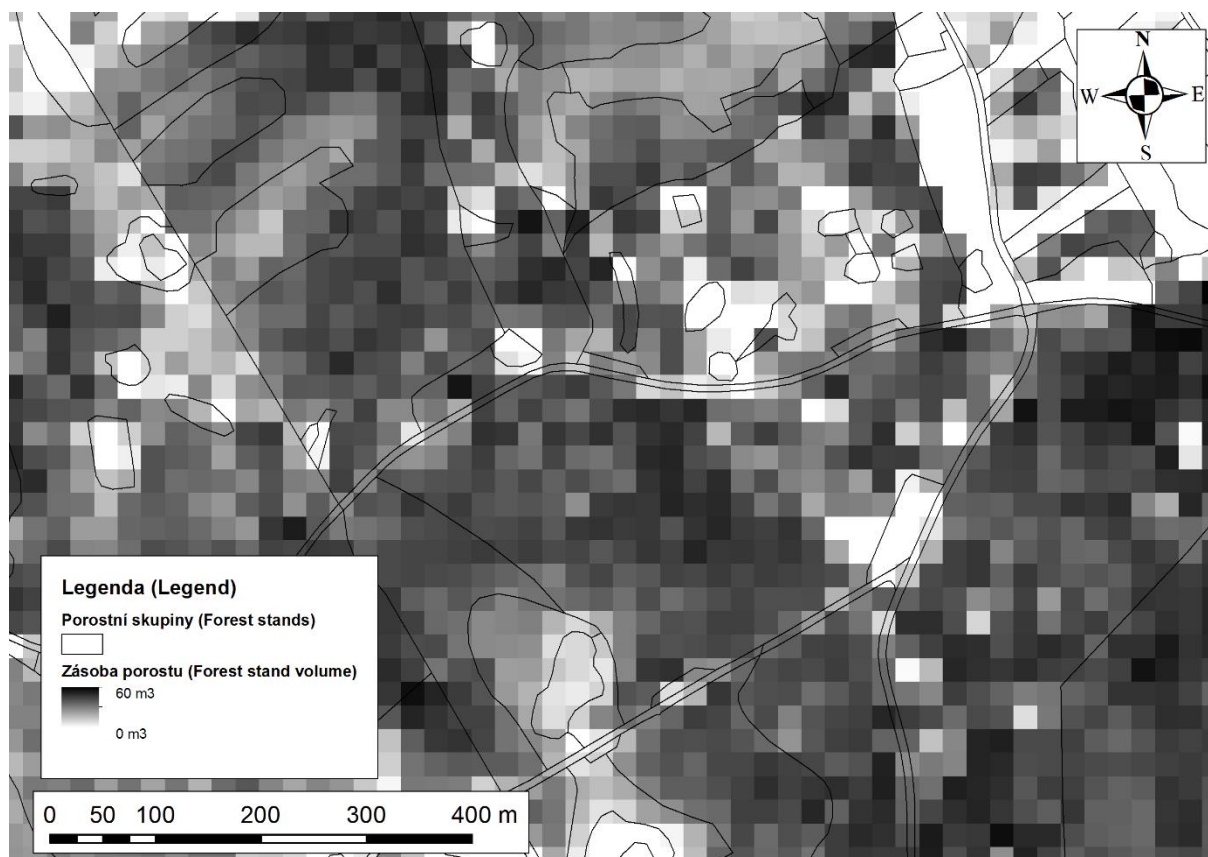
Tvorba regresních modelů na základě vícevrstevných neuronových sítí probíhala v modulu *Neuronové sítě* programu Statistica. Jako strategie pro vytváření prediktivních modelů bylo zvoleno automatické vyhledávání sítí (ANS). Rozdělení dat na trénovací, testovací a validační množinu bylo provedeno náhodným vzorkováním v poměru 60:20:20. Bylo natrénováno 10000 sítí s minimální počtem 8 a maximálním počtem 25 skrytých neuronů. Jako typy aktivačních funkcí byly zvoleny funkce identita, logistická, hyperbolický tangens a exponenciální funkce a to jak u neuronů skrytých vrstev, tak u výstupních neuronů. Pro učení sítě byl použit algoritmus BFGS (Broyden-Fletcher-Goldfarb-Shanno) Quasi-Newton. Software Statistica kombinoval různou velikost vah, různý počet neuronů a různý typ aktivační funkce. Neuronové sítě seřadil podle nejvyššího validačního výkonu a zachoval 100 nejlepších sítí. Na základě globální analýzy citlivosti byly vymazány proměnné, které nebyly důležité, a celý postup trénování se opakoval bez těchto proměnných. Do finálních neuronových sítí pak tedy vstupovalo 66 charakteristik bodového mračna. Výsledné neuronové sítě byly uloženy do formátu PMML (Predictive Model Markup Language – výměnný formát pro data mining na bázi XML) pro pozdější nasazení na celé bodové mračno.

Dále byl vytvořen regresní model pomocí MARSplines. Pro tvorbu modelu byly použity všechny charakteristiky bodového mračna z FUSIONu. Proces tvorby regresního modelu je plně automatizovaný. Výsledný model se uložil do formátu PMML pro pozdější nasazení.

Poslední způsobem vytváření regresního modelu byla dataminigová technika Random Forests. Zde byl nejdříve proveden výběr optimální nezávislých proměnných pomocí funkce *Feature Selection* programu Statistica. Nejlepších výsledků bylo dosaženo nastavením počtu řezů množiny hodnot pro každou proměnnou na $k = 4$. Z vytvořeného pořadí proměnných bylo vybráno 20 nejlepších. Pro tvorbu jednoho regresního stromu se pak z množiny těchto proměnných náhodně deset vybralo. Pro testování modelu bylo použito 30 % dat a bylo vytvořeno 80 stromů s maximální možnou složitostí (max. počet úrovní stromu = 32, max. počet uzlů = 1000). Výsledný model se uložil do formátu PMML pro pozdější nasazení.

Pro odhad zásob v jednotlivých porostech je třeba vypočítat charakteristiky v celém bodovém mračnu. K tomu se využívá příkazu *gridmetrics*, který vytvoří rastr, kde v každém pixelu je informace o velikosti hodnoty dané charakteristiky mračna bodů. Plocha pixelu by měla být vždy blízká velikosti zkusné plochy. V této studii byl použit rastr s prostorovým rozlišením 22,36 m. Podobně je tomu tak i ve světě, např: Finsko – poloměr zkusné plochy 9 m, pixel – 16 m, Ontario – poloměr zkusné plochy 11,28 m, pixel 20 m, Britská

Kolumbie – poloměr zkušné plochy 11,28 m, pixel 20 m (WHITE et al. 2013). Zadáním regresních modelů a vstupních rastrů charakteristik bodového mračka do *Raster Calculatoru* vznikla mapy zásoby (obr. 1).



Obr. 1 Mapa zásoby lesních porostů

V případě neuronových sítí se výsledná kolekce 100 sítí nasadila v modulu *Neuronové sítě* na rastr vytvořený pomocí příkazu *gridmetrics*, v případě modelů MARSpline a Random Forests bylo využito pro nasazení využito modulu *Rapid Deployment* programu Statistica.

VÝSLEDKY

Na základě regresní analýzy v softwaru QC Expert byly vybrány nejvhodnější modely pro výpočet zásob

Výsledný regresní model pro výpočet zásoby porostu lze popsat rovnicí:

$$\text{Zásoba} = -45,13317342 + 1,841567494x + 0,419936447y,$$

kde x představuje charakteristiku Elev P30 a y charakteristiku (All returns above mean/Total first returns) \times 100

Charakteristika (All returns above mean/Total first returns) \times 100 se vypočítá jako stonásobek podílu všech odrazů nad průměrnou výškou všech bodů nad terénem k celkovému počtu všech prvních odrazů, charakteristika Elev P30 určuje průměrnou výšku bodů v třicátém percentilu. Percentilem se v tomto smyslu myslí relativní umístění bodů vzhledem k ostatním bodům ve vertikálním profilu bodového mračka konkrétní zkušné plochy. Například stý percentil by byl roven nejvyššímu bodu v mračku.

Kvalitu regresního modelu popisuje Tab. 2.

Tab. 2 Statistické charakteristiky regresního modelu pro výpočet zásob porostů

Vícenásobný korelační koeficient R	0.91
Koeficient determinace R ²	0.82
Predikovaný korelační koeficient Rp	0.64
Střední kvadratická chyba predikce MEP	15.97
Akaikeho informační kritérium	119.67

Důležitou součástí regresní analýzy je studium regresního tripletu, tedy hodnocení kvality dat, kvality modelu a kvality metody odhadu (metoda nejmenších čtverců). V rámci testování regresního tripletu byly provedeny tyto testy: Fisher-Snedecorův test významnosti modelu, Scottovo kritérium multikolinearity, Cook-Weisbergův test heteroskedasticity, Jarque-Berrův test normality, Waldův test autokorelace, Durbin-Watsonův test autokorelace a Znaménkový test reziduí. Na základě těchto testů nebyly vyvozeny žádné negativní závěry, jež by ovlivnily věrohodnost regresních modelů.

Vytvořená kolekce neuronových sítí byla charakterizována těmito statistickými charakteristikami (Tab. 3):

Tab. 3 Statistické charakteristiky kolekce 100 neuronových sítí

Střední kvadratická chyba	10.85
Střední absolutní chyba	2.59
Střední relativní kvadratická chyba	0.01
Střední relativní absolutní chyba	0.08
Korelační koeficient	0.93

Model MARSplines obsahoval tři základní funkce a byl charakterizován těmito statistickými charakteristikami (Tab. 4):

Tab. 4 Statistické charakteristiky modelu MARSpline

Střední kvadratická chyba	12.07
Střední absolutní chyba	2.85
Střední relativní kvadratická chyba	0.02
Střední relativní absolutní chyba	0.10
Korelační koeficient	0.92
Koeficient determinace	0.85

Model Random Forests byl charakterizován těmito statistickými charakteristikami (Tab. 5):

Tab. 5 Statistické charakteristiky modelu Random Forests

Střední kvadratická chyba	15.12
Střední absolutní chyba	3.16
Střední relativní kvadratická chyba	0.02
Střední relativní absolutní chyba	0.10
Korelační koeficient	0.92

Pro účely validace výsledků bylo provedeno porovnání s lesní hospodářskou knihou zpracovanou v rámci lesního hospodářského plánu pro ŠLP Masarykův les Křtiny pomocí zonální statistiky, která sčítala hodnoty pixelů v každém polygonu porostu. V Tab. 6 - jsou uvedeny plochy porostů rozdělené na základě velikosti odchylky zásoby zjištěné pomocí různých metod z dat leteckého laserového skenování od zásoby uvedené v lesní hospodářské knize.

Tab. 6 Plochy porostů rozdělené podle velikosti odchylky zásoby zjištěné pomocí lineární regrese z dat leteckého laserového skenování od zásoby uvedené v lesní hospodářské knize

	Plocha porostů	Procentuální podíl
Celkem	549.83	100.00
Odchylka do 3 %	59.13	10.75
Odchylka do 5 %	95.78	17.42
Odchylka do 10 %	177.85	32.35
Odchylka do 15 %	256.24	46.60
Odchylka do 20 %	292.43	53.19
Odchylka do 25 %	333.42	60.64
Odchylka do 30 %	400.16	72.78

Tab. 7 Plochy porostů rozdělené podle velikosti odchylky zásoby zjištěné pomocí neuronových sítí z dat leteckého laserového skenování od zásoby uvedené v lesní hospodářské knize

	Plocha porostů	Procentuální podíl
Celkem	549.83	100.00
Odchylka do 3 %	78.94	14.36
Odchylka do 5 %	162.24	29.51
Odchylka do 10 %	226.53	41.20
Odchylka do 15 %	342.40	62.27
Odchylka do 20 %	374.53	68.12
Odchylka do 25 %	420.52	76.48
Odchylka do 30 %	451.57	82.13

Tab. 8 Plochy porostů rozdělené podle velikosti odchylky zásoby zjištěné pomocí MARSplines z dat leteckého laserového skenování od zásoby uvedené v lesní hospodářské knize

	Plocha porostů	Procentuální podíl
Celkem	549.83	100.00
Odchylka do 3 %	31.37	5.70
Odchylka do 5 %	65.73	11.95
Odchylka do 10 %	117.92	21.45
Odchylka do 15 %	159.58	29.02
Odchylka do 20 %	231.86	42.17
Odchylka do 25 %	287.63	52.31
Odchylka do 30 %	300.26	54.61

Tab. 9 Plochy porostů rozdělené podle velikosti odchylky zásoby zjištěné pomocí Random Forests z dat leteckého laserového skenování od zásoby uvedené v lesní hospodářské knize

	Plocha porostů	Procentuální podíl
Celkem	549.83	100.00
Odchylka do 3 %	40.44	7.36
Odchylka do 5 %	61.96	11.27
Odchylka do 10 %	137.44	25.00
Odchylka do 15 %	174.11	31.67
Odchylka do 20 %	226.72	41.23
Odchylka do 25 %	274.24	49.88
Odchylka do 30 %	340.34	61.90

DISKUSE

Výsledky plošné aplikace vytvořených regresních modelů vykazují různou kvalitu v závislosti na celé řadě faktorů. Nejlepších výsledků bylo dosaženo v případě výpočtu zásoby pomocí neuronových sítí. Zásoba na 40 % plochy všech porostů byla vypočítána s odchylkou do deseti procent od dat v lesní hospodářské knize, což je možné považovat i za obecnou přesnost lesních hospodářských plánů. Vzhledem k tomu, že se kvalita lesních hospodářských plánů v poslední době výrazně snížila, teoreticky můžeme považovat za správnou i odchylku do 15 % od údajů uvedených v lesním hospodářském plánu. Potom by plochy se správně vypočítanou zásobou představovaly 60,43 % ze všech porostů, ve kterých byl proveden výpočet. Metoda Random Forests zásobu poněkud nadhodnocuje (průměrně o 37 %), jelikož ve výsledném rastru nejsou žádné prázdné pixely reprezentující holiny a mladé porosty do 40 let věku. Nejhorších výsledků bylo dosaženo metodou MARSpline a to pravděpodobně z důvodu přeučení (overfittingu) modelu.

MEANS et al. (1999) dosáhl při výpočtu regresních modelů pro odhad výšky stromů, výčetní kruhové základny a objemu nadzemní biomasy v douglaskových porostech koeficientů determinace 0,95; 0,96 a 0,96. HOLLAUS (2006) dosáhl při zjišťování objemu kmene koeficientu determinace 0,87. NÆSSET (2002) vytvořil regresní modely pro horní výšku porostu, počet stromů a výčetní kruhovou základnu s koeficienty determinace mezi 0,5 až 0,93. Koeficient determinace pro model sloužící k výpočtu zásoby se pohyboval mezi 0,80 až 0,93. Nejhorší koeficient determinace (0,39 až 0,78) byl dosažen pro regresní rovnici pro výpočet výčetní tloušťky. BOUVIER et al. (2015) vytvořil regresní model pro odhad zásoby s koeficientem determinace 0,95 a regresní model pro odhad výčetní kruhové základny s koeficientem determinace 0,84. Všechny tyto modely byly vyvinuty pro jehličnaté porosty a do regresní analýzy vstupovalo 39 zkusných ploch. PATOČKA et al. (2015) použil deset zkusných ploch ze stejného souboru zkusných ploch jako v této práci a vytvořil tři regresní modely s koeficienty determinace 0,8 až 0,96. Při využití všech zkusných ploch pak koeficienty determinace klesly a zároveň byly použity jiné charakteristiky mračna bodů. YU et al. (2010) porovnával plošný přístup s individuální detekcí stromů a jeho regresní modely dosahovaly koeficientů determinace 0,84 pro výčetní tloušťku středního kmene a 0,79 pro objem středního kmene.

Dalším zdrojem chyb je skutečnost, že na zkusných plochách zcela dominovaly jehličnaté dřeviny, přičemž mezi porostními skupinami pro porovnání s LHP byly i porosty listnaté a dokonce porosty s bohatou strukturou. V těchto porostech jsou ale body leteckého laserového skenování zcela odlišně distribuovány a bylo by nutné provést měření také u listnáčů a vytvořit pro ně vlastní regresní model. Problémem však jsou smíšené porosty. Zde by bylo vhodné provést klasifikaci jednotlivých stromů z multispektrálních nebo ještě lépe hyperspektrálních snímků, tyto stromy sdružit do clusterů a každému clusteru pak přiřadit specifický regresní model.

Vzhledem ke kolísající přesnosti LHP je možné namítnout, že porovnání výsledků s lesní hospodářskou knihou není zcela vhodné. U některých porostních skupin je dokonce možné říci, že výpočet zásoby pomocí

leteckého laserového skenování je přesnější. Správná validace by spočívala ve zpětném porovnání s dalšími zkusnými plochami, které se neúčastnily tvorby regresních modelů a jsou tedy na těchto modelech nezávislé. Porovnání s LHP bylo zvoleno pro demonstrování možnosti navázání metody plošného přístupu na konvenční metody inventarizace lesa, což jako velkou výhodou popisuje také SHAN, TOTH (2008). Zároveň bylo cílem práce provést výpočet pro celé porostní skupiny, jelikož v zájmu lesnického provozu je znát zásobu celých porostních skupin, nikoliv pouze zkusných ploch. Provádět zpětnou validaci modelů v celých porostních skupinách průměrkováním naplno by pak bylo příliš časově náročné.

Jak bylo zmíněno v metodice, pro porovnání s LHP byla použita zonální statistika, která pracuje na principu tzv. pravidla absence a výskytu. Jestliže nějaký pixel zasahuje do polygonu porostu, je započítána celá jeho hodnota, nikoliv jen jeho poměrná část. Tato vlastnost může představovat zdroj drobných nepřesností. Jednotlivé porostní skupiny se mohou vyskytovat ve více polygonech, tzn., že jedna konkrétní porostní skupina se nachází vícekrát v jednom dílci na různých místech. Zároveň je pak hodnota zásoby, respektive výčetní kruhové základny porostní skupiny v lesní hospodářské knize společná pro několik polygonů. Proto bylo nutné přepočítat tyto taxační veličiny na plochu konkrétního polygonu. Zásoba, respektive výčetní kruhová základna však nemusí být distribuována rovnoměrně po celé porostní skupině (ve všech polygonech porostní skupiny).

ZÁVĚR

Tato studie ukázala, že je možné aplikovat technologii leteckého laserového skenování nejenom v boreálních lesích, kde se používá v praxi již více než deset let, ale i v lesích na území České republiky. Toto téma je aktuální zejména z toho důvodu, že se v současné době dokončuje digitální model povrchu 1. generace, který není sice zcela vhodný pro aplikaci v inventarizaci lesa, ale i přesto je možné jej využít a to na území celé republiky.

Výhoda plošného přístupu ke zpracování dat leteckého laserového skenování spočívá zejména v možnosti navázání na konvenční způsoby inventarizace lesa, dále umožňuje snížit potřebný počet zkusných ploch a zároveň eliminovat chybu způsobenou výběrem nereprezentativních zkusných ploch.

K aplikaci do lesnického provozu ještě chybí několik kroků. Zejména bude potřebné data leteckého laserového skenování zkombinovat s hyperspektrálními snímky tak, aby bylo možné zjišťovat i dřevinnou skladbu porostů. Dále vyvinout modely pro různé dřeviny a na základě segmentace hyperspektrálních snímků přiřadit každému segmentu specifický model. Určitého zpřesnění výsledků může být také dosaženo kombinací s metodou individuální detekce stromů.

Poděkování

V textu jsou publikovány výsledky, které vznikly za podpory z projektu Lesnické a dřevařské fakulty Mendelovy univerzity v Brně IGA 13/2015 „Využití dat leteckého laserového skenování zpracovaných metodou plošného přístupu pro zjišťování taxačních charakteristik“.

LITERATURA

BREIDENBACH, J., NÆSSET, E., LIEN, V., GOBAKKEN, T., SOLBERG, S. 2010. Prediction of species specific forest inventory attributes using a nonparametric semiindividual tree crown approach based on fused airborne laser scanning and multispectral data. *Remote Sensing of Environment* 114 (4), 911–924

BREIMAN L., 2001. Random forests. *Machine Learning*, 45: 5-32.

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.

HALAJ, J. 1959. Prieskum výškovej vzrastavosti drevín na Slovensku a návrh stupnic výškových bonít. *Lesnícký časopis*, 3–4: 173–204.

- HOLLAUS M. 2006. Large Scale Applications of Airborne Laser Scanning for a Complex Mountainous Environment. Ph.D. thesis. Vienna University of Technology; Vienna, Austria, 127 s.
- HUDAK, A. T., CROOKSTON, N. L., EVANS, J. S., HALL, D. E., FALKOWSKI, M. J., 2008. Nearest neighbor imputation of species-level, plot-scale forest structure attributes from LiDAR data. *Remote Sensing of Environment*, 112 (5): 2232–2245.
- HYYPÄ J., HYYPÄ H., LECKEE D., GOUGEON F., YU X., MALTAMO M. 2008. Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. *International Journal of Remote Sensing*, 29: 1339–1366.
- HYYPÄ J., INKINEN M. 1999. Detecting and estimating attributes for single trees using laser scanner. *The Photogrammetric Journal of Finland* 16 (2): 27–42.
- FRIEDMAN, J. H., 1991. Multivariate Adaptive Regression Splines. *Annals of Statistics*, 19, 1–67.
- GOUGEON F. A. 1995. A crown following approach to the automatic delineation of individual tree crowns in high spatial resolution digital images. *Canadian Journal of Remote Sensing*, 21: 274–284.
- JEDLIČKA K. 2009. Accuracy of surface models acquired from different sources – important information for geomorphological research. *Geomorphologia Slovaca et Bohemica*, 9 (1): 17–28.
- JIRINA, M. 2003. Jak na neuronové sítě v programu Statistica. 1 vyd. Praha: Statsoft. 73 s.
- JUNTTILA, V., MALTAMO, M., KAURANNE, T. 2008. Sparse Bayesian estimation of forest stand characteristics from airborne laser scanning. *Forest Science*, 54: 543–552.
- KAARTINEN, H., HYYPÄ, J. 2008. EuroSDR/ISPRS Project, Commission II “Tree Extraction”, Final Report, EuroSDR. European Spatial Data Research, Official Publication No 53.
- KORPELA I., KOSKINEN M., VASANDER H. 2009. Airborne small-footprint discrete-return LiDAR data in the assessment of boreal mire surface patterns, vegetation, and habitats. *Forest Ecology and Management*, 258: 1549–1566.
- MALTAMO M., MALINEN J., PACKALÉN P., SUVANTO A., KANGAS J. 2006. Nonparametric estimation of stem volume using airborne laser scanning, aerial photography and stand-register data. *Canadian Journal of Forest Research*, 36 (2): 426–436.
- MCGAUGHEY R., 2014. FUSION/LDV: Software for lidar data analysis and visualization. Version 3.41. Seattle, WA: U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station [online]. Dostupné na WWW: <http://forsys.cfr.washington.edu/fusion/fusionlatest.htm>
- MEANS, J.E., ACKER, S.A. D.J. HARDING, J.B. BLAIR, M.A. LEFSKY, W.B. COHEN, M.E. HARMON, MCKEE W.A. 1999. Use of large-footprint scanning airborne lidar to estimate forest stand characteristics in the western Cascades of Oregon, *Remote Sensing of Environment*, 67 (3): 298–308.
- MICHAILOFF, I. 1943. Zahlenmäßiges Verfahren für die Ausführung der Bestandeshöhenkurven. *Forstwissenschaftliches Centralblatt*, Heft 6: 273–279.
- NÄSLUND M. 1947. Functions and tables for computing the cubic volume of standing trees: pine, spruce and birch in Southern Sweden and in the whole of Sweden. Report 36. Stockholm, National Forest Research Institute: 81 s.
- NÆSSET E. 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sensing of Environment*, 80 (1), 88–99.
- NÆSSET E. 2004. Practical large-scale forest stand inventory using a small-footprint airborne scanning laser. *Scandinavian Journal of Forest Research*, 19: 164–179.
- NOVOTNÝ, J. 2014. Tree crown delineation using growing and active contour: Approach introduction. Mendel2014: 20th International Conference on Soft Computing, vol. 20, Brno University of Technology, Brno.

PATOČKA, Z., SABOL, J., MIKITA, T., CARBOL, S. 2015. Využití plošného přístupu ke zpracování dat leteckého laserového skenování v inventarizaci lesa. In Praktické využití GIS v lesnictví a zemědělství 2015. Brno, Mendelova univerzita v Brně: 1–6.

PETRÁŠ, R., PAJTIK, J. 1991. Sústava česko-slovenských objemových tabuliek dřevín. Lesnícky časopis, 37, (1): 49–56.

Pošík P. 2003. Jak na data mining v programu STATISTICA Data Miner. Praha: StatSoft, 2008. 78 s. ISBN 978-80-903630-6-9.

SHAN J., TOTH C. K. 2008. Topographic Laser Ranging and Scanning: Principles and Processing. CRC Press/Taylor & Francis, London, England, UK, 590 s

SUVANTO, A., MALTAMO, M., PACKALÉN, P., KANGAS, J. 2005. Kuviokohtaistenpuustotunnusten ennustaminen laserkeilauksella. Metsätieteen aikakauskirja, 2005 (4): 413–428.

ŠMELKO, Š., PÁNEK, F., ZANVIT, B. 1987. Matematická formulácia systému jednotných výškových kriviek rovnovekých porastov SSR. Acta Facultatis Forestalis Zvolen, XXIV, s. 151-173.

VASTARANTA, M., KANKARE, V., HOLOPAINEN, M., YU, X., HYYPPÄ, J., HYYPPÄ, H., 2012. Combination of individual tree detection and area-based approach in imputation of forest variables using airborne laser data. ISPRS Journal of Photogrammetry and Remote Sensing 67: 73–79. doi:10.1016/j.isprsjrs.2011.10.006

VINCENT, L., SOILLE, P. 1991. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. IEEE PAMI, 13 (6): 583–598.

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 the area-based approach. Information Report FI-X-10. Natural Resources Canada, Canadian Forest Service, Canadian Wood Fibre Centre, Pacific Forestry Centre, Victoria, BC. 50 s.

YU X., HYYPPÄ J., HOLOPAINEN M., VASTARANTA M. 2010. Comparison of area-based and individual tree-based methods for predicting plot-level forest attributes. Remote Sensing, 2: 1481–495. DOI: 10.3390/rs2061481