

**JIHOČESKÁ UNIVERZITA V ČESKÝCH
BUDĚJOVICÍCH
ZEMĚDĚLSKÁ FAKULTA**

Katedra krajinného managementu

Studijní obor: Aplikovaná a krajinná ekologie

DISERTAČNÍ PRÁCE

**HODNOCENÍ SEKVESTRAČNÍHO POTENCIÁLU
VEGETACE/POROSTŮ REKULTIVOVANÝCH
VÝSYPEK METODAMI DPZ**

Vypracoval: Ing. Miroslav Píkl

Školitel: doc. Mgr. Ing. František Zemek, Ph.D.

2018

Prohlášení

Prohlašuji, že jsem disertační práci vypracoval samostatně na základě vlastních zjištění a za pomoci uvedené literatury.

V Brně

Poděkování

Rád bych poděkoval vedoucímu disertační práce doc. Mgr. Ing. Františku Zemkovi, Ph.D., za pomoc a rady, které mi poskytoval v průběhu doktorského studia.

Dále bych rád poděkoval Prof. Ing. Mgr. Janu Frouzovi, CSc. a Mgr. Olze Vinduškové, Ph.D., za pomoc a cenné rady, které mi poskytli při řešení této práce.

Také bych rád poděkoval Ústavu výzkumu globální změny AV ČR v. v. i. za zázemí, které mi během studia poskytoval.

Nemalý dík patří i rodině, přátelům a kolegům, kteří mě v průběhu studia podporovali.

Abstrakt

Práce si klade za cíl zhodnocení a mapování množství uhlíku alokovaného v nadzemní biomase dřevin a organominerálním půdním horizontu na plochách, které vznikly jako úložiště hlušiny po povrchové těžbě hnědého uhlí v oblasti Sokolovské uhelné pánve. Pro dosažení tohoto cíle jsou kombinována data získaná z pozemních měření, laboratorních analýz odebraných vzorků a data leteckého dálkového průzkumu, jmenovitě hyperspektrální data pro oblast viditelného a blízkého infračerveného záření a data leteckého laserového skenování. Vyhodnocení dat je založeno na digitální analýze obrazu, GIS modelování a multivariačních statistických metodách.

Výsledky ukazují, že v rámci celého zájmového území (209 ha) je v nadzemní biomase porostů vzniklých cílenou rekultivací a spontánní sukcesí vázáno 7,6 tis. tun uhlíku a v půdním A horizontu pod porosty, v závislosti na metodě výpočtu, 8,1 až 12,2 tis. tun uhlíku. V rámci testovaných hypotéz byl prokázán 1/ statisticky významný negativní vztah ($p < 0,01$) mezi svažitostí terénu a množstvím půdního uhlíku, přičemž vyšší vliv se projevil pro skupinu listnatých porostů; 2/ statisticky významný rozdíl ($p < 0,05$) v množství v půdě vázaného uhlíku pod skupinami listnatých a jehličnatých druhů i pod třídami druhů, nejvyšší pro olše (*Alnus sp.*) a borovice (*Pinus sp.*); 3/ statisticky významný vztah ($p < 0,05$) mezi množstvím uhlíku vázaného v půdě a v nadzemní biomase pro skupinu jehličnatých dřevin a třídu spontánní sukcese.

Klíčová slova: půdní uhlík, nadzemní biomasa, dálkový průzkum Země, rekultivace výsypek

Abstract

The study aims at estimation and mapping the amount of carbon allocated in above ground biomass of wood and in organo-mineral soil horizon at sites where reclamation and spontaneous succession took place on spoil heaps after coal mining. Several categories of data have been used to meet the objectives, namely ground field measurements, laboratory analyses of soil samples, airborne hyperspectral data from VNIR region, and airborne LiDAR scanning data. The digital imagery analysis, GIS modeling and multivariation statistical methods were applied in data assessment.

The results show that there is a 7 600 tons of carbon allocated in above ground wood biomass in the area of 209 ha, and 8 100–12 200 tons in the soil A horizon in the region of the same size. The results proofed: 1/ statistically significant negative relationships ($p < 0,01$) between slope and amount of soil carbon, where higher negative correlation was for broad leaved species; 2/ statistically significant difference ($p < 0,05$) between amount of soil carbon under broad leaved and needle classes and under different species, the highest between soils under *Alnus sp.* and *Pinus sp.*; 3/ statistically significant relationships ($p < 0,05$) between the amount of carbon allocated in the aboveground wood biomass and that in the soil A horizon under the needle leaved class and under the spontaneous wood vegetation.

Key words: soil organic carbon, above ground biomass, remote sensing, reclamation of spoil heaps

Obsah

1 Úvod.....	8
2 Literární přehled.....	8
2.1 Environmentální dopady těžby uhlí.....	10
2.2 Nápravná opatření.....	12
2.3 Souhrn přístupů pro hodnocení množství nadzemní biomasy.....	13
2.3.1 Techniky DPZ využívané pro studium nadzemní biomasy.....	14
2.3.1.1 Stručný přehled technik DPZ vztažený k předkládané práci.....	14
2.3.1.2 Historie a vývoj DPZ v kontextu lesní biomasy.....	18
2.3.1.3 Plošný přístup odhadu množství nadzemní biomasy.....	21
2.3.1.4 Odhad nadzemní biomasy pomocí identifikace jednotlivých stromů.....	21
2.3.1.5 Metody klasifikace.....	22
2.4 Hodnocení obsahu půdního organického uhlíku pomocí DPZ.....	25
2.5 Půdní uhlík na hnědouhelných výsypkách.....	27
3 Hypotézy disertační práce.....	28
4 Metodika.....	28
4.1 Popis lokality.....	28
4.2 Data dálkového průzkumu Země.....	30
4.2.1 Letecká hyperspektrální data.....	30
4.2.2 Data leteckého laserového skenování.....	31
4.3 Stanovení množství nadzemní biomasy a půdního uhlíku na základě terénních měření.....	33
4.3.1 Data 2006 a jejich zpracování.....	33
4.3.2 Data 2015 a jejich zpracování.....	35
4.3.2.1 Stanovení obsahu recentního uhlíku metodou ¹⁴ C radiokarbonové hmotnostní spektrometrie.....	35
4.3.3 Data 2017 a jejich zpracování.....	36
4.3.4 Stanovení množství recentního uhlíku v A horizontu.....	37
4.3.4.1 Korekce množstvím uhlíku v horizontu C ($A_{C_{RADIO}}$).....	37
4.3.4.2 Korekce množstvím uhlíku v horizontu C upraveným konstantou ($A_{C_{KRIB}}$).....	38
4.3.4.3 Korekce podílem recentního uhlíku v horizontu A ($A_{A_{RADIO}}$).....	38
4.3.4.4 Výpočet zásoby uhlíku v horizontu A.....	38
4.3.5 Hodnocení vlivu druhového složení na množství půdního uhlíku.....	38
4.3.6 Hodnocení vztahu půdního uhlíku a orografie.....	39
4.4 Analýza změny vegetačního pokryvu v oblasti výsypky.....	39
4.5 Klasifikace tříd druhů na základě dat DPZ.....	42
4.5.1 Klasifikace datové sady 2009+2010.....	43
4.5.2 Klasifikace datové sady 2017.....	43
4.6 Odhad množství nadzemní biomasy na základě dat DPZ.....	44
4.6.1 Odhad množství uhlíku nadzemní biomasy z dat 2009+2010.....	44
4.6.2 Odhad množství uhlíku nadzemní biomasy z dat 2017.....	45
4.6.2.1 Identifikace jednotlivých stromů z dat ALS.....	46
4.6.2.2 Verifikace hustoty stromů a jejich výšky.....	47
4.6.2.3 Odhad množství nadzemní biomasy.....	47

4.7	Zásoba půdního uhlíku.....	48
4.7.1	Analýza dat 2009+2010.....	48
4.7.2	Hodnocení vztahů půdního uhlíku a množství nadzemní biomasy.....	48
4.7.3	Prostorová distribuce půdního uhlíku 2017.....	49
5	Výsledky.....	50
5.1	Výsledky terénních šetření.....	50
5.1.1	Výsledky z dat 2006.....	50
5.1.2	Výsledky z dat 2015.....	50
5.1.3	Výsledky z dat 2017.....	52
5.1.3.1	Další faktory prostředí z dat 2017.....	54
5.1.4	Zásoba uhlíku na zkusných plochách.....	56
5.1.5	Vztah obsahu uhlíku v půdě a objemové hmotnosti na zkusných plochách.....	60
5.1.6	Vztah obsahu uhlíku v půdě a orografie na zkusných plochách.....	60
5.2	Změna vegetačního pokryvu v oblasti výsypky.....	61
5.3	Výsledky objektově orientované klasifikace.....	64
5.3.1	Klasifikace dat 2009+2010.....	64
5.3.2	Klasifikace dat 2017.....	66
5.4	Odhad množství uhlíku nadzemní biomasy dřevin.....	67
5.4.1	Množství uhlíku odhadnuté z dat 2009.....	67
5.4.2	Množství uhlíku odhadnuté z dat 2017.....	69
5.4.2.1	Identifikace stromů z dat ALS.....	69
5.4.2.2	Odhad množství uhlíku nadzemní biomasy.....	71
5.4.3	Celková zásoba uhlíku nadzemní biomasy.....	73
5.5	Zásoba půdního uhlíku.....	75
5.5.1	Analýza dat 2009+2010.....	75
5.5.2	Vztah obsahu uhlíku v půdě a nadzemní biomasy na zkusných plochách.....	76
5.5.3	Prostorová distribuce půdního uhlíku 2017.....	77
6	Diskuse.....	79
6.1	Změna pokryvu.....	79
6.2	Klasifikace tříd druhů.....	80
6.3	Uhlík nadzemní biomasy.....	81
6.4	Půdní uhlík.....	84
7	Závěry.....	88
8	Seznam literatury.....	91
9	Přílohy.....	115

1 Úvod

Uhlík je jedním ze základních stavebních prvků zemské bioty a toky uhlíku patří k základním cyklům energie a hmoty na Zemi. Znalosti o míře využití a poutání uhlíku organismy v nadzemní a podzemní biomase, následné procesy dekompozice biomasy a transformace do jiných forem v půdě, a opětovné uvolňování uhlíku do atmosféry, umožňují lidem aktivně reagovat s cílem stabilizace těchto procesů. Většina výše zmíněných procesů se odehrává v dlouhodobějším časovém měřítku (např. transformace organického uhlíku v půdě). Některé z těchto procesů se dají simulovat laboratorně nebo polními experimenty bodového a/nebo maloplošného rozsahu. Pro některé z takových studií může být limitující, že probíhají v již „stabilně fungujícím“ prostředí, což neumožňuje dostatečně přesně popsat výchozí podmínky experimentu. Naproti tomu výsypky, vznikající při povrchové těžbě uhlí, se z jistého pohledu jeví jako unikátní prostředí pro hodnocení ukládání uhlíku v biomase a půdě v tom ohledu, že můžeme dostatečně přesně určit jak počáteční podmínky (chemické složení a fyzikální vlastnosti materiálu), iniciovat proces využití území rostlinami volbou způsobu rekultivace a procesy probíhají v plošně větším měřítku, které je bližší přirozenému stavu. S rostoucí plochou se studování projevů akumulace uhlíku klasickými terénními metodami stává komplikovanější. V takových případech může dálkový průzkum Země poskytnout informace o faktorech, které se na akumulaci uhlíku podílejí nebo jsou jejím projevem.


Práce si klade za cíl zhodnocení/zmapování množství uhlíku alokovaného v nadzemní biomase dřevin a v organominerálním půdním horizontu na rekultivovaných plochách, stejně jako na plochách spontánní sukcese, vzniklých jako úložiště hlušiny po povrchové těžbě hnědého uhlí v oblasti Sokolovské uhelné pánve. Pro dosažení tohoto cíle jsou kombinována data získaná z pozemních měření, jejich laboratorních analýz a data leteckého dálkového průzkumu, jmenovitě hyperspektrálních data pro oblast viditelného a blízkého infračerveného záření a data laserového leteckého skenování. Vyhodnocení dat je založeno na digitální analýze obrazu, GIS modelování a multivariačních statistických metodách.

2 Literární přehled

Oxid uhličitý je jedním z často diskutovaných témat v kategorii tzv. skleníkových plynů. Značná pozornost je věnována uhlíkovému cyklu, a to jak z hlediska zdrojů, ze kterých je CO₂ uvolňován, tak i z hlediska možných dlouhodobých způsobů fixace CO₂. Hlavním zdrojem emisí CO₂ je energetický a těžký průmysl, který produkuje asi 60 % celkového množství CO₂. Průmyslové emise jsou většinou produkovány velkými lokálními zdroji, což představuje určitý potenciál pro zavádění technologií snižujících

uvolňování CO₂ do atmosféry (Gale et al. 2005). Dalším výrazným zdrojem CO₂, který se na celkovém množství uhlíku uvolněného do atmosféry podílí asi jednou čtvrtinou, je odlesňování (Pachauri 2008). V souvislosti s lesními ekosystémy je v současnosti studován vliv rostoucích teplot na rychlost dekompozice organické hmoty uložené v permafrostu, případně v organických horizontech boreálních lesů, které mohou představovat další výrazný zdroj uhlíkových emisí ať už ve formě CO₂ nebo CH₄ (Schädel et al. 2016; Helbig et al. 2017).

Přestože je energetický průmysl jedním z hlavních zdrojů CO₂, představuje v současnosti uhlí jeden z hlavních zdrojů energie a tudíž i jednu z významných složek uhlíkového cyklu. V současnosti se z uhlí generuje asi 40 % elektrické energie, přičemž v Číně jakožto největším spotřebiteli je to asi 80 %. Uhlí je relativně snadno dostupná surovina, která se vyskytuje prakticky ve všech geografických oblastech Země, i když jeho celkové zdroje jsou vyčerpatelné. Nelze proto očekávat, že by v blízké budoucnosti došlo k výraznému omezení využití uhlí jako energetické suroviny (World Energy Council 2013), naopak se předpokládá, že do roku 2030 by spotřeba uhlí mohla vzrůst asi o 50 % (Obr 1), přičemž nejvíce se na nárůstu budou podílet dynamicky se rozvíjející země (World Energy Council 2013).



Obr 1: Model produkce uhlí podle geografických oblastí.
Převzato z Mohr et al. (2015)

2.1 Environmentální dopady těžby uhlí

Jedním ze způsobů těžby uhlí a některých dalších surovin je povrchová těžba. Ta souvisí s nutností odstranění vegetačního krytu, půdy a ostatních nadložních vrstev. Těžba uhlí je tudíž výrazným zásahem do krajiny, který ovlivňuje řadu jejích funkcí. Mezi hlavní environmentální dopady těžby uhlí patří: změna charakteru krajiny, zábor území pro vlastní těžbu, zábor území pro ukládání hlušiny, narušení vegetačního krytu, degradace půd, změna vodního režimu krajiny, znečištění půd, vod a ovzduší (Kuter 2013).

Krajina

Projevy celkových dopadů těžby uhlí na krajinu jsou rozsáhlé a velmi dobře patrné i pouhým okem. Skládky hlušiny, velká těžební technika a přilehlá infrastruktura na zpracování vytváří výrazné krajinné dominanty. Samotná těžební oblast je krajinnou dominantou zejména v případě povrchové těžby. Nicméně i podpovrchovou těžbu doprovází charakteristické projevy. Vlivem poddolování může docházet k poklesům terénu, nebo v případě horší stability k trhlinám, propadům nebo sesuvům. V důsledku těchto pohybů může docházet k poškození veřejné infrastruktury a budov nebo omezení některých dalších funkcí krajiny (Dong et al. 2015). Pokles terénu v důsledku těžby je problematický zejména v Číně, kde asi 95 % produkce uhlí pochází z podpovrchové těžby (Bian et al. 2010). Projevy poklesu terénu v souvislosti s těžbou uhlí byly dokumentovány i v ČR nebo sousedním Polsku (Marschalko et al. 2012; Perski 1998).

Dalším typickým projevem těžby jsou skládky hlušiny, které zejména v případě povrchové těžby mohou výrazně měnit charakter krajiny. Jelikož se uhlí vyskytuje ve vrstvách, které jsou zakryty dalšími vrstvami usazenin (pískovcem, břidlicemi a jílovcem), je v případě povrchové těžby potřeba odtěžit v průměru 0,5–2 t hlušiny pro získání 1 t uhlí (Skarżyńska 1995). Tato hlšina je nejprve skládkována na vnějších výsypkách a až v pozdějších fázích těžby je ukládána uvnitř vlastního těžebního prostoru.

Ovzduší

V souvislosti s těžbou uhlí dochází rovněž ke znečišťování ovzduší. Mezi hlavní polutanty v souvislosti s těžbou uhlí patří prachové částice, volatilní látky a plyny, z nichž nejvýznamnější jsou metan, oxidy síry a dusíku. Při těžbě a následném zpracování vznikají prachové částice různé velikosti (PM_{2.5}, PM₁₀). V nejvyšších koncentracích se vyskytují v okolí těžební techniky (Sastri et al. 2015), ale zvýšené koncentrace se vyskytují i v širším okolí a kromě zdravotního stavu obyvatelstva mohou v závislosti na složení působit i na produkční potenciál zemědělských plodin pěstovaných v oblasti (Arup Environmental and Great Britain. Minerals Division 1996). Dalším velmi významným polutantem je metan. V uhelných ložiscích se vyskytuje v různých koncentracích a uvolňuje se během těžby. V případě hlubinné těžby je

následně v nízkých koncentracích (0,1–1 %_{obj}) odváděn ve ventilačním vzduchu. Odhaduje se, že těžba uhlí přispívá do globální antropogenní produkce metanu přibližně 10 % (Cheng et al. 2011).

V souvislosti s těžbou uhlí je uvolňován i oxid uhličitý ze dvou hlavních zdrojů. Odlesněním a změnou využití krajiny na zemědělskou půdu, což může být i případ využití skřívky zeminy dochází k redukci množství půdního organického uhlíku (SOC) mezi 8,5–42 % v závislosti na kombinaci geografických, klimatických podmínek a následného managementu území. Druhým zdrojem je výroba energie pro vlastní těžbu. Spotřeba energie v povrchovém uhelném dole je v rozmezí 14,5–30 kWh·t⁻¹ vytěženého uhlí (BCS, Incorporated 2002) což odpovídá zhruba 3,5–10,5 kg CO₂ na 1 t vytěženého uhlí v závislosti na kombinaci použitých technologií.

Voda

Vodní prostředí je důlní činností ovlivněno dvěma způsoby: změnou odtokových poměrů a hladiny podzemní vody, změnou chemického složení a pH.

Hlavním důsledkem těžby je změna odtokových poměrů. Vlivem důlní činnosti dochází k výrazné změně orografických charakteristik území a tudíž i ke změnám směru proudění a akumulace vody. Ke změně odtokových poměrů a zejména hladiny podzemní vody může docházet i vlivem hlubinné těžby a souvisejících poklesů terénu. V návaznosti na změnu odtokových poměrů v území může docházet i ke zvýšení půdní eroze, zanášení toků a zvyšování množství nerozpuštěných částic ve vodním prostředí.

Dalším typickým projevem důlní činnosti na vodní prostředí je změna pH, která souvisí s geologickým složením těžených vrstev. Spolu s uhlím se vyskytuje určité množství pyritu (případně jiných sloučenin síry), typicky 1 – 20 %, který je v přírodě nejčastěji se vyskytujícím sulfidem (Johnson a Hallberg 2005). Při změně odtokových poměrů, které těžba způsobuje, může docházet k pronikání vody a vzduchu do těchto vrstev bohatých na sloučeniny síry a v důsledku změny oxidoredukčních podmínek k oxidaci pyritu a acidifikaci protékající vody. Tento proces může být dále urychlen činností některých druhů mikroorganismů (Johnson 2003). Nízké pH zvyšuje rozpustnost některých kovů – Al, Fe, Mn nebo As. Tyto kovy způsobují tzv. minerální kyselost tím, že při jejich dalších reakcích ve vodném prostředí dochází k uvolňování H⁺ iontů. K acidifikaci vody může docházet i v případě výsypek. Někdy je poukazováno i na to, že v případě výsypek může být projev acidifikace výraznější než v případě vlastního důlního prostředí v důsledku velkého relativního povrchu a vyšší koncentrace sirných materiálů (Johnson a Hallberg 2005).

Půda

Povrchová těžba má výrazný vliv na půdní prostředí. Po provedení skrývky může být půda dočasně skladována, aby mohla být následně použita při rekultivaci. Půda je navršena a po několik let ponechána v nepřírozeném stavu. Při dlouhodobém navršení dochází ke zhutnění, degradaci půdní struktury a změně oxidoredukčních podmínek, což může dále ovlivnit dostupnost některých živin (Ghose 2001).

Půda v blízkém okolí uhelných dolů může být kontaminována řadou těžkých kovů v závislosti na podmínkách (klimatických), ve kterých těžené vrstvy vznikaly. Kovy těchto vrstev lze rozlišit do 3 kategorií (Bhuiyan et al. 2010):

- kovy vyskytující se v souvislosti s nadložními vrstvami. Z těchto vrstev se uvolňuje především Mn, Pb, Sr, Zn, což jsou zároveň kovy, které reagují s půdní organickou hmotou.
- kovy v uhelných vrstvách, uhelném prachu a popílku. V těchto materiálech se vyskytují vysoká množství As, Fe a Ti.
- kovy, které se uvolňují z povrchových krust. Jedná se zejména o Nb a Zr.

2.2 Nápravná opatření

Výše popsané zásahy do krajiny, při nichž krajina ztrácí většinu svých ekosystémových funkcí, vyústily v průběhu 20. století v legislativní úpravu regulující nápravná opatření spojená s ukončením těžby. Bradshaw (1996) rozlišuje opatření podle cílového stavu:

- obnovu (restoration) – uvedení do perfektně stejného stavu jako před těžbou,
- rehabilitaci (rehabilitation) – uvedení do předchozího stavu s menším důrazem na dosažení přesně stejného stavu,
- remediaci (remediation) – uvedení do stavu, který je vhodný pro určité využití,
- nahrazení (replacement) – změna na jiné využití než před těžbou.

Jedním z možných rekultivačních opatření je lesnická rekultivace, která je často využívána i v ČR (Prach et al. 2011). Z pohledu uhlíkové bilance jsou lesní ekosystémy v současnosti uvažovány jako jeden z prostředků, jak přispět ke snižování koncentrace oxidu uhličitého v atmosféře. Lesní ekosystémy mohou fixovat uhlík dlouhodobě, přičemž v raných sukcesních stádiích byla na rekultivovaných plochách pozorována velmi výrazná schopnost porostů fixovat uhlík v nadzemní biomase a v půdě (Turner et al. 2004). V dalších sukcesních stádiích se ukládání relativně zpomaluje, ale k akumulaci uhlíku může docházet i několik stovek let, podobně jako u lesních ekosystémů (Houghton 2005). V lesích je globálně alokováno asi 50 % uhlíku obsaženého ve vegetaci (Food and Agriculture Organization of the United Nations

2015) a asi 50 % uhlíku obsaženého v půdě (J. Dong et al. 2003). Z hlediska globální bilance uhlíku jsou v současnosti lesy jak zdrojem tak úložištěm oxidu uhličitého, přičemž ze zpráv jednotlivých zemí vyplývá, že k ukládání uhlíku dochází v zemích Severní Ameriky, Evropy a Asie. Pro lesy Jižní Ameriky a Afriky je hlášen výrazný pokles množství uloženého uhlíku (Köhl et al. 2015).

V rámci mezinárodních úmluv se řada států zavázala regulovat množství skleníkových plynů. Bilance uhlíku, které jsou připravované v rámci těchto dohod a programů (REDD+, FAO), kalkulují i se změnami množství uhlíku vázaného v lesních ekosystémech a jsou sestavovány na základě různých zdrojů. Jedním z nich jsou výsledky národních inventarizací lesů. Přestože tyto metody dosahují relativně vysoké přesnosti v odhadu množství nadzemní biomasy, často postrádají informaci o prostorové variabilitě. V případě oblastí, kde se inventarizace neprovádí, je umožněno získávat potřebné informace prostřednictvím dálkového průzkumu Země.

2.3 Souhrn přístupů pro hodnocení množství nadzemní biomasy

V zemích, kde je krajina dlouhodobě intenzivně využívána (převážně Evropa), byla postupně vyvinuta řada lesnických přístupů pro měření/odhad různých charakteristik jednotlivých stromů v porostu s následným statistickým vyhodnocením v rámci větších porostních celků. Těmito postupy lze odhadovat např. objem kmene (Muukkonen 2007), množství celkové nadzemní biomasy a podzemní biomasy (Bond-Lamberty et al. 2002), množství jednotlivých složek nadzemní biomasy, např. hroubí, větroví, olistění (Turski et al. 2008) a další parametry. Přímá měření těchto parametrů nejsou v rámci inventarizace možná, protože jsou spojena s destrukcí stromů. Proto jsou využívány především nepřímé metody, založené na alometrických rovnicích (získávaných destruktivními metodami), do kterých vstupují snáze měřitelné veličiny, jako jsou průměr kmene ve výčetní výšce (DBH), výška stromu, průmět koruny, věk nebo výška nasazení koruny. Pro odhad množství biomasy jednotlivých stromů se pak nejčastěji používá exponenciální typ modelu, přičemž často se vychází jen z DBH. Tato veličina je v terénu snadno měřitelná, při jejím měření vzniká malá chyba a zároveň bylo zjištěno, že v některých případech zahrnutí výšky významně nepřispívá ke zpřesnění odhadu (Wang 2006). Stanovení množství biomasy v určitém území je pak založeno na statistickém vyhodnocení sledovaných parametrů získaných na reprezentativních zkusných plochách v prvním kroku nejčastěji pomocí distribučních funkcí (Reineke 1933; Cao 2004) a následně prostřednictvím průměrného množství biomasy pro jednotlivé lesní celky (Botkin et al. 1993). Tento přístup je v případě větších území značně pracovně, ale i finančně náročný, a ve smyslu prostorové variability nemusí poskytovat dostatečnou přesnost odhadu. Pro zpřesnění popisu prostorové variability

distribuce nadzemní biomasy (AGB) lze využít geostatistické metody, které mohou využívat jako kovarianty klimatické nebo orografické podmínky (Sales et al. 2007; Li et al. 2015). Souhrn přístupů k hodnocení AGB a jejich hlavních limitujících faktorů uvádí (Shi a Liu 2017), viz Tab 1.

*Tab 1: Přístupy využívané pro odhad AGB a jejich hlavní limitující faktory.
Zdroj: Shi a Liu (2017)*

Metoda	Měřítko	Limitující faktor
alometrické rovnice	jednotlivé stromy, lokální stanoviště	variabilní v závislosti na druhu a lokálních podmínkách (orografie, klima)
průměrná hustota biomasy	lokální stanoviště, porostní celky	náchylnost k nadhodnocování
expanzní faktory	lokální stanoviště	variabilní v závislosti na druhu a lokálních podmínkách (orografie, klima)
dálkový průzkum Země	lokální stanoviště, porostní celky	saturace signálu senzoru, efekt orografie a struktury vegetace
geo-statistické metody	porostní celky	množství vstupních dat

I z těchto důvodů jsou dlouhodobě hledány automatizovatelné, reprodukovatelné, přesnější a ekonomicky efektivnější přístupy pro odhad nadzemní biomasy lesních porostů. Z tohoto pohledu se prostředky dálkového průzkumu Země (DPZ) dlouhodobě ukazují jako jeden z hlavních nástrojů pro zpřesnění nebo přímé stanovení zásob nadzemní biomasy zejména při mapování rozsáhlých a nepřístupných území. Jejich velkou výhodou je standardizace procedur měření a opakovatelnost a to i na globální úrovni. Kromě sledování AGB umožňují metody DPZ i sledování dalších charakteristik, jako jsou druhové složení, listová plocha (LAI) (Lefsky et al. 1999), zdravotní stav (Campbell et al. 2004) nebo poškození vlivem škůdců (Lawrence a Labus 2003).


2.3.1 Techniky DPZ využívané pro studium nadzemní biomasy

Senzory a metody DPZ využitelné pro odhad množství AGB se mohou lišit v závislosti na prostorovém měřítku, ve kterém jsou sledované parametry hodnoceny. Pro sledování lesních porostů včetně odhadu množství nadzemní biomasy se využívají tři úrovně senzorů: satelitní, letecké a terestriální; používané techniky měření jsou pasivní a aktivní; přístupy k vyhodnocení zahrnují hodnocení na úrovni plošné (nejmenší jednotkou je pixel), nebo na úrovni jednotlivých stromů.

2.3.1.1 Stručný přehled technik DPZ vztažený k předkládané práci

Dálkový průzkum Země se řadí mezi nepřímé, bezkontaktní způsoby měření. Při bezkontaktních metodách měření není čidlo v přímém kontaktu se sledovaným

objektem, ale měří vlastnosti jiného média, které se sledovaným objektem interaguje. V případě DPZ jsou metody založeny na měření intenzity elektromagnetického záření (EM), které je sledovaným objektem odraženo nebo vyzářeno. Rozsah vlnových délek, užívaných v DPZ znázorňuje Obr 2.




Obr 2: Rozsah vlnových délek využívaných dálkovým průzkumem.
Převzato z (Homolová et al. 2014)

Při řešení této studie byla využívána data nasnímaná v optické části spektra, která jsou založena na měření odraženého EM záření o vlnové délce v rozsahu 380–2500 nm. Optické metody je dále možné rozlišit podle zdroje záření na metody pasivní a aktivní.

Pasivní metody


Principem pasivních metod je měření intenzity záření o různé vlnové délce dopadajícího na čidla senzoru, přičemž zdrojem záření je další, na senzoru nezávislý objekt, nejčastěji Slunce. To se řadí mezi širokospektrální, polychromatické zdroje záření. Spektrální profil záření Slunce lze popsat s využitím Planckova zákona pomocí povrchové teploty a chemického složení (Obr 3). Při průchodu atmosférou Země je část tohoto záření absorbována a měření proto probíhá v tzv. atmosferických oknech.



Obr 3: Spektrální křivka slunečního záření. Zdroj dat: National Renewable Energy Laboratory

Pasivní optické metody DPZ lze rozdělit podle způsobu měření:


- multispektrální – měření probíhá v několika (obvykle 3–12) vybraných spektrálních pásmech, která mají zachytit určité příznaky. Spektrální pásma na sebe nemusejí přímo navazovat.
- hyperspektrální (spektroskopické) – jsou charakteristické větším počtem spektrálních kanálů (cca 20–250), které na sebe přímo navazují a tudíž lze popsat spektrální profil sledovaného povrchu (Obr 4).



Obr 4: Odrazivost vegetace zachycená satelitním multispektrálním (Sentinel-2), leteckým multispektrálním a hyperspektrálním senzorem.

Aktivní optické metody

Principem aktivních metod DPZ je měření intenzity odraženého záření a vzdálenosti sledovaného objektu na základě záření, které je emitováno senzorem, šíří se známou rychlostí, odrazí se od sledovaného povrchu a je přijímáno zpět senzorem (Obr 5). Jako zdroj záření je v případě aktivních optických metod využíván laser o určité vlnové délce, případně několik laserů s různou vlnovou délkou. Tento typ měření je označován jako ALS (Airborne Laser Scanning) nebo jako LiDAR (Light Detection And Ranging).



Obr 5: Tvar signálu přijímaného aktivním laserovým skenerem.
Převzato z Hanzl et al. (2014)

2.3.1.2 Historie a vývoj DPZ v kontextu lesní biomasy

Pasivní optické metody jsou nejdéle používaným přístupem DPZ pro zjišťování parametrů lesních ekosystémů. Letecká fotografie byla ve 30. letech 20. stol. intenzivně využívána pro odhad zásob dřeva v Britské Kolumbii (Andrews 1942). Zhruba ve stejném období byla letecká stereofotogrametrie využívána v Německu pro zjišťování výšky stromů, průměru koruny a DBH a byl popsán odhad objemu dřevní biomasy prostřednictvím letecké fotografie (Taniguchi 1961). K významnému rozvoji ve využití fotografických technik došlo po druhé světové válce.

Značný pokrok při mapování rozsáhlých a často zároveň nepřístupných lesních území umožnilo umístění multispektrálních senzorů na oběžnou dráhu Země. Data pořízená satelitem Landsat-1 umožnila odhad zásob dřeva s přijatelnou přesností a příznivými náklady (Freden et al. 1974). V současnosti jsou satelitní data využívána především pro sledování lesních porostů na globální nebo regionální úrovni v nepřístupných oblastech a tam, kde není zavedený systém inventarizace.

V případě pasivních optických senzorů je množství nadzemní biomasy většinou odhadováno pomocí vegetačních indexů nebo hodnot odrazivosti v jednotlivých kanálech. Roy a Ravan (1996) ale upozorňují, že pro odhad množství nadzemní biomasy je potřeba ideálně používat takové parametry, které jsou málo citlivé vůči

fenologickým změnám v pigmentaci. Dong et al. (2003) použili normalizovaný rozdílový vegetační index (NDVI) odvozený z dat AVHRR pro odhad množství biomasy a pro odhad změn v množství nadzemní biomasy pro boreální lesy. Foody et al. (2003) ověřili možnosti přenositelnosti predikčních vztahů pro odhad množství biomasy pomocí dat nasnímaných misemi Landsat. Z jejich výsledků vyplývá, že hodnoty korelace mezi AGB a NDVI dosahovaly nižších hodnot, než v případě jiných vegetačních indexů, což potvrzuje závěry o menší vhodnosti NDVI pro odhad nadzemní biomasy lesních porostů (Roy a Ravan 1996). Lepších predikčních výsledků bylo dosaženo pomocí neparametrických metod, avšak přenositelnost těchto predikčních modelů je nízká (Foody et al. 2003). Rovněž nelze očekávat, že přesnost odhadu nadzemní biomasy ze satelitních dat by mohla obecně dosahovat srovnatelné přesnosti s výsledky dobře propracovaných inventarizačních systémů (Houghton 2005).

Jednou z příčin nižší přesnosti odhadu nadzemní biomasy z dat pasivního optického skenování je možnost saturace signálu senzoru v případě vysokého množství nadzemní biomasy, zejména u víceúrovňových porostů (Franklin 1986; Roy a Ravan 1996; Dong et al. 2003). Naopak, satelitní pasivní optická data prokazují vysokou vypovídací úroveň při výrazných změnách v množství nadzemní biomasy, např. vykácení částí porostů či odlesňování rozsáhlých území (Houghton 2005; J. Dong et al. 2003). Ke sledování a hodnocení menších změn množství biomasy výrazně přispívá frekvence snímání dat pro totožné zájmové území. V současnosti je jedním z takovýchto systémů hodnocení biomasy a dalších parametrů na lokální i globální úrovni satelitní systém MODIS (Muukkonen a Heiskanen 2007; Baccini et al. 2008), který poskytuje data sice malého prostorového rozlišení (250–1000 m), ale s jedno až dvoudenní frekvencí opakování. Velká očekávání jsou z hlediska hodnocení změn v průběhu vegetační sezóny vkládána do konstelace satelitů Sentinel-2, které by měly snímat s vysoký časovým (cca 5 dní) i prostorovým (10–60 m) rozlišením.

Mimo již zmíněnou možnost saturace u optických pasivních dat existují i další možná omezení této kategorie dat. Mezi ně patří špatná kvalita dat v důsledku oblačnosti a obecně nepřímý vztah mezi množstvím biomasy a získanými spektrálními charakteristikami. Tato omezení lze částečně překonat využitím dat aktivního radarového a laserového skenování. U satelitních senzorů se jedná zejména o technologii RADAR (Radio Detection And Ranging) pracující v oblasti mikrovlnného záření. Pro použití v lesním hospodářství jsou uváděny jako vhodné vlnové délky v rozmezí 5–100 cm (C, L, P-kanály). Nicméně i v případě radarových dat byla pozorována saturace signálu při určitém množství biomasy. Toan et al. (2004) uvádí 30, 50 a 150 až 200 t·ha⁻¹ jako množství biomasy, při kterém dochází k saturaci pro vlnové délky 6, 24 a 70 cm. Mezi další vlivy, které působí na radarový signál, patří topografie, sněhová pokrývka nebo struktura porostu (Patenaude et al. 2005). Hlavní předností radarových systémů proto zůstává jejich schopnost snímat i v oblačných podmínkách.

Rovněž pro radarová data byla prokázána dobrá schopnost detekce změn AGB v důsledku těžby (Antropov et al. 2016; Lei et al. 2018).

Další kategorií aktivních senzorů jsou systémy laserového skenování označované zkratkou LiDAR (Light Detection And Ranging). Ty jsou založené na podobném principu jako radarová technologie s tím rozdílem, že nejčastěji využívají elektromagnetické záření v infračervené části spektra (1064 a 1560 nm). Laserové měření je primárně založeno na měření času, po který trvá návrat vyslaného signálu mezi senzorem a snímaným povrchem. Následně je čas návratu signálu převeden na vzdálenost mezi těmito objekty a lze tudíž určit polohu objektu v rámci referenčního systému. Tento princip umožňuje měřit přímo vertikální a horizontální charakteristiky (3D) snímaných povrchů. V případě snímání lesních porostů získáváme 3D mračna bodů, z nichž lze následně různými přístupy odvodit informaci o distribuci nadzemní biomasy. Z LiDAR dat lze získat i charakteristiky o celkové intenzitě odrazu a tvaru odraženého signálu. Mezi satelitní LiDARové systémy lze zařadit již ukončenou misi ICESat se systémem GLASS. Ten byl aktivní v letech 2003–2010, a i když jeho hlavní náplní bylo sledování změn ledovcového pokryvu Země, podařilo se nasnímaná data použít i pro vytvoření globální mapy výšky lesních porostů (Simard et al. 2011). Na září roku 2018 je plánováno vypuštění satelitu ICESat-2, jehož vedlejším cílem je už i sledování lesních porostů (European Space Agency 2014).

Využitelnost satelitních dat s nižším prostorovým rozlišením pro lesnickou inventarizaci je do určité míry limitována velikostí existujících kalibračních ploch, která nemusí být v souladu s prostorovým rozlišením satelitních prostředků DPZ. Úprava jejich velikosti s sebou může nést značné organizační a finanční náklady. Naproti tomu je většina současných kalibračních ploch dobře použitelná ve spojení s daty získanými z leteckých nosičů. Letecký dálkový průzkum umožňuje získávat všechny typy obrazových dat, radarová data nebo data laserového skenování a zároveň pokrýt relativně velká území, až v řádu stovek kilometrů čtverečných. Z nasnímaných dat lze odvodit charakteristiky o nadzemní biomase na plošné úrovni (např. porostu), nebo na úrovni individuálních stromů. Charakteristiky na úrovni individuálních stromů je možné získat pouze z reflektančních dat s velmi vysokým prostorovým rozlišením nebo při vysoké hustotě bodů LiDARových dat. V obou případech data slouží jako vstup do empirických modelů, které jsou kalibrovány na základě pozemních měření. Existuje ale zásadní rozdíl mezi charakteristikami, které lze odvodit z jednotlivých kategorií dat. Zatímco z multi-, hyperspektrálních dat leteckého skenování lze při základním zpracování odvodit charakteristiky o biomase jen nepřímou na základě spektrálních projevů, LiDARová data poskytují 3D informaci o strukturálním rozložení nadzemní biomasy.

2.3.1.3 Plošný přístup odhadu množství nadzemní biomasy

Plošný přístup odhadu AGB je empirický způsob, který využívá kalibrační plochy, jejichž biomasu (případně jiný parametr) odhaduje na úrovni plošné jednotky, nejčastěji pixelu. Tento postup je charakteristický zejména pro satelitní data. Pro různé typy lesních porostů byla zjištěna nižší přesnost odhadu množství AGB z pasivních leteckých senzorů a to jak multispektrálních tak i hyperspektrálních (Clark et al. 2011; Vaglio Laurin et al. 2014). Naproti tomu pomocí dat získaných aktivními optickými senzory se podařilo dosáhnout výrazného zlepšení přesnosti odhadu AGB. Řada autorů rovněž poukazuje na možnost kombinace aktivních a pasivních optických dat, při níž dochází ve většině případů k dalšímu zpřesnění odhadu (Anderson et al. 2008; Vaglio Laurin et al. 2014), které už nebývá tak výrazné jako při přechodu z pasivního na aktivní snímání. Pro odhad množství nadzemní biomasy z kombinovaných dat jsou nejčastěji jako vysvětlující proměnné označovány: spektrální pásma v zelené a infračervené oblasti v případě hyperspektrálních dat (Latifi et al. 2012) a průměrná výšky bodů vegetace nebo výškové percentily v případě LiDARových dat (Bouvier et al. 2015; Garcia-Gutierrez et al. 2014; Chirici et al. 2016). Navzdory obvykle nižší přesnosti a závislosti na kalibračních/validačních plochách jsou tyto postupy využívány pro inventarizační účely. Ve vztahu k ALS jsou tyto postupy využívány v situacích, kdy bodová hustota neumožňuje identifikaci jednotlivých stromů (Roussel et al. 2017).

2.3.1.4 Odhad nadzemní biomasy pomocí identifikace jednotlivých stromů

Spolu s rostoucími technickými možnostmi pro generování bodových mračen o vysoké hustotě jsou rozvíjeny techniky pro hodnocení nadzemní biomasy na úrovni jednotlivých stromů. Postup zpracování většinou sestává ze dvou kroků. V závislosti na zvoleném algoritmu je v prvním kroku provedena identifikace jednotlivých stromů (např. identifikací lokálních maxim-minim) na základě výšek bodů nebo hodnot pixelů odvozených z bodových mračen. V dalším kroku jsou z těchto dat ke každému identifikovanému stromu vypočteny metriky (např. výška stromu, průmět a výška nasazení koruny), jež následně vstupují do alometrických rovnic. V návaznosti na potřeby tohoto přístupu je možné sledovat rozvoj metod pro identifikaci jednotlivých stromů a delinaci jejich korun především z produktů bodových mračen získaných ať už laserovým skenováním, nebo pomocí analýzy obrazu (Kwak et al. 2007; Ferster et al. 2009; Hu et al. 2014).

Využití alometrických rovnic pro výpočet biomasy vyžaduje stanovení druhu dřeviny, pro který je rovnice odvozena. Řada studií prezentuje možnost klasifikace druhů z dat leteckého laserového skenování (ALS) (Korpela et al. 2010; Heinzel a Koch 2011; Hovi et al. 2016). Zároveň bylo ale zjištěno, že při použití multispektrálních, ale zejména pak

hyperspektrálních dat, případně v kombinaci s daty ALS, lze dosáhnout vyšší přesnosti klasifikace jednotlivých druhů dřevin (Dalponte et al. 2008; Ke et al. 2010; Dalponte et al. 2012).

Přístupy leteckého DPZ mají také některá omezení. V případě plošných přístupů se jedná hlavně o množství kalibračních/verifikačních ploch pro sestavení modelu a ověření výstupů modelu. Mezi nejčastěji zmiňované nevýhody přístupu hodnocení na úrovni individuálních stromů pak patří podhodnocování počtu stromů na plochu v důsledku neidentifikování podúrovňových stromů, nižší přesnost delineace korun jednotlivých stromů v případě porostů s vysokým stupněm zapojení, vyšší nároky na hustotu bodů a vyšší výpočetní náročnost.

I přes některá výše zmíněná omezení se popsané přístupy s využitím leteckých LiDAR dat v některých zemích používají pro účely lesnické inventarizace (Peterson et al. 2005; Maltamo et al. 2007; Beets et al. 2011; White et al. 2013).

2.3.1.5 Metody klasifikace

Jak již bylo zmíněno výše, klasifikace jednotlivých druhů dřevin nebo jejich skupin přispívá ke zpřesnění odhadu parametrů porostu. Z hlediska prostorového přístupu ke klasifikovanému území lze rozlišovat 2 způsoby klasifikace:

- klasifikace na úrovni pixelu
- klasifikace na úrovni objektů

Klasifikace na úrovni jednotlivých pixelů je v současnosti charakteristická zejména pro satelitní data s nižším prostorovým rozlišením. V případě klasifikací prováděných na lesních porostech hraje prostorové měřítko (velikost pixelu) významnou roli. V případě větších pixelů senzor zaznamená informaci, která pochází od korun stromů, zastíněných částí stromů, půdy a podrostu, což ztěžuje jednoznačné určení třídy klasifikace. V takových případech je vhodné využít metody, které umožňují určit podíl jednotlivých složek pokryvu daného pixelu, např. „spektrální unmixing“ (Lu et al. 2003). Pokud to je možné, je vhodnější využít data s vyšším prostorovým rozlišením, která je možné získat pomocí leteckých i satelitních senzorů. Vysokých přesností klasifikace jednotlivých druhů dřevin je dosahováno při velikosti pixelu mezi 0,4–8 m (cca 5–120 % průměru koruny) v závislosti na místních podmínkách (Peña et al. 2013; Ghosh et al. 2014). Data s velmi vysokým prostorovým rozlišením (pixel < 1 m) jsou vhodná pro použití přístupů objektově orientované klasifikace, při níž je obraz nejprve rozdělen (rozsegmentován) na prostorové jednotky s definovanými vnitřními parametry. Klasifikátor pak pracuje s těmito jednotkami, které mohou kromě informace z původních pixelů nést i informaci o hodnotách jednotek sousedních, nebo v případě


víceúrovňové klasifikace i objektů jiného měřítka, se kterými se protínají (Zhou et al. 2014).

Vlastní klasifikační algoritmy jsou univerzální a lze je aplikovat v obou přístupech. Volba klasifikátoru je vždy závislá na konkrétních podmínkách, předpokládaném druhu vstupních dat DPZ a v případě řízené klasifikace i počtu pozorování, která lze využít pro trénování klasifikátoru. V DPZ je v současnosti znatelný přechod od parametrických klasifikátorů, např. „maximum likelihood“ klasifikátoru, i když i tento může dosahovat dobrých výsledků (Shafri et al. 2007), zejména k metodám strojového učení. Je to zapříčiněno zejména faktem, že jsou stále častěji využívána hyperspektrální data, která mohou být kombinována s deriváty odvozenými z ALS skenování a počet nezávislých proměnných tak často převyšuje počet pozorování závislé proměnné. Dalším faktorem, který limituje parametrické metody, je autokorelace nezávislých proměnných, kterou lze u výše zmíněných vstupů pozorovat. Dnes jsou tedy preferovány spíše neparametrické metody strojového učení např. support vector machine nebo random forest.

Fassnacht et al. (2016) uvádí, že pro výsledek klasifikace je důležitější předzpracování vstupních dat takovým způsobem, aby splňovaly požadavky zvoleného klasifikátoru, než samotný druh použitého klasifikačního algoritmu.

Klasifikace nejbližším sousedem – kNN


Původní metoda nejbližších sousedů (Cover a Hart 1967) je velmi rozšířená metoda, která je využívána mnoha metodami grupování a strojového učení. Metodu nejbližších sousedů lze využít pro řadu klasifikačních i regresních úloh (Mathur et al. 2002; Breidenbach et al. 2012). Největším rozdílem oproti dalším metodám klasifikace či regrese je, že kNN negeneralizuje vztah mezi nezávislými a závislými proměnnými, ale výsledek je založen přímo na hodnotách trénovacích vzorků (Obr 6). Principem klasifikace metodou nejbližších sousedů je nalézt v n -dimenzionálním prostoru „ k “ nejbližších trénovacích vzorků vzhledem k právě hodnocenému. Vzdálenost mezi vzorky je nejčastěji popsána pomocí Euklidovské vzdálenosti, avšak obecně lze využít jakoukoliv metriku v závislosti na typu řešené úlohy. V nejjednodušší verzi algoritmu kNN je hodnocenému vzorku přiřazena třída na základě hodnoty převažující u nalezených nejbližších sousedů. Metoda má několik variací: počet sousedů může být fixní nebo se jejich počet mění, zatímco je fixní vzdálenost, do které jsou sousedé hledáni. Při rozhodování mohou mít všichni sousedé stejnou váhu, nebo se jejich váha může měnit např. v závislosti na jejich vzdálenosti od hodnoceného bodu.



Obr 6: Princip klasifikace pomocí nejbližšího souseda. Zdroj: <http://scikit-learn.org>

Klasifikace support vector machine – SVM

Support vector machine (Cortes a Vapnik 1995) je technika strojového učení, kterou lze řešit nelineární klasifikační a regresní úkoly. Při klasifikaci pomocí SVM je hledána taková plocha/rovina, která maximalizuje prostor mezi dvěma sousedícími třídami. Jako „support vectors“ jsou pak označeny ta pozorování, která leží na hranici tohoto prostoru (Obr 7). Při použití SVM je vždy potřeba optimalizovat několik parametrů. Prvním z nich je typ plochy, která bude pro danou úlohu nejvhodnější. Mezi nejčastěji využívané typy patří lineární, polynomiální, radial basis function (RBF) a sigmoidní. Další parametry se pak odvíjí od zvoleného typu plochy. Pro klasifikace dat na základě n -dimenzionálních prostorů je často využíván typ RBF, který vyžaduje optimalizaci dalších dvou parametrů C a γ . Parametr C rozhoduje o komplexitě modelu prostřednictvím počtu support vectors. Vysoké hodnoty parametru umožňují použití většího počtu support vectors a tudíž i výrazně komplexnějšího modelu. Při nízkých hodnotách parametru je naopak akceptována větší možnost chyby. Parametr γ definuje efektivní vzdálenost vlivu jednotlivých pozorování vybraných jako „support vectors“. Parametr γ ovlivňuje výsledek klasifikace výrazněji než parametr C . Při příliš vysoké hodnotě parametru γ bude efektivní vzdálenost malá a zvyšuje se pravděpodobnost přetrénování (overfitting). Naopak při příliš nízké hodnotě parametru γ se model bude blížit chování, ke kterému by docházelo při použití lineárního typu plochy.



Obr 7: Základní princip klasifikátoru support vector machine. Převzato z Meyer (2017)

2.4 Hodnocení obsahu půdního organického uhlíku pomocí DPZ

V půdní organické hmotě je vázáno až čtyřikrát více uhlíku než v nadzemní biomase (Jobbágy a Jackson 2000). Obsah půdní organické hmoty je klíčový pro řadu půdních procesů a ovlivňuje řadu půdních vlastností, např. sorpční schopnost půdy, vododržnost, objemovou hmotnost nebo teplotní režim půdy (Carter 2002; Kumar et al. 2015). Tyto vlastnosti úzce souvisí s úrodností půd a proto je v půdních vzorcích sledován nejen obsah půdní organické hmoty/uhlíku (SOC) ale často i její formy (Cambardella a Elliott 1993). Z důvodů časové a finanční náročnosti odběru půdních vzorků a jejich následné laboratorní analýzy se v pedologii stále častěji uplatňují i bezkontaktní metody (Stenberg et al. 2010).

Problematika půdního uhlíku je vzhledem k principům DPZ řešena především v rámci zemědělských ploch. Protože je orná půda vždy po určitý časový úsek bez vegetačního pokryvu, lze měřit přímou odezvu EM záření na složení a strukturu půdy. Půdní spektroskopie má své počátky v 60. letech 20. stol., kdy byl zjišťován vliv vlhkosti půdy, obsahu uhlíku a velikosti půdních částic na spektrální profil půdních vzorků (Bowers a Hanks 1965). V dalších letech byly hledány predikční modely pro hodnocení řady půdních vlastností jako vlhkost, obsah uhlíku, jílu, železa (Morra et al. 1991; Viscarra Rossel a McBratney 1998; Ben-Dor a Banin 1994). Pro hodnocení těchto

parametrů lze použít metody lineární regrese, případně vícenásobné regrese, a to buď na základě kombinací spektrálních kanálů (obdoba vegetačních indexů) nebo vybraných oblastí spektrálního profilu. Dnes je však v oblasti půdní spektroskopie nejčastěji využívána metoda „Partial Least Square Regression“ (PLSR) pracující s celým spektrálním profilem, případně další statistické postupy, které umožňují řešit nelineární úlohy s autokorelovanými daty, např. „random forest, support vector regression“ (Chagas et al. 2016; Morellos et al. 2016). Tyto metody převážně strojového učení umožňují v případě půdní organické hmoty nejen určit její množství, ale i např. rozlišit množství recentní a fosilní půdní organické hmoty ve skládkovém materiálu po těžbě uhlí (Vindušková et al. 2014), množství extracelulárních enzymů nebo potenciální denitrifikaci (Cécillon et al. 2008). Aplikováním těchto přístupů na obrazová hyperspektrální data je pak možné získat mapy půdních vlastností (Ben-Dor et al. 2002).

Na rozdíl od zemědělských půd je odhad množství půdní organické hmoty pod lesními porosty v současnosti založen především na odběru a analýze půdních vzorků s následným využitím statistických a geostatistických metod za účelem získání plošné informace (ICIMOD 2015). V rámci těchto postupů bylo zjištěno, že množství půdní organické hmoty je spojeno s různými parametry nadzemní biomasy a stanovištních podmínek. Bae a Ryu (2015) pozoroval rozdíly v obsahu SOM pod různými kategoriemi dřevin (listnaté, jehličnaté, smíšené). K podobným výsledkům došly i jiné studie, přičemž rozdíly v obsahu SOM jsou nejčastěji dávány do souvislosti s chemickým složením (kvalitou) opadu (Melillo et al. 1982) nebo rozdílným množstvím a aktivitou půdního edafonu (Frouz 2008). Jako další faktory ovlivňující množství půdního uhlíku uvádí (Grinand et al. 2017) jako nejvýznamnější klimatické faktory a jako méně významné pak spektrální charakteristiky vegetace/pokryvu a orografické charakteristiky. V závislosti na zeměpisné poloze byly popsány různé vztahy obsahu uhlíku s nadmořskou výškou, orientací, svažitostí nebo některými dalšími topografickými charakteristikami (Tsui et al. 2004; Garcia-Pausas et al. 2007; Seibert et al. 2007).

Některé z těchto charakteristik stanoviště je pomocí DPZ možné měřit přímo, nebo přímo ovlivňují spektrální profil EM záření ve vlnových délkách, které DPZ využívá. Možnosti DPZ pro odhad AGB již byly popsány, viz. kap. 2.3. Orografické charakteristiky jsou označovány jako jedna z klíčových proměnných určujících množství půdní organické hmoty pod lesními porosty nezávisle na klimatickém regionu (Grinand et al. 2017; Kristensen et al. 2015). Orografie je zároveň faktor, který lze metodami DPZ dobře popsat. Model terénu, ze kterého jsou následně odvozovány orografické charakteristiky, lze získat pomocí řady metod DPZ. Pomocí kamer a bezpilotních prostředků a postupů „structure from motion“ je možné získat mikoreliéf s rozlišením v řádech jednotek centimetrů a vertikální přesností v jednotkách centimetrů (Uysal et al. 2015). Těmito postupy lze efektivně popsat území s rozlohou v řádech

několika km², přičemž hlavním limitujícím faktorem pro získání DTM je vegetační pokryv, kdy s rostoucím množstvím a hustotou nadzemní biomasy klesá výšková přesnost. V takových situacích, zejména v zalesněných oblastech, lze získat výškopis terénu pomocí technologie LiDAR, která v případě leteckých nosičů poskytuje data s prostorovým rozlišením v řádech desítek centimetrů s absolutní polohovou a výškovou přesností 17–26 cm v závislosti na typu a hustotě vegetačního pokryvu (Hodgson a Bresnahan 2004; Ahokas et al. 2003), a to na územích stovek až tisíců km². Výškopis rozsáhlejších území, případně výškopis v globálním měřítku je pak získáván zejména prostřednictvím technologie RADAR, využívající satelitních nosičů, a poskytující výšková data s rozlišením 30 a více metrů a výškovou přesností v jednotkách metrů (Elkhrachy 2017).

Spektrální charakteristiky lze využít pro odhad obsahu dusíku, ligninu a dalších vlastností vegetace, které bývají uváděny v souvislosti s dekompozicí opadu (Huber et al. 2008; le Maire et al. 2008). Kromě parametrů nadzemní biomasy byl zjištěn i vztah mezi NDVI a SOM tropického lesa (Kumar et al. 2016). Také Egberth et al. (2017) prokázal využitelnost satelitních multispektrálních dat pro odhad množství SOM. Naproti tomu v dalších studiích byla prokázána jen slabá korelace mezi SOM a vegetačními indexy (Dube et al. 2018). Problematika spektrálních charakteristik vegetace, vlastností opadu a množství uhlíku je komplikována např. reabsorpcí dusíku v průběhu senescence, která ovlivňuje dekompozici opadu (Sariyildiz a Anderson 2005). Další charakteristiky prostředí s vazbou na půdní uhlík, které jsou měřitelné nejen metodami DPZ, uvádí (Rasel et al. 2017).

2.5 Půdní uhlík na hnědouhelných výsypkách

Materiál nadložních vrstev, které jsou při povrchové těžbě odstraňovány, je tvořen především materiálem sedimentárního původu. Obsah organického uhlíku v těchto vrstvách se pohybuje v rozmezí do 18 %. V případě uhelných pánví v ČR byl u cyprisových nadložních materiálů zjištěn obsah 1,8–6,8 % (Pešek et al. 2010). Při těžbě, zpracování, transportu a ukládání nadložních materiálů může dojít k navýšení obsahu uhlíku prostřednictvím příměsí uhlí. Přítomný organický uhlík je označován jako uhlík fosilní. Ten je z části tvořen příměsí uhlí, a dalšími formami fosilního uhlíku, např. kerogen (Vindušková et al. 2014). Při technologických operacích s nadložním materiálem dochází zároveň k jeho aeraci a inokulaci mikroorganismy. Po exponování materiálu vnějšímu prostředí dochází vlivem abiotických a biotických faktorů k transformacím fosilního organického materiálu. U exponovaných nadložních materiálů byl pozorován pokles množství organického uhlíku v průběhu času. Po 35 letech byl u cyprisových výsypků na Sokolovsku pozorována změna podílu C/N z hodnoty ~40 na hodnotu ~10 (Kříbek a Macurová 1996). Rovněž (Strnad a Kříbek

1996) dokumentovali pokles obsahu organického uhlíku v cyprisových jílech.

Po určité době dochází ke kolonizaci výsypkových ploch vegetací z okolí, případně jsou po stabilizaci materiálu provedena rekultivační opatření. K souvislému zapojení vegetace dochází většinou do 15 let (Prach et al. 2011). S růstem vegetace dochází k akumulaci uhlíku v nadzemní biomase a zároveň ukládání organické hmoty (recentní uhlík) do půdotvorného substrátu. V důsledku přeměn organické hmoty pak dochází k vývoji půdních horizontů. Rychlost akumulace půdního uhlíku se liší u listnatých a jehličnatých dřevin a její maximum se nachází mezi 10–30 roky stáří porostu (Vindušková a Frouz 2013). Změna rychlosti akumulace půdního uhlíku pravděpodobně souvisí se změnou v množství opadu (Frouz et al. 2001; Frouz 2017). Na množství půdního uhlíku na sukcesních plochách má pozitivní vliv přítomnost křovinného podrostu. Spolu s vlivem podrostu byl na plochách spontánní sukcese zjištěn i statisticky významný vliv mikro-orografie na množství půdního uhlíku (Frouz et al. 2011).

Zásoba uhlíku v lesních půdách, které jsou „cílovým“ stavem lesnické rekultivace, se na většině plochy ČR pohybuje do $100 \text{ t} \cdot \text{ha}^{-1}$, přičemž nejčastěji se lze setkat s hodnotami mezi 50 a $60 \text{ t} \cdot \text{ha}^{-1}$ (Cienciala et al. 2011).

3 Hypotézy disertační práce

Druhové složení porostů rozhoduje o množství půdního uhlíku pod porosty dřevin na rekultivovaných plochách těžebních výsypek.

Množství nadzemní biomasy má vliv na množství půdního uhlíku pod porosty dřevin na rekultivovaných plochách těžebních výsypek.

Prostorová variabilita množství půdního uhlíku a množství biomasy na rekultivovaných výsypkách závisí na orografických vlastnostech území.

4 Metodika

4.1 Popis lokality

Velká podkrušnohorská výsypka ($50^{\circ}14'44'' \text{ N}$, $12^{\circ}41'4'' \text{ E}$) se nachází v severozápadních Čechách asi 7 km severovýchodně od města Sokolov. Celá výsypka se nachází ve výšce asi 450–550 m n. m. a zaujímá plochu asi 20 km^2 . Průměrná roční teplota v oblasti je $6,5^{\circ} \text{ C}$ a průměrné roční srážky 650 mm. Výsypka vznikala od 70. let 20. stol. nasypáním převážně jílovcového materiálu. Nasypání se provádělo pomocí dopravníků otáčejících se okolo pevného bodu, čímž vznikly charakteristické terénní vlny (Obr 8). V místech plánovaných revitalizačních zásahů byly tyto vlny urovnány

a následně probíhala lesnická rekultivace, při níž byly přímo do jílového materiálu výsypky v monokulturách vysazovány dub letní (*Quercus robur* L.), lípa malolistá (*Tilia cordata* L.) a modřín opadavý (*Larix decidua* Mill). Ve směsích byly vysazovány olše lepkavá (*Alnus glutinosa* L.) s příměsí olše šedé (*Alnus incana* L.), borovice lesní (*Pinus sylvestris* L.) s borovicí černou (*Pinus nigra* Arnold) a smrk omorika (*Picea omorica* Panic) se smrkem pichlavým (*Picea pungens* Engelm). Na části výsypky, kde probíhá spontánní sukcese, byly terénní vlny ponechány. Těmto plochám zprvu dominuje bříza bělokorá (*Betula pendula* Roth) a později směs vrby jívy (*Salix caprea* L.) a topolu osiky (*Populus tremula* L.).



Obr 8: Letecká fotografie části zájmového území. Ve spodní části obrázku je viditelná sukcesní plocha s charakteristickými terénními vlnami. Autor: Hanuš, 2009

V průběhu terénních šetření byly dále zjištěny plochy s výsadbou druhů javor klen (*Acer pseudoplatanus* L.) a jasan ztepilý (*Fraxinus excelsior* L.). Pro účely analýzy byly druhy zařazeny do pracovních tříd (Tab 2).

Tab 2: Zařazení druhů dřevin do pracovních tříd.

třída	druhové zastoupení
a	<i>Alnus glutinosa</i> L., <i>Alnus incana</i> L.
l	<i>Larix decidua</i> Mill
o	<i>Acer pseudoplatanus</i> L., <i>Fraxinus excelsior</i> L.
pc	<i>Picea omorica</i> Panic, <i>Picea pungens</i> Engelm
pn	<i>Pinus sylvestris</i> L., <i>Pinus nigra</i> Arnold
q	<i>Quercus robur</i> L.
s	<i>Salix caprea</i> L., <i>Betula pendula</i> Roth, <i>Populus tremula</i> L.
t	<i>Tilia cordata</i> L.

4.2 Data dálkového průzkumu Země


4.2.1 Letecká hyperspektrální data

První sada leteckých hyperspektrálních dat byla pro zájmové území nasnímána 27. 7. 2009 skenerem AISA Eagle (Specim, Spectral Imaging Ltd., Finsko). Skenování probíhalo z nosiče Cessna TU 206 F. Základní parametry snímaných dat jsou uvedeny v Tab 3. Současně s hyperspektrálními daty byly zaznamenávány informace o pozici nosiče pomocí IMU/GPS jednotky AEROcontrol (IGI mbH, Německo). Snímání probíhalo od 11:26 do 13:01 hod CEST za bezmračných podmínek. Zájmové území bylo pokryto celkem 9 liniemi s překryvem 30 % při průměrné výšce letu 316 m nad terénem. Většina náletových os byla orientována přibližně ve směru SV – JZ (Obr 9).

Tab 3: Charakteristika nasnímaných leteckých hyperspektrálních dat.

Parametr	AISA Eagle	CASI 1500
Prostorové rozlišení (m)	0,4	0,5
Spektrální rozsah (nm)	400 – 990	375 – 1047
Spektrální rozlišení (nm)	9	9

Druhá sada leteckých hyperspektrálních dat byla nasnímána 18. 5. 2017 skenerem CASI 1500 (ITRES Research Limited, Kanada). Skener byl instalován spolu s IMU/GPS jednotkou POS (Applanix Corporation, Kanada) v nosiči Cessna 208B. Skenování probíhalo přibližně od 10:15 do 12:15 hod CEST za bezmračných podmínek. Zájmové území bylo pokryto celkem 14 liniemi s překryvem 60 % při průměrné výšce letu cca 1000 m nad terénem. Náletové osy byly orientovány v podélné ose výsypky, tj. přibližně ve směru SV – JZ (Obr 9).



Obr 9: Hranice leteckých dat a orientace náletových os dat nasnímaných v roce 2009 a 2017.

Souběžně s leteckým skenováním probíhala pozemní podpůrná měření, která byla využita pro předzpracování leteckých hyperspektrálních dat. V době přeletů byla měřena propustnost atmosféry pomocí sunphotometru Microtops (Solar Light Company, Inc., USA). Polním spektrometrem FieldSpec (ASD Inc., USA) byla měřena referenční spektra kalibračních panelů a vybraných referenčních povrchů v zájmovém území. Pomocí geodetické GPS stanice (TOPCON CORPORATION, Japonsko) byly zaměřeny souřadnice vybraných bodů, které byly dále použity pro zpřesnění georeferencování výsledné mozaiky. Na surových hyperspektrálních datech byla provedena radiometrická, atmosférická a geometrická korekce, jejichž výsledkem je georeferencovaná hyperspektrální kostka nesoucí informaci o odrazivosti jednotlivých povrchů.

4.2.2 Data leteckého laserového skenování

Snímání a předzpracování ALS dat provedla v roce 2010 společnost GEODIS BRNO, spol. s r. o. Data byla nasnímana skenerem Leica ALS50-II (Leica Geosystems AG, Švýcarsko). Dodavatel provedl georeferencování dat, relativní vyrovnání dat z jednotlivých linií, klasifikaci bodů terénu a export do formátu LAS 1.2. Vlivem překryvů jednotlivých náletových linií má dodané LiDARové mračno nestejnou hustotu bodů. Základní charakteristiky dodaných dat uvádí Tab 4.

Druhé ALS skenování proběhlo 18. 5. 2017, souběžně s hyperspektrálním skenováním. Pro snímání byl použit skener Riegl LMS-Q780i (RIEGL Laser Measurement Systems GmbH, Rakousko). Území bylo pokryto 14 letovými liniemi. Skenování probíhalo z výšky cca 1000 m nad terénem s překryvem 74 %. Základní předzpracování dat bylo

provedeno v prostředí RiPROCESS (RIEGL Laser Measurement Systems GmbH, Rakousko). Předzpracování nasnímaných dat zahrnovalo dekompozici nasnímané vlny, georeferencování a relativní vyrovnání dat jednotlivých letových linií a export do formátu LAS 1.3.


Formát LAS (American Society for Photogrammetry and Remote Sensing) je univerzální výměnný formát pro bodová mračna, se kterým je dále možno pracovat prostřednictvím komerčně, nebo i volně dostupného softwaru. Pro další zpracování bodových mračen a tvorbu vrstev vstupujících do jednotlivých analýz byl využíván především softwarový balík LAStools (rapidlasso GmbH, Německo). Prvním krokem zpracování dat ve formátu LAS bylo odfiltrování odlehlých bodů programem „lasnoise“ (*step* = 2; *isolated* = 3). Při tomto nastavení jsou jako šumové označeny ty body, které v okolí 6×6×6 m mají 3 a méně bodů. Dalším krokem přípravy ALS dat pro analýzu byla klasifikace bodů terénu programem „lasground_new“ (*step* = 3; *bulge* = 0,6), který využívá pro identifikaci bodů terénu postupné zahušťování nepravidelné trojúhelníkové sítě (Axelsson 2000). Parametr *step* udává, v jak velkém okolí jsou hledány potenciální body terénu. Parametr *bulge* udává maximální odchylku od roviny trojúhelníku, kterou by způsobilo přidání právě testovaného bodu. Jelikož v dalších krocích měly být zkoumány výškové charakteristiky vegetace, byla jako poslední přípravný krok provedena programem „lasheight“ normalizace výšky bodů nad terénem . Charakteristika výsledného bodového mračna je uvedena v Tab 4.

Tab 4: Základní charakteristika nasnímaných LiDAR dat.

Parametr	Leica ALS50-II (2010)	Riegl LMS-Q780i (2017)
Výška letu nad terénem (m)	1000	1000
Průměr footprintu (m)	0,25	0,25
Max. počet odrazů na puls	2	7
Průměrná hustota bodů – holá půda (b·m ⁻²) [Q01 – Q99]	1 [0,6 – 1,5]	15,6 [10 – 21]
Průměrná hustota bodů – les (b·m ⁻²) [Q01 – Q99]	2,9 [2,1 – 3,7]	32,1 [21 – 61]

4.3 Stanovení množství nadzemní biomasy a půdního uhlíku na základě terénních měření

Množství nadzemní biomasy a půdního uhlíku bylo stanoveno na základě terénních šetření uskutečněných v roce 2006, 2015 a 2017 (Obr 10).



Obr 10: Přehled lokalit, na kterých probíhalo vzorkování v letech 2006, 2015 a 2017; v pravém dolním rohu lokalizace odběrových ploch v rámci celé výsypky.

4.3.1 Data 2006 a jejich zpracování

Pro každou zájmovou skupinu dřevin (olše, dub, lípa, smrk, borovice, modřín, spontánní sukcese) byly vytyčeny 4 kruhové pokusné plochy o poloměru 8 m. Umístění pokusných ploch bylo vybíráno tak, aby vzdálenost okraje pokusné plochy vzhledem k okraji porostu dané dřeviny byla nejméně 5 m a střed každé plochy byl zaměřen pomocí GPS se zvýšenou přesností. Pro stanovení nadzemní biomasy byl měřen průměr kmene ve výčetní výšce (DBH) u všech stromů s DBH > 50 mm a jejich výška. Pro stanovení biomasy stromů s DBH < 50 mm byly uvnitř pokusné plochy náhodně umístěny 3 menší kruhové plochy (4,19 m²), uvnitř kterých byl měřen parametr DBH všech dřevin vyšších 1,3 m. Nadzemní biomasa jednotlivých stromů byla následně stanovena pomocí existujících alometrických rovnic (Tab 5). Pro stanovení nadzemní biomasy vrby jívy byla vytvořena alometrická rovnice na základě destruktivního vzorkování 30 kmenů.

Odhadnutá nadzemní biomasa byla vyjádřena na plochu 1 ha a přepočtena na množství uhlíku pomocí generalizovaného koeficientu 0,5.

Tab 5: Seznam studií obsahujících alometrické rovnice použité v roce 2006.

Zdroj: Cienciala et al. (2006b).

Skupina dřevin	Studie
smrk	(Wirth et al. 2004)
borovice	(Chroust 1985; Cienciala et al. 2006a)
modřín	(Ker 1980)
dub	(Hochbichler 2002)
olše	(Johansson 2000)
lípa	(Ter-Mikaelian a Korzukhin 1997)
spontánní sukcese	(Marklund 1988; Utkin et al. 1996; Cienciala et al. 2006b)

Množství recentního půdního uhlíku (C_{REC}) bylo stanovováno ve fermentačním (Fe) a organominerálním (A) horizontu. Pro stanovení množství uhlíku v Fe horizontu bylo uvnitř každé pokusné plochy náhodně odebráno 6 vzorků (každý 625 cm²). Jednotlivé vzorky byly vysušeny, zváženy a následně homogenizovány. Pro stanovení množství recentního uhlíku v A horizontu byla uprostřed každé pokusné plochy vykopána půdní sonda (2 m délka, 0,75 m hloubka). Na 20 náhodných místech půdní sondy byla změřena mocnost A horizontu. Pomocí Kopeckého válečků (100 cm³) byly uvnitř půdní sondy náhodně odebrány 4 vzorky A horizontu a 4 vzorky minerálního (C) horizontu. Vzorky byly vysušeny, zváženy a homogenizovány.

Pro stanovení C_{REC} bylo z každého homogenizovaného vzorku odváženo a následně namleto 10 g materiálu. Množství organického uhlíku bylo stanoveno oxidací dichromanem a přepočteno na relativní obsah C_{REC} . Celkové množství C_{REC} (t·ha⁻¹) v Fe horizontu bylo vypočteno jako součin průměrného obsahu uhlíku a průměrné hmotnosti vzorku korigovaný na odběrovou plochu. Pro A horizont byla nejprve vypočtena hmotnost A horizontu jako součin jeho průměrné mocnosti a objemové hmotnosti. Pro určení podílu recentního uhlíku v A horizontu se vycházelo z předpokladu, že uhlík zjištěný v C horizontu představuje pouze fosilní složku. Podíl recentního uhlíku pro A horizont byl proto určen jako rozdíl celkového obsahu uhlíku v A horizontu a obsahu uhlíku v C horizontu. Množství C_{REC} v A horizontu (t·ha⁻¹) bylo pak vypočteno jako součin objemové hmotnosti A horizontu, hloubky A horizontu a relativního podílu C_{REC} korigovaný plochou pokusné plochy. Tato data pozemního vzorkování jsou data převzatá (Cienciala et al. 2006b; Frouz et al. 2009), kteří uvádějí další specifika příslušných terénních měření.

4.3.2 Data 2015 a jejich zpracování

Účelem vzorkování v roce 2015 bylo ověření předpokladu, že celkový obsah uhlíku horizontu C lze využít jako referenční hodnotu obsahu fosilního uhlíku v horizontu A a lze tak nepřímo určit podíl recentního uhlíku v horizontu A.

Na 14 plochách, na kterých probíhalo vzorkování v roce 2006, byly odebrány vzorky horizontu A (0–10 cm) a horizontu C z hloubky 40–50 cm. Vzorky horizontu A byly odebrány dvěma Kopeckého válečky o objemu 63,585 cm³, aby bylo možné vypočítat objemovou hmotnost a celkovou zásobu recentního uhlíku ve vrchní deseticentimetrové vrstvě půdy. Vzorky byly zbaveny kořenů, živočichů, případně i nejílovitého skeletu a předsušeny na vzduchu. Pro stanovení objemové hmotnosti byl celý vzorek horizontu A nejprve zvážen a poté z něj byl odebrán podvzorek půdy odpovídající 50–80 g suché půdy a rovněž zvážen. Podvzorek byl vysušen na Petriho misce při teplotě 105 °C do konstantní hmotnosti a poté znovu zvážen. Takto byl vypočten relativní obsah sušiny, kterým byla korigována hmotnost celého vzorku A horizontu, a následně byla vypočtena objemová hmotnost.

Část každého vzorku byla namleta na kulovém mlýnu na analytickou jemnost tak, aby prošla sítím s velikostí oka 0,125 mm. U všech odebraných vzorků byl stanoven celkový obsah uhlíku po spálení v proudu čistého kyslíku při teplotě > 1000 °C (Schumacher 2002). Stanovení bylo provedeno na prvkovém analyzátoru EA 1108 (Carlo Erba Instruments) v Ústavu pro životní prostředí (ÚŽP), PřF UK.

4.3.2.1 Stanovení obsahu recentního uhlíku metodou ¹⁴C radiokarbonové hmotnostní spektrometrie

Ve 14 vzorcích horizontu A a 2 referenčních vzorcích horizontu C s analytickou jemností byl stanoven podíl recentního uhlíku metodou ¹⁴C hmotnostní spektrometrie, která vyjadřuje aktivitu ¹⁴C ve vzorku (pMC – percent modern carbon). Aktivita je udávána jako podíl nestabilního uhlíku ¹⁴C ve vzorku vůči množství ¹⁴C v laboratorním standardu. ¹⁴C analýza byla provedena formou zakázky v Center for Applied Isotope Studies, University of Georgia.

Před vlastním stanovením aktivity ¹⁴C byly vzorky ponechány 1 hodinu při 80 °C v 5% HCl a poté propláchnuty deionizovanou vodou a NaOH. Následně byly vzorky znovu umístěny do HCl, propláchnuty deionizovanou vodou a usušeny při 60 °C. Takto připravené vzorky byly spáleny při 900 °C. Vzniklý CO₂ byl kryogenicky vyčištěn a kataliticky převeden na grafit (Vogel et al. 1984). Následně byl na akceleratorovém hmotnostním spektrometru CAIS 0.5 MeV změřen podíl ¹⁴C/¹³C vzniklého grafitu. Tento podíl byl vztažen k podílu naměřenému u laboratorního standardu kyseliny šťavelové (Oxalic Acid I; NBS SRM 4990).

Podíl recentního uhlíku na celkovém obsahu uhlíku v organické hmotě byl spočítán podle vztahu:

$$C_{REC}(\%) = \frac{pMC_{TOC}}{pMC_{REC}}$$

kde pMC_{TOC} je aktivita ^{14}C naměřená ve vzorcích půd a pMC_{REC} je aktivita ^{14}C předpokládaná v čisté recentní organické hmotě. Pro výpočet byla použita hodnota $pMC_{REC} = 115$, která je udávána jako průměrná pro současné lesní ekosystémy (Rumpel et al. 1999; Morgenroth et al. 2004).

Pomocí takto určeného podílu recentního uhlíku byl odvozen podíl uhlíku fosilního, který byl srovnán s podílem celkového uhlíku zjištěném v horizontu C.

4.3.3 Data 2017 a jejich zpracování

Pro každou třídu dřevin bylo stratifikovaně navrženo 20 ploch pro vzorkování v roce 2017. Pozice ploch pro odběr vzorků byla navržena na základě mapy klasifikace druhů a mapy výšky vegetace (CHM), které byly získané analýzou HS dat nasnímaných v roce 2009 a ALS dat z roku 2010. Nejprve byla pro území klasifikace vygenerována pravidelná síť bodů s rozlišením 5 m. Pro jednotlivé body byla z nejbližšího pixelu rastru CHM získána informace o výšce vegetace. Pro každý druh byly body rozděleny na základě výšky do skupin podle intervalů vypočtených pomocí algoritmu pro určování přirozených hranic (Jenks 1977). Pro každou skupinu, definovanou intervaly výšky, byla vypočtena relativní četnost bodů této skupiny vůči počtu všech bodů daného druhu. Počet vzorkovacích ploch pro každou skupinu byl poté vypočten na základě relativní četnosti skupiny a fixního celkového počtu ploch pro daný druh. Konečný výběr bodů v rámci každé skupiny probíhal náhodně.

Odběr vzorků půdy probíhal v květnu 2017. Na každé vzorkovací ploše byly odebrány 2 vzorky z horizontu A, a 2 vzorky horizontu C, ze kterých byly pro jednotlivé horizonty vytvořeny směsné vzorky. Jednotlivé vzorky byly odebírány ve vzájemné vzdálenosti 2 m. Vzorky z horizontu A byly odebírány pomocí Kopeckého válečku (100 cm^3). Jednotlivé směsné vzorky byly vysušeny, zváženy a homogenizovány. Vzorky horizontu C byly odebírány pomocí půdní sondýrky z hloubky cca 50 cm. Vzorky v sondýrce byly zároveň využity pro měření hloubky A horizontu (Obr 11). Zároveň s odběrem půdních vzorků bylo provedeno měření DBH a výšky na 10 reprezentativních stromech, které se nacházely nejblíže ke středu vzorkované plochy.

Relativní obsah uhlíku homogenizovaných vzorků byl stanoven chromatograficky pomocí prvkového analyzátoru Flash 2000 (Thermo Fisher Scientific, USA) při teplotě

větší než 1000 °C. Laboratorní analýza obsahu uhlíku ve vzorcích z roku 2017 byla provedena firmou GEOTest, a. s.



Obr 11: Půdní profil v severní části vzorkovaného území s převažujícím druhovým zastoupením jasanu a lípy.

4.3.4 Stanovení množství recentního uhlíku v A horizontu

Na základě dostupných informací o množství fosilní organické hmoty v materiálech výsypek po těžbě uhlí, změnách v množství fosilní hmoty v čase a také na základě hodnot zjištěných ve vzorcích odebraných v roce 2015, byly pro stanovení relativního množství recentního uhlíku v A horizontu (A_{REC}) použity tři přístupy.

4.3.4.1 Korekce množství uhlíku v horizontu C ($A_{C_{RADIO}}$)

Tato metoda je pro stanovení množství recentního uhlíku v materiálu výsypek po těžbě uhlí obvykle využívána (Vindušková a Frouz 2013). Metoda vychází z předpokladu, že materiál organominerálního horizontu A a minerálního horizontu C obsahoval při nasýpání podobné množství fosilního uhlíku (C_{FOS}), a že v průběhu se množství C_{FOS} měnilo v obou horizontech s podobnou intenzitou. Za splnění podmínky rovnosti množství C_{FOS} v obou horizontech se množství A_{REC} vypočte podle vztahu:

$$A_{REC}(\%) = A_{TOTAL}(\%) - C_{TOTAL}(\%)$$

kde A_{TOTAL} je celkové množství uhlíku v horizontu A, a C_{TOTAL} celkové množství uhlíku v horizontu C.

Tento vztah byl modifikován na základě laboratorně zjištěného množství uhlíku

(C_{TOTAL}), množství fosilního uhlíku v horizontu A, a regresní analýzy těchto dvou charakteristik (kap. 5.1.2) do podoby:

$$A_{REC}(\%) = A_{TOTAL}(\%) - \frac{C_{TOTAL}(\%) + 1,9}{1,64}$$

4.3.4.2 Korekce množstvím uhlíku v horizontu C upraveným konstantou ($A_{C_{KRIB}}$)

Množství půdního fosilního uhlíku se mění rozdílně rychle v souvislosti s hloubkou (Strnad a Kříbek 1996). Na základě této informace bylo množství uhlíku zjištěného v horizontu C upraveno koeficientem vyjadřujícím podíl fosilního uhlíku v různých hloubkách po totožné době depozice materiálu. Množství A_{REC} je pak vyjádřeno jako:

$$A_{REC}(\%) = A_{TOTAL}(\%) - 0,666 \cdot C_{TOTAL}(\%)$$

4.3.4.3 Korekce podílem recentního uhlíku v horizontu A ($A_{A_{RADIO}}$)

Tento způsob odhadu množství půdního uhlíku je předložen na základě výsledků laboratorních analýz obsahu celkového a recentního uhlíku v horizontu A (kap. 5.1.2). Množství recentního uhlíku se vypočte jako:

$$A_{REC}(\%) = 0,41 \cdot A_{TOTAL}(\%) + 0,43$$

4.3.4.4 Výpočet zásoby uhlíku v horizontu A

Zjištěný relativní obsah uhlíku v horizontu A byl pomocí hloubky A horizontu a jeho objemové hmotnosti přepočten na zásobu uhlíku v organominerálním horizontu A na jednotku plochy:

$$C(kg \cdot m^{-2}) = 10 \cdot H \cdot \rho \cdot C_{rel}$$

kde C – zásoba uhlíku ($kg \cdot m^{-2}$), H – hloubka A horizontu (m), ρ – objemová hmotnost A horizontu ($g \cdot cm^{-3}$), C_{rel} – relativní obsah uhlíku v horizontu A (%).

Tímto postupem byla pro zkusné plochy vypočtena hodnota: 1/ celkové zásoby uhlíku v horizontu A (A_{TOTAL}), 2/ zásoba recentního uhlíku v horizontu A – metoda C_{RADIO} , 3/ zásoba recentního uhlíku v horizontu A – metoda C_{KRIB} , 4/ zásoba recentního uhlíku v horizontu A – metoda A_{RADIO} .

4.3.5 Hodnocení vlivu druhového složení na množství půdního uhlíku

Metodou analýzy variance bylo testováno, zda se vyskytují statisticky významné rozdíly v obsahu (%) a v zásobě ($kg \cdot m^{-2}$) organického uhlíku pod pracovními třídami druhů na odběrových plochách 2017. Analýza variance byla provedena na hladině významnosti

$\alpha = 0,05$ pro veličiny: celkový obsah uhlíku v horizontu A, celkový obsah uhlíku v horizontu C, celková zásoba uhlíku v horizontu A (A_{TOTAL}), zásoba recentního uhlíku v horizontu A – metoda C_{RADIO} , zásoba recentního uhlíku v horizontu A – metoda C_{KRIB} , zásoba recentního uhlíku v horizontu A – metoda A_{RADIO} . V případě, že byl metodou ANOVA prokázán statisticky významný rozdíl, byl proveden Tukey pos-hoc test pro určení tříd se statisticky významným rozdílem střední hodnoty obsahu/zásoby uhlíku.

Pro skupiny jehličnatých a listnatých druhů byla pro stejné veličiny obsahu/zásoby uhlíku testována hypotéza shody střední hodnoty. Testování bylo provedeno párovým t-testem na hladině významnosti $\alpha = 0,05$. Statistická analýza byla provedena v soft. prostředí Statistica 13 (TIBCO Software Inc.).

4.3.6 Hodnocení vztahu půdního uhlíku a orografie

Metodou analýzy variance bylo testováno, zda se vyskytují statisticky významné rozdíly ve svažitosti zkusných ploch pod kategoriemi pracovních tříd. Analýza variance byla provedena na hladině významnosti $\alpha = 0,05$. V případě, že byl metodou ANOVA prokázán statisticky významný rozdíl, byl proveden Tukey pos-hoc test pro určení tříd se statisticky významným rozdílem střední hodnoty svažitosti.

Pro skupiny jehličnatých a listnatých druhů byla testována hypotéza shody střední hodnoty svažitosti. Testování bylo provedeno párovým t-testem na hladině významnosti $\alpha = 0,05$.

4.4 Analýza změny vegetačního pokryvu v oblasti výsypky

Analýza změny pokryvu byla zaměřena především na plochy s přítomností stromů, případně keřů. Pro analýzu byly využity HS a ALS data z obou termínů snímání:

- HS 2009 + ALS 2010
- HS 2017 + ALS 2017


Z důvodu nižší bodové hustoty datové sady ALS 2010, byla analýza změny pokryvu prováděna na rastrových datech s velikostí pixelu 1 m. Použití tohoto prostorového rozlišení zároveň umožnilo zarovnání rastrových vrstev vstupujících do analýzy ke stejnému počátku. Jelikož HS data z roku 2009 pokrývají nejmenší plochu, byly veškeré analýzy změn pokryvu prováděny pod maskou, která byla připravena na jejich základě.

Pro jednotlivé roky byla z HS dat nejprve vypočtena hodnota indexu NDVI. Následně byly tyto vrstvy převzorkovány na společné prostorové rozlišení 1 m, kdy nová hodnota pixelu byla vypočtena jako průměr hodnot pixelů, jejichž střed se nacházel uvnitř nového pixelu.

Z prvních odrazů předzpracovaného bodového mračka ALS dat byl pro jednotlivé termíny pomocí nástroje „blast2dem“ odvozen model výšek nadzemních objektů (CHM) ve společném prostorovém rozlišení 1 m.

Pro každou datovou sadu (2009+2010 a 2017) byla následně pomocí rozhodovacího stromu (Obr 12) provedena klasifikace pokryvu do pěti tříd:

- holá půda
- bylinná vegetace
- směs bylinné a nízké dřevinné vegetace
- nízká dřevinná vegetace
- vysoká dřevinná vegetace



Obr 12: Rozhodovací strom pro klasifikaci pokryvu do tříd použitých pro výpočet změny pokryvu území.

Na vrstvy klasifikace byl aplikován modální filtr s velikostí okna 3×3 . Z takto připravených vrstev klasifikace pokryvu byla vypočtena rozdílová vrstva vyjadřující kombinace přechodů mezi jednotlivými třídami pokryvu. Třídy označující změny v pokryvu byly sloučeny do skupin: 1/ na základě intenzity změny, 2/ na základě přítomnosti dřevinné vegetace.

Dle intenzity byly vytvořeny 4 kategorie: pro nárůst množství vegetace kategorie „pozitivní++“ a „pozitivní+-“, pro úbytek vegetace „negativní--“ a „negativní+-“ (Tab 6). Pro změnu množství dřevinné vegetace byly vytvořeny 3 třídy – nárůst, úbytek a beze

změny (Tab 7). Následně byla vypočtena celková plošná změna pokryvu jako počet pixelů dané kategorie vážený plochou pixelu.

Tab 6: Reklasifikační tabulka pro třídy změny množství vegetace.

intenzita změny	2009	2017
pozitivní +	bylin	směs
	směs	nízká dř.
	nízká dř.	vysoká dř.
pozitivní ++	holá půda	nízká dř.
	bylin	nízká dř.
	holá půda	vysoká dř.
	bylin	vysoká dř.
	směs	vysoká dř.
	holá půda	bylin
	holá půda	směs
negativní -	vysoká dř.	nízká dř.
	nízká dř.	směs
	směs	bylin
negativní --	vysoká dř.	holá půda
	vysoká dř.	bylin
	vysoká dř.	směs
	nízká dř.	holá půda
	nízká dř.	bylin
	směs	holá půda
	bylin	holá půda

Tab 7: Reklasifikační tabulka pro třídy změny pokryvu dřevinnou vegetací.

změna dř. pokryvu	2009	2017
+	holá půda	vysoká dř.
	bylin	vysoká dř.
	směs	vysoká dř.
	holá půda	nízká dř.
	bylin	nízká dř.
	směs	nízká dř.
-	vysoká dř.	holá půda
	vysoká dř.	bylin
	vysoká dř.	směs
	nízká dř.	holá půda
	nízká dř.	bylin
	nízká dř.	směs
0	vysoká dř.	vysoká dř.
	nízká dř.	nízká dř.
	nízká dř.	vysoká dř.
	vysoká dř.	nízká dř.

4.5 Klasifikace tříd druhů na základě dat DPZ

Jednotlivé druhy dřevin na výsypce se vyskytují v prostorově větších a druhově homogenních celcích (důsledek výsadby). Pro druhovou klasifikaci byla zvolena metoda objektově orientované analýzy obrazu (OBIA), která byla provedena v prostředí eCognition (Trimble Munich, Německo). Tento přístup umožňuje pracovat s prostorově většími celky, které lze charakterizovat určitým stupněm homogenity vybraných parametrů. V tomto případě jsou celky tvořeny částmi monokultur s „homogenní“ spektrální odezvou. Klasifikace pomocí OBIA se skládá ze dvou kroků: segmentace obrazu na celky s definovanými vlastnostmi a následné klasifikace těchto objektů do cílových tříd. Pro segmentaci a klasifikaci byly využity dva zdroje dat: letecká obrazová hyperspektrální data a data odvozená z ALS skenování. Na HS datech byla nejprve provedena Minimal Noise Fraction (MNF) transformace (Green et al. 1988). MNF transformace je složena ze dvou lineárních transformací. První transformace normalizuje šum senzoru. Při druhé transformaci se provádí lineární transformace původního n-rozměrného spektrálního prostoru do nového ortogonálního systému, čímž se dosahuje nezávislosti nově vygenerovaných komponent. První komponenta obsahuje většinu variability původního datového souboru a s rostoucím číslem komponenty klesá množství v ní obsažené informace a zvyšuje se podíl šumu. Následná analýza (segmentace a klasifikace) je pak výpočetně jednodušší při zachování většiny původní informace. Z LiDAR dat byl jako pomocná vrstva vygenerován rastrový digitální výškový model reprezentující výšku vegetace (CHM). Počty použitých komponent a parametry CHM jsou specifikovány dále, samostatně pro jednotlivé datové sady 2009+2010 a 2017.

4.5.1 Klasifikace datové sady 2009+2010

Ke klasifikaci bylo použito prvních 30 MNF komponent s prostorovým rozlišením 0,4 m odvozených z HS dat 2009 a CHM s prostorovým rozlišením 0,8 m vytvořený na základě LiDAR dat 2010. V prvním kroku byla vytvořena maska porostů prahováním vrstvy CHM. Jako aktivní byly ponechány pixely s hodnotami výšky CHM > 1 m. V druhém kroku byla pod vrstvou masky provedena dvouúrovňová „multiresolution“ segmentace na základě MNF komponent. První úroveň segmentace byla parametrizována tak, aby vytvořila segmenty, které by byly málo ovlivněné případnou změnou hustoty korunového zápoje. Druhá úroveň segmentace byla parametrizována, aby produkovala plošně větší objekty, které by ale respektovaly hranice monokulturních porostních celků. Ve třetím kroku byla v soft. eCognition provedena klasifikace na základě nejbližšího souseda (kNN; $k = 1$). Segmenty jednotlivých tříd sloužící jako reference pro kNN klasifikátor ($n = 217$) byly vybrány z první úrovně segmentace pod plochami zkusných ploch 2006. Vlastní klasifikace pak probíhala na druhé úrovni segmentace (větší objekty). Pro validaci klasifikace byly pod maskou zkusných ploch 2006 vybrány ty segmenty, které: 1/ pronikaly celou plochu polygonu nebo; 2/ průnik tvořil alespoň 30 procent jejich vlastní plochy. Tímto způsobem bylo celkem vybráno 107 segmentů. Validace byla provedena prostřednictvím křížné matice, „producer accuracy“ a „user accuracy“.

4.5.2 Klasifikace datové sady 2017

Jako vstupní data pro objektově orientovanou klasifikaci dat nasnímaných v roce 2017 bylo použito prvních 10 MNF komponent odvozených z HS dat 2017 a CHM vytvořený na základě LiDAR dat 2017. Všechny použité vrstvy měly shodné prostorové rozlišení 0,4 m. V prvním kroku byla vytvořena maska porostů prahováním vrstvy CHM. Jako aktivní byly ponechány pixely s hodnotami výšky CHM > 1 m. Ve druhém kroku byla pod 1m maskou provedena segmentace obrazu na základě MNF komponent. Pro jednotlivé segmenty byly vypočteny zonální statistiky na základě MNF komponent a rastru CHM (Tab 8).

Tab 8: Atributy objektů použité pro klasifikaci druhů z datové sady 2017

Proměnné založené na MNF datech

Průměrná hodnota MNF kanálu 1 – 10

Směrodatná odchylka MNF kanálu 1 – 10

GLCM homogenita MNF kanálu 4

GLCM entropie MNF kanálu 9

GLCM StdV MNF kanálu 2

GLCM StdV MNF kanálu 3

Proměnné založené na CHM

Průměrná výška CHM

Směrodatná odchylka výšky CHM

Normalizovaný kvantil výšky CHM; $rq_n = q_n / q_{100}$; pro $n = 10, 25, 50, 75, 85, 95$

Segmenty byly vyexportovány do formátu SHP. Ve třetím kroku byla provedena klasifikace pomocí algoritmu „Support Vector Machine“ (SVM) (Vapnik 1979). Pro klasifikaci byla použita python knihovna „Scikit-learn“ (Pedregosa et al. 2011). Při trénování klasifikátoru byly testovány různé varianty možných parametrů (Tab 9).

Tab 9: Testované parametry SVM klasifikátoru.

kernel	parametr	hodnota
radial basis	C	1, 10, 100, 1000, 5000, 10 000
function	gamma	0.0001, 0.0005, 0.001, 0.005, 0.01, 0.1, 0.2, 0.5, 0.7, 1.0
polynom	stupeň	2, 3, 4, 5

Pro trénování klasifikátoru byla použita data z terénních šetření z roku 2017. Polygony ploch ($r = 8$ m), na kterých probíhalo vzorkování, se překrýly s vrstvou segmentů a pro analýzu byly vybrány ty segmenty, které: 1/ pronikaly celou plochu polygonu nebo; 2/ průnik tvořil alespoň 30 procent jejich vlastní plochy. Celkem bylo pro trénování klasifikátoru vybráno 889 segmentů. Analogickým způsobem byly na plochách, kde probíhalo vzorkování v roce 2006, získány segmenty, které byly použity pro validaci klasifikace. Pro validaci bylo identifikováno 257 segmentů. Validace byla provedena prostřednictvím křížné matice, hodnot „producer accuracy“ a „user accuracy“.

4.6 Odhad množství nadzemní biomasy na základě dat DPZ

4.6.1 Odhad množství uhlíku nadzemní biomasy z dat 2009+2010

Z důvodu nízké hustoty bodů ALS dat byl pro hodnocení vztahu mezi hyperspektrálními, ALS daty a daty z pozemních šetření zvolen plošný přístup (vztah je hledán na úrovni prostorové jednotky, pixelu). Proto byly nejprve vytvořeny rastrové vrstvy jednotlivých vysvětlujících proměnných tak, že hyperspektrální a ALS data s vysokým prostorovým rozlišením byla převzorkována na velikost pixelu 14 m. Tato velikost pixelu reprezentuje velikost zkusných ploch, na nichž byla prováděna terénní měření. Souhrn vysvětlujících proměnných uvádí Tab 10. Jednotlivým zkusným plochám pak byly přiřazeny hodnoty vysvětlujících proměnných z pixelu, který byl nejbližší ke středu zkusné plochy.

Tab 10: Vysvětlující proměnné odvozené na základě HS a LiDAR dat pro parametrizaci regresních modelů.

Proměnné založené na hyperspektrálních datech

Průměrná hodnota reflektance v jednotlivých spektrálních kanálech

Směrodatná odchylka reflektance v jednotlivých spektrálních kanálech

Proměnné založené na datech ALS

Digitální model terénu (m)

Orientace terénu (stupně)

Svažitost

Topografický vlhkostní index

Průměrná výška bodů vegetace (m)

Směrodatná odchylka výšky bodů vegetace (m)

Počet modů výškového rozdělení bodů

Střed nejkratšího 50% intervalu (m)

Poloha výškového percentilu bodů vegetace (m) - 5, 10, 15, 25, 50, 75, 85, 90, 95

Pokryvnost korunové vrstvy (%)

Hustota korunové vrstvy (%)

Pokryvnost korunové vrstvy byla vypočtena jako podíl prvních odrazů nad prahovou hodnotou výšky (2 m) vůči všem prvním odrazům pro daný pixel. Hustota korunové vrstvy byla vypočtena jako podíl všech odrazů nad prahovou hodnotou výšky (2 m) vůči všem odrazům pro daný pixel.

Pomocí Pearsonova korelačního koeficientu bylo testováno, zda existuje lineární vztah mezi jednotlivými vysvětlujícími proměnnými a množstvím uhlíku nadzemní biomasy. Hodnoty korelace byly zjišťovány zvlášť pro jehličnaté a listnaté stromy a pro sloučenou datovou sadu. Následně byly sestaveny lineární modely mezi množstvím uhlíku nadzemní biomasou a nezávislou proměnnou s nejvyšší hodnotou korelačního koeficientu. Tyto modely byly pod maskou příslušných skupin aplikovány na rastrovou vrstvu nezávislé proměnné. Takto získané mapy prostorové distribuce nadzemní biomasy byly sloučeny a pod maskou klasifikace jednotlivých druhů (kap. 5.3.1) bylo zjištěno celkové množství uhlíku nadzemní biomasy ve studovaném území.

4.6.2 Odhad množství uhlíku nadzemní biomasy z dat 2017

Letecká data ALS nasnímaná v roce 2017 dosahovala výrazně vyšší bodové hustoty oproti datům nasnímaným v roce 2010 (Tab 6). Tato hustota je již dostatečná pro odhad množství nadzemní biomasy na základě identifikace jednotlivých stromů (Yu et al. 2010; 2014; Sibona et al. 2016).

Postup, který byl aplikován, sestával z následujících kroků:

1. identifikace jednotlivých stromů,
2. verifikace hustoty stromů a jejich výšky,
3. odhad množství nadzemní biomasy.

4.6.2.1 Identifikace jednotlivých stromů z dat ALS

Identifikace stromů probíhala na základě dvou vstupních vrstev. První vrstvou byl rastrový digitální model výšky porostu (CHM) s prostorovým rozlišením 0,25 m vygenerovaný na základě výškově normalizovaného LiDARového mračka bodů. Pro výpočet byl použit program „las2dem“ (rapidlasso GmbH, Německo). Druhou vstupní vrstvou byla rastrová vrstva klasifikace druhů, která byla vytvořena na základě OBIA analýzy HS a LiDAR dat 2017 (kap. 5.3.2). Pro identifikaci jednotlivých stromů byl použit algoritmus založený na identifikaci lokálních maxim (Novotný 2014; Hanuš et al. 2017). Algoritmem jsou nejprve identifikována potenciální lokální maxima v rastru CHM. Identifikace lokálních maxim probíhá pod plovoucím oknem dotazováním, zda je středový pixel maximem hodnot plovoucího okna. Takto identifikované potenciální stromy jsou seřazeny na základě hodnoty výšky v klesajícím pořadí. V dalším kroku jsou mezi potencionálními stromy iterativním procesem, založeným na alometrických rovnicích poloměru koruny a analýze obrazu, vyhledávány nejpravděpodobnější vrcholy jednotlivých stromů. Pro vyhledávání stromů byly využity druhově specifické alometrické rovnice pro výpočet poloměru koruny (Tab 11).

Tab 11: Parametry druhově specifických rovnic pro výpočet poloměru koruny. Zdroj: (Pretzsch et al. 2015)

$\ln(cr) = a + b \cdot \ln(dbh)$		
Druh	a	b
lípa	-0,3512	0,5812
smrk, dub	-0,3947	0,4821
borovice, olše, modřín, ostatní, spontánní	-1,0065	0,6575

Tyto rovnice využívají pro odhad poloměru koruny veličinu DBH. Jelikož hodnotu DBH není možné z leteckých LiDAR dat přímo získat, byly na základě dat získaných při terénních měřeních v roce 2017 odvozeny místně a druhově specifické vztahy mezi výškou stromu a DBH. Pro odhad DBH byla použita metoda lineární regrese.

4.6.2.2 Verifikace hustoty stromů a jejich výšky

Před další analýzou (odhadem AGB) bylo pro jednotlivé druhy provedeno srovnání množství počtu identifikovaných stromů vůči referenční hodnotě získané vizuální interpretací CHM rastru a ortofoto snímků. Toto srovnání bylo provedeno na plochách, na kterých probíhalo vzorkování včetně inventarizace počtu stromů v roce 2006. Pro celkem 28 těchto ploch ($r = 8$ m) byly v prostředí GIS manuálně identifikovány středy korun jednotlivých stromů. Počet stromů identifikovaný algoritmičticky byl srovnán s počtem stromů identifikovaným vizuálně a s počtem stromů identifikovaným při terénním šetření 2006.

Srovnání výšky algoritmičticky identifikovaných stromů s výškou stromů změřenou v terénu bylo provedeno na plochách ($r = 8$ m), na kterých probíhalo měření biomasy v roce 2017. Protože při terénním šetření byla měřena na každé ploše výška vždy jen 10 stromů, bylo srovnání pro jednotlivé druhy provedeno na základě středních hodnot výšky stromů změřených v terénu a středních hodnot výšek stromů identifikovaných algoritmičticky. Pro srovnání byla využita hodnota Pearsonova korelačního koeficientu.

4.6.2.3 Odhad množství nadzemní biomasy

Pro odhad biomasy jednotlivých algoritmičticky identifikovaných stromů byly využity druhově specifické alometrické rovnice. Vzhledem k cca desetiletému odstupu nebyly použity rovnice využívané při vyhodnocení dat terénního šetření 2006. Místo nich byly na základě DBH zjištěného při terénním měření 2017 a literatury identifikovány druhově specifické rovnice (Tab 12). Pro většinu sledovaných druhů tyto rovnice využívají jako parametry DBH a výšku. Jako výška a DBH byly použity hodnoty získané při algoritmičticky identifikaci stromů. Poté co byly dostupné hodnoty všech vyžadovaných parametrů, byla pomocí alometrických rovnic pro jednotlivé, algoritmičticky identifikované stromy vypočtena hodnota množství nadzemní biomasy (kg_{dw}), která byla následně přepočtena na množství uhlíku pomocí koeficientu 0,5. Nakonec bylo pod maskou klasifikace druhů pro jednotlivé sledované druhy vypočteno celkové množství uhlíku nadzemní biomasy ve sledovaném území.

Tab 12: Alometrické rovnice použité pro výpočet nadzemní biomasy stromů identifikovaných z dat ALS.

třída	D (cm)	rovnice (kg _{dw})	zdroj
a	< 15	$ab=0,00079 \cdot 10 \cdot D^{2,28546}$ $ab=0,00309 \cdot 10 \cdot D^{2,022126}$	(T. Johansson 2000b) (Tord Johansson 1999b)
l	< 6	$ab=-2,0108+2,1517 \cdot \ln(D)$ $ab=0,1081 \cdot D^{1,53} \cdot H^{0,9482}$	(Zavitkovski, Lundgren, and Strong 1983) (Snorrason and Einarsson 2006)
pc	< 10	$ab=H^{-0,2028} \cdot 0,4274 \cdot (D+1)^{0,8674+1,0099 \cdot \ln(D)}$ $ab=0,11975 \cdot (D^2 \cdot H)^{0,81336}$	(Černý 1990) (Chroust and Tesařová 1985)
pn	< 6	$ab=0,1599 \cdot D^{2,206}$ $ab=(200,87186 \cdot D^2+124,6808 \cdot D^2-49,0)/1000$	(Chroust 1985) (Brække 1986)
q		$ab=\exp(-2,4232+2,4682 \cdot \ln(d))$	(Bunce 1968)
s	< 9	$ab=1,46 \cdot 10^{-4} \cdot 10 \cdot D^{2,6035333}$ $ab=0,0519 \cdot D^{2,545}$	(Tord Johansson 1999a) (Rock 2007)
t	< 10	$ab=\exp(-2,6788+2,4542 \cdot \ln(D))$ $ab=\exp(-3,032+2,115 \cdot \ln(D)+0,538 \cdot \ln(H))$	(Bunce 1968) (Čihák et al. 2014)

4.7 Zásoba půdního uhlíku

Celková zásoba uhlíku v zájmovém území mohla být pro jednotlivé druhy odhadnuta na základě mapy prostorové distribuce půdního uhlíku. Výběr techniky použité pro odvození této mapy byl závislý na analýze faktorů, které mohou množství půdního uhlíku ovlivňovat. Zásoba uhlíku v zájmovém území byla prostřednictvím zonální statistiky vypočtena pro jednotlivé třídy druhů dřevin. Zonální výpočet probíhal pod maskou klasifikace 2017, která byla z důvodu nerovnoměrné distribuce zkusných ploch oříznuta hranicí HS dat použitých pro klasifikaci 2009.

4.7.1 Analýza dat 2009+2010

Pomocí korelační analýzy byla testována závislost zásoby půdního uhlíku v horizontu A získané při terénním šetření v roce 2006 vůči charakteristikám odvozeným na úrovni pixelu z dat DPZ (Tab 10). Testování probíhalo na hladině statistické významnosti $\alpha = 0,05$.

4.7.2 Hodnocení vztahů půdního uhlíku a množství nadzemní biomasy

Posledním z faktorů potencionálně ovlivňujících množství půdního uhlíku bylo množství nadzemní biomasy. Tento faktor bylo možné na základě získaných dat analyzovat až po provedení odhadu množství nadzemní biomasy na zkusných plochách 2017. Možný vztah mezi množstvím uhlíku nadzemní biomasy, relativním obsahem uhlíku (%) a zásobou uhlíku (kg·m²) byl testován pro všechna pozorování, jehličnaté a listnaté druhy a jednotlivé třídy prostřednictvím korelační analýzy.

4.7.3 Prostorová distribuce půdního uhlíku 2017

Pro interpolaci jednotlivých parametrů v ploše celého zájmového území z bodově získaných dat byla vybrána metoda založená na radiálních bázích, která je v dalším textu odkazována označením RBF (Radial Basis Function). Volbě této metody předcházelo zhodnocení základních statistických charakteristik jednotlivých parametrů z chemických a fyzikálních analýz půd, z nichž rozhodující pro volbu interpolační metody byly následující: 1/ prostorové rozmístění bodových dat je shlukovité, s velkými prázdnými plochami z důvodu jiného než hodnoceného dřevinného pokryvu; 2/ prostorově sousedící data vykazují velkou hodnotovou variabilitu a tudíž nelze využít metod postavených na vazbě mezi změnou hodnoty vlastnosti a změnou vzdáleností mezi body. Proto také stochastické geostatistické metody, založené na autokorelaci a určitém rozložení hodnot dat, nemohly poskytnout dostatečně přesný interpolovaný povrch pro celé zájmové území. Problém je také v prostorové „nespojivosti“ území, což bylo dáno finančními a technickými možnostmi při prvním leteckém skenování území, na jehož základě byly zkusné plochy pro rok 2017 navrženy (kap. 4.3.3).

Naopak, deterministické metody RBF mají některé vlastnosti, odpovídající prostorovému a hodnotovému rozložení získaných dat: RBF nekladou většinou žádné omezující podmínky na charakter dat a vhodnou volbou parametrů lze minimalizovat chybu mezi interpolací provedenou z kalibračních dat a validačními body. Mezi základní parametry, vyjma volby typu jádrové funkce (Kernel function), které je nutné specifikovat, patří velikost hlavní a vedlejší poloosy, minimální a maximální počet bodů a parametr kernelu. Hlavní a vedlejší poloosy definují radiálně symetrickou plochu jádra (plošný rozsah území), v rámci kterého jsou odvozeny váhy jednotlivých bodů dané minimálním a maximálním počtem bodů, vstupujících do výpočtu funkce. Parametr kernel určuje charakter změny funkce (tvar funkce). Interpolace byla provedena v prostředí ArcGIS (Esri, USA). Z RBF metod dostupných v knihovně „Geostatistical Analyst“ byla po testování zvolena metoda "Inverse multiquadric" (Mongillo 2011). Vstupní bodová data (118 bodů) byla náhodným výběrem (generátor náhodných čísel ArcGIS) rozdělena do dvou skupin. Kalibrační soubor obsahuje 60 bodů, validační soubor 58 bodů. Metodou RBF bylo zpracováno celkem 6 vrstev/map, interpolovaných z atributů bodových dat:

1. procentuální zastoupení uhlíku v C horizontu,
2. procentuální zastoupení uhlíku v A horizontu,
3. celkové množství uhlíku v A horizontu ($\text{kg} \cdot \text{m}^{-2}$) bez odečtení fosilního uhlíku,
4. množství uhlíku v A horizontu ($\text{kg} \cdot \text{m}^{-2}$) po odečtení fosilního uhlíku metodou A_C_{RADIO} ,

5. množství uhlíku v A horizontu ($\text{kg} \cdot \text{m}^{-2}$) po odečtení fosilního uhlíku metodou, A_C_{KRIB} ,
6. množství uhlíku v A horizontu ($\text{kg} \cdot \text{m}^{-2}$) po odečtení fosilního uhlíku metodou A_A_{RADIO} .

Náhodný výběr kalibračních a validačních bodů se neměnil, zatímco parametry RBF byly optimalizovány pro každou na základě validace výsledků daného parametru.

5 Výsledky

5.1 Výsledky terénních šetření

5.1.1 Výsledky z dat 2006

Průměrná množství uhlíku vázaného v nadzemní biomase dřevin (C_{AGB}), množství recentního uhlíku v horizontu A a množství uhlíku v horizontu C, která byla zjištěna při pozemním šetření, jsou prezentována v Tab 13. Největší množství nadzemní biomasy bylo zjištěno v porostech modřinu „l“. Mezi listnatými dřevinami bylo nejvyšší množství nadzemní biomasy pozorováno u lípy „t“ a olše „a“. Nejmenší množství nadzemní biomasy bylo pozorováno u ploch spontánní sukcese „s“. Absolutní množství recentního uhlíku v horizontu A vykazovalo podobný trend jako množství nadzemní biomasy. V horizontu A bylo pod porosty jehličnatých dřevin na zkoumaných plochách akumulováno přibližně 60 % průměrného množství pod druhy listnatými.

Tab 13: Množství uhlíku v nadzemní biomase a půdě na zkusných plochách v roce 2006. Zdroj: (Frouz et al. 2009)

třída	$C_{\text{AGB}} \pm \text{Std (t.ha}^{-1}\text{)}$	$C_{\text{Ahor}} \pm \text{Std (t.ha}^{-1}\text{)}$	$C_{\text{Ahor}} \pm \text{Std (\%)} $	$C_{\text{Chor}} \pm \text{Std (\%)} $	věk (r)
a	$45,6 \pm 17,2$	$35,9 \pm 20,4$	$7,1 \pm 0,5$	$2,5 \pm 0,5$	$28,0 \pm 2,2$
q	$33,9 \pm 7,8$	$15,9 \pm 7,0$	$6,7 \pm 0,8$	$1,9 \pm 0,6$	$28,0 \pm 0,0$
t	$45,5 \pm 15,5$	$37,9 \pm 7,0$	$9,5 \pm 0,2$	$1,9 \pm 0,5$	$31,0 \pm 0,5$
s	$17,0 \pm 6,4$	$2,4 \pm 3,6$	$6,5 \pm 0,5$	$1,4 \pm 0,2$	$27,8 \pm 1,3$
pc	$29,5 \pm 11,5$	$4,1 \pm 3,9$	$4,8 \pm 0,2$	$2,4 \pm 0,2$	$27,0 \pm 2,1$
pn	$21,1 \pm 12,4$	$6,6 \pm 2,5$	$4,6 \pm 0,4$	$3,0 \pm 0,4$	$22,0 \pm 0,9$
l	$67,6 \pm 11,9$	$19,0 \pm 4,7$	$4,2 \pm 0,2$	$3,7 \pm 0,3$	$29,5 \pm 2,1$

Pro přehled tříd viz Tab 2.

5.1.2 Výsledky z dat 2015

Ve čtrnácti vzorcích odebraných v roce 2015 byl a) laboratorně zjištěn obsah celkového uhlíku, b) metodou ^{14}C radiokarbonové hmotnostní spektroskopie byl stanoven podíl recentního uhlíku v A horizontu (Tab 14). Průměrné množství uhlíku zjištěné na vybraných plochách ve vzorcích 2015 bylo asi třikrát vyšší oproti stavu zjištěnému v roce 2006. K nejvyšší změně množství půdního uhlíku pod jednotlivými druhy došlo


v případě ploch smrku.

Tab 14: Množství uhlíku stanoveného ve vzorcích 2015 laboratorně a metodou ^{14}C hmotnostní spektroskopie .

plocha	třída	2006	2015					
		A_{REC} ($\text{kg}\cdot\text{m}^{-2}$)	A_{TOTAL} (%)	C_{TOTAL} (%)	pMC	A_{REC} (%)	A_{REC} ($\text{kg}\cdot\text{m}^{-2}$)	A_{FOS} (%)
1	olše	2,4	5,09	1,20	71,45	3,16	4,72	1,93
2	smrk	0	8,45	2,55	60,58	4,45	6,37	4,00
3	smrk	0,66	7,74	4,05	47,94	3,23	4,04	4,51
4	smrk	0,92	6,94	2,77	62,26	3,76	6,58	3,18
5	borovice	0,49	4,65	3,04	45,44	1,84	3,26	2,81
6	borovice	0,72	5,68	3,20	40,66	2,01	3,22	3,67
7	dub	1,06	6,00	7,31	50,26	2,62	4,15	3,38
8	dub	2,06	8,04	10,80	39	2,73	4,24	5,32
9	dub	2,47	7,46	4,58	64,25	4,17	6,34	3,29
10	spontánní	0,02	7,46	6,86	23,1	1,50	2,15	5,96
11	spontánní	0	7,95	5,74	36,25	2,51	4,00	5,44
12	lípa	3,49	5,96	2,32	56,84	2,95	4,85	3,01
13	lípa	4,53	7,41	2,81	63,65	4,10	7,36	3,31
14	lípa	4,37	6,95	1,88	66,38	4,01	7,04	2,94


Zdroj dat 2006 (Frouz, osobní sdělení)

U 14 testovaných vzorků byl nalezen statisticky významný vztah ($p < 0,01$) mezi koncentrací uhlíku v C horizontu (C_{TOTAL}) a koncentrací fosilního uhlíku v A horizontu (A_{FOS}), která byla zjištěna pomocí ^{14}C analýzy (Obr 13).



Obr 13: Regresní analýza mezi relativním množstvím fosilního uhlíku v A horizontu a relativním množstvím celkového uhlíku v C horizontu.

Přímé stanovení množství recentního uhlíku ^{14}C metodou umožnilo testovat závislost mezi celkovým množstvím uhlíku a množstvím recentního uhlíku v A horizontu. Pro tento test bylo jedno z pozorování (plocha 10) vyřazeno jako odlehlá hodnota. Metodou jednoduché lineární regrese byla zjištěna slabě statisticky významná ($p = 0,04$) závislost mezi testovanými proměnnými (Obr 14).



Obr 14: Regresní analýza relativního množství celkového uhlíku (A_{TOTAL}) a relativního množství recentního uhlíku (A_{REC}) v horizontu A.

5.1.3 Výsledky z dat 2017

Odběr půdních vzorků proběhl v roce 2017 na 118 plochách, navržených na základě výsledku klasifikace datové sady 2009+2010 a výšky porostu odvozené z ALS dat 2010. Ve vzorcích byl laboratorně stanoven relativní obsah organického uhlíku (Tab 15). Pro výpočet statistik za jednotlivé pracovní třídy byla jedna plocha třídy „q“ (dub) vyloučena pro výrazně odlehlou hodnotu relativního obsahu uhlíku v horizontu A.


Tab 15: Relativní množství uhlíku v půdě a věk porostů zkusných ploch 2017.

třída	A _{TOTAL} ± Std (%)	C _{TOTAL} ± Std (%)	věk ± Std (r)	n
a	6,2 ± 2,4	3,7 ± 1,8	26,8 ± 12,5	26
q	5,5 ± 0,8	3,5 ± 0,6	35,9 ± 2,3	7
t	5,4 ± 1,5	2,7 ± 0,8	42 ± 0	7
s	5,6 ± 1,4	3,6 ± 2	19,3 ± 9,7	16
o	4,7 ± 1,1	2,3 ± 1,3	35,2 ± 9,2	6
pc	5,7 ± 1,4	4,1 ± 1,4	25,4 ± 8,8	21
pn	4,8 ± 1,4	4,1 ± 1,7	17,9 ± 3,1	20
l	6,4 ± 2,5	4,9 ± 2,1	23,9 ± 11,8	15


věk - zdroj Ciencala, osobní sdělení

Pro přehled tříd viz Tab 2.

Na úrovni všech zkusných ploch byl pozorován statisticky významný rozdíl ($p < 0,01$) střední hodnoty relativního obsahu organického uhlíku mezi horizontem A (5,7 %) a horizontem C (3,9 %), viz Obr 15. Relativní obsah organického uhlíku v horizontu A vykazoval u všech pracovních tříd nižší variabilitu než v horizontu C. Zatímco v horizontu A nebyl zjištěn statisticky významný rozdíl střední hodnoty obsahu organického uhlíku mezi třídami druhů, byl zjištěn stat. významný rozdíl tříd „t, o“ a „l“ pro obsah uhlíku v C horizontu (Obr 16).



Obr 15: Relativní množství uhlíku (%_{hm}) horizontů A a C stanovené ve vzorcích 2017.



Obr 16: ANOVA - relativní množství uhlíku (%_{hm}) v horizontu C pro jednotlivé třídy.

Pro přehled tříd viz Tab 2.

5.1.3.1 Další faktory prostředí z dat 2017

Kromě relativního množství uhlíku byly pro zkusné plochy měřeny i další parametry. Při odběru vzorků byla měřena hloubka A horizontu, ze vzorků A horizontu byla stanovena objemová hmotnost, na základě digitálního modelu reliéfu terénu z ALS dat byla pro jednotlivé plochy vypočtena hodnota svažitosti, a jednotlivým plochám byla přiřazena hodnota stáří porostu (Tab 16, 15).


Tab 16: Objemová hmotnost a hloubka horizontu A a svažitost zkusných ploch pro jednotlivé třídy 2017.

třída	obj. hmotnost $\pm$ Std (t·m ⁻³)	hloubka Ahor $\pm$ Std (cm)	svažitost $\pm$ Std (°)
a	1,6 $\pm$ 0,4	10,9 $\pm$ 6	5,8 $\pm$ 3,6
q	1,6 $\pm$ 0,1	11,3 $\pm$ 2,2	4,8 $\pm$ 1,5
t	1,7 $\pm$ 0,2	6,4 $\pm$ 2	7,2 $\pm$ 3,4
s	1,2 $\pm$ 0,4	6,9 $\pm$ 4	9,5 $\pm$ 5,7
o	1,5 $\pm$ 0,3	9,9 $\pm$ 3,8	7 $\pm$ 3,2
pc	1,4 $\pm$ 0,3	8,9 $\pm$ 2,8	6,9 $\pm$ 4,4
pn	1,6 $\pm$ 0,4	9,2 $\pm$ 3	5,6 $\pm$ 3,2
l	1,3 $\pm$ 0,6	9,2 $\pm$ 4,2	4,2 $\pm$ 2,4

Pro přehled tříd viz Tab 2.

U skupiny jehličnatých druhů byly pozorovány velmi podobné hloubky horizontu A. V případě listnatých stromů vykazovaly nižší hodnoty třídy „t“ a „s“, avšak statisticky

významné rozdíly nebyly prokázány ani mezi jednotlivými třídami ani mezi skupinou listnatých a jehličnatých druhů. A horizont pod listnatými a jehličnatými druhy dosahoval v průměru blízkých hodnot objemové hmotnosti ($1,48$ a $1,43 \text{ t}\cdot\text{m}^{-3}$) a nebyl mezi nimi zjištěn statisticky významný rozdíl. V případě jednotlivých tříd byly zjištěny statisticky významné rozdíly ($p < 0,01$) mezi třídami (Obr 17). Nejvýraznější rozdíl byl zjištěn u třídy „s“, která dosahovala nejnižší průměrné objemové hmotnosti ($< 1,2 \text{ t}\cdot\text{m}^{-3}$). Tukeyho test prokázal statisticky významnou odlišnost třídy „s“ od tříd „pn“ a „a“. Odlišnost tříd „s“ a „t“ byla na hranici statistické významnosti (Tab 17).



Obr 17: ANOVA - objemová hmotnost pod jednotlivými třídami.
Pro přehled tříd viz Tab 2.


Tab 17: TUKEY test - rozdíly v objemové hmotnosti mezi třídami ($\alpha = 0,05$).

třída	l	t	pn	s	a	o	pc	q
l		0,332	0,248	0,972	0,256	0,888	0,997	0,783
t	0,332		1,000	0,058	0,999	0,997	0,618	0,999
pn	0,248	1,000		0,018	1,000	1,000	0,580	1,000
s	0,972	0,058	0,018		0,016	0,433	0,629	0,283
a	0,256	0,999	1,000	0,016		1,000	0,606	1,000
o	0,888	0,997	1,000	0,433	1,000		0,989	1,000
pc	0,997	0,618	0,580	0,629	0,606	0,989		0,963
q	0,783	0,999	1,000	0,283	1,000	1,000	0,963	

Pro přehled tříd viz Tab 2.

Rozdíl ve svažitosti mezi skupinou listnatých a jehličnatých druhů byl výraznější než v případě hloubky A horizontu a objemové hmotnost, nicméně nebyl statisticky

významný. V průměru se svažitost vzorkovaných ploch pohybovala mezi 5–7°. Výjimku tvořily třídy „l“ a „q“, se svažitostí mezi 4–5°, a třída „s“ spontánní sukcese. Vyšší svažitost listnatých ploch je způsobena statisticky významně odlišnou svažitostí ploch spontánní sukcese (Obr 18).



Obr 18: ANOVA - svažitost pod jednotlivými třídami.
Pro přehled tříd viz Tab 2.


Z hlediska věku byl pozorován statisticky významný rozdíl jak mezi skupinami listnatých a jehličnatých druhů ($p < 0,01$), tak i mezi jednotlivými třídami ($p < 0,01$).

5.1.4 Zásoba uhlíku na zkusných plochách

Na základě charakteristik zjištěných během odběru vzorků a laboratorní analýzou byla pro jednotlivé zkusné plochy vypočtena zásoba uhlíku ($\text{kg} \cdot \text{m}^{-2}$). Množství uhlíku bylo vypočteno jako:


- celkové množství uhlíku v horizontu A (A_{TOTAL}),
- množství recentního uhlíku normalizací uhlíkem horizontu C podle ^{14}C analýzy ($A_{\text{C}_{\text{RADIO}}}$),
- množství recentního uhlíku normalizací uhlíkem horizontu C váženým konstantou ($A_{\text{C}_{\text{KRIB}}}$),
- množství recentního uhlíku přímým vztahem mezi A_{TOTAL} a recentním uhlíkem zjištěným ^{14}C analýzou ($A_{\text{A}_{\text{RADIO}}}$).

Zásoba uhlíku vypočtená metodami $A_{C_{KRIB}}$ a $A_{A_{RADIO}}$ dosahovala velmi blízké průměrné hodnoty ($\sim 4 \text{ kg}\cdot\text{m}^{-2}$), která byla asi o $1 \text{ kg}\cdot\text{m}^{-2}$ vyšší než průměrná hodnota vypočtená metodou $A_{C_{RADIO}}$ (Obr 19).



Obr 19: Zásoba uhlíku v horizontu A na jednotku plochy vypočtená jako zásoba celkového uhlíku (A_{total}) a zásoba recentního uhlíku (A_{CKrib} , A_{Aradio} , A_{Cradio}).


Celková průměrná zásoba uhlíku na m^2 byla u listnatých druhů vyšší ($8,5 \text{ kg}\cdot\text{m}^{-2}$) než u jehličnatých druhů ($7,4 \text{ kg}\cdot\text{m}^{-2}$), ale nebyl mezi nimi prokázán statisticky významný rozdíl. Nejvyšší průměrná hodnota zásoby celkového uhlíku byla zjištěna u třídy „a“ ($9,9 \text{ kg}\cdot\text{m}^{-2}$), která se významně lišila od třídy „s“ ($5,9 \text{ kg}\cdot\text{m}^{-2}$). Podobných hodnot celkové zásoby uhlíku v horizontu A dosahovaly třídy „l, t, pn, o, pc“; dále „a, q“; samostatně pak vystupovala třída „s“ (Obr 20).




Obr 20: ANOVA - celková zásoba uhlíku na jednotku plochy mezi pracovními třídami.

Pro přehled tříd viz Tab 2.

Zásoba recentního uhlíku vypočtená na základě celkového obsahu uhlíku (A_{A_RADIO}) v A horizontu jevila nejmenší variabilitu ze třech postupů výpočtu recentního uhlíku (Obr 19) a nebyl zjištěn statisticky významný rozdíl ani mezi listnatými a jehličnatými druhy ($p = 0,15$), ani pro jednotlivé třídy ($p = 0,06$). U zbývajících dvou postupů výpočtu recentního uhlíku (A_{C_RADIO} , A_{C_KRIB}) byl zjištěn statisticky významný rozdíl mezi listnatými a jehličnatými druhy a zároveň mezi třídami „pn“ a „a“ (ve všech případech $p < 0,01$), viz Obr 21, 22.




Obr 21: ANOVA - zásoba recentního uhlíku na jednotku plochy vypočtená metodou C_{RADIO} .
Pro přehled tříd viz Tab 2.



Obr 22: ANOVA - zásoba recentního uhlíku na jednotku plochy vypočtená metodou C_{KRIB} .
Pro přehled tříd viz Tab 2.

5.1.5 Vztah obsahu uhlíku v půdě a objemové hmotnosti na zkusných plochách

Na zkusných plochách byl pozorován statisticky významný vztah mezi relativním množstvím celkového uhlíku v horizontu A (%) a jeho objemovou hmotností (Obr 23). Přepočet uhlíku na uhlík recentní nevedl ke zúžení vztahu vůči objemové hmotnosti.




Obr 23: Lineární regrese mezi celkovým obsahem uhlíku a objemovou hmotností organominerálního horizontu A.

5.1.6 Vztah obsahu uhlíku v půdě a orografie na zkusných plochách

Vztah mezi svažitostí terénu odvozenou z dat ALS a zásobou uhlíku v půdě na zkusných plochách 2017 byl testován pomocí Pearsonova korelačního koeficientu. Statisticky významné hodnoty korelace ($\alpha = 0,05$) byly menší než nula a dosahovaly nízkých absolutních hodnot s výjimkou porostů lípy „t“ ($r = -0,87$; $p < 0,01$). V rámci jednotlivých tříd byla statisticky významná korelace zjištěna ještě u třídy „pn“ a „q“. Nízké absolutní hodnoty korelace byly zjištěny také pro skupinu listnatých druhů ($r = -0,34$; $p < 0,01$) a pro všechna pozorování bez rozlišení druhů ($r = -0,24$; $p < 0,01$). V případě všech pozorování byla statisticky významná korelace zjištěná jen pro celkovou zásobu uhlíku v horizontu A a pro zásobu recentního uhlíku vypočtenou na základě horizontu A pomocí analýzy ¹⁴C (A_{RADIO}).

5.2 Změna vegetačního pokryvu v oblasti výsypky

Pomocí rozhodovacího stromu byla pro jednotlivé termíny snímání (2009+2010 a 2017) získána klasifikace pokryvu (Obr 24). Následně byla překryvnou analýzou získána rozdílová vrstva obsahující informaci o změnách mezi jednotlivými třídami klasifikace. Grupováním byly získány vrstvy znázorňující 1/ intenzitu změny pokryvu (Obr 25), 2/ změny plochy dřevinného pokryvu (Obr 26).



Obr 24: Výřez klasifikace datové sady 2009+2010 do tříd pokryvu použitých pro výpočet změny využití.


Velikost zkoumané plochy pod maskou odvozenou z HS dat 2009 činila 790 ha. Největší podíl plochy zkoumané oblasti zaujímala v obou datových sadách/termínech třída bylinné vegetace (~50 %). Druhou nejvyšší pokryvnost měla třída vysoké dřeviny (25 a 32 %) a dále třída holé půdy (18 a 15 %) pro termíny 2009 a 2017. Zbylé dvě třídy „směsná vegetace“ a nízké dřeviny pokrývaly v obou termínech asi 4 % zkoumané plochy. V absolutních hodnotách došlo k největší změně pokryvu u třídy „vysoké dřeviny“, jejíž plocha se v porovnání s rokem 2009 zvětšila o 57 ha (30 % původní plochy). Na této změně se nejvíce podílely plochy, které byly pro rok 2009 klasifikovány jako bylinná vegetace a nízká dřevinná vegetace. Značná část plochy

(54 ha) původně klasifikované jako bylinná vegetace byla v termínu 2017 klasifikována jako holá půda. Změna plochy holé půdy byla druhá nejvyšší po vysoké dřevinné vegetaci 23 ha (16 % původní plochy). Z třídy holé půdy přešlo nejvíce plochy do třídy bylinné vegetace, v důsledku čehož ve zkoumaném území celkově ploch holé půdy ubylo (Tab 18).

Z Obr 25 je patrné, že v rozmezí let 2009 a 2017 došlo u většiny ploch vegetace ke kategorii změny „pozitivní ++“. Celková plocha této kategorie změny byla 142 ha, z čehož 71 ha připadá na změnu pokryvu z holé půdy na bylinnou vegetaci a zbytek na nárůst vegetace o více než jednu třídu.

Tab 18: Změna plochy tříd pokryvu (ha) mezi roky 2009 a 2017.

Třída 2017	Třída 2009					Celkem 2017
	holá půda	bylin	směs	nízká dř	vysoká dř	
holá půda	60,30	53,87	0,15	0,24	0,89	115,45
bylin	71,48	303,68	2,05	3,82	10,46	391,49
směs	0,63	4,10	0,09	0,19	0,28	5,30
nízká dř	2,18	19,27	0,76	1,18	1,86	25,24
vysoká dř	4,38	42,96	6,11	17,15	182,31	252,92
Celkem	138,97	423,88	9,16	22,59	195,81	790,41
Rozdíl 2017-2009	-23,52	-32,39	-3,86	2,65	57,12	



Obr 25: Intenzita změny pokryvu vegetace v rámci plochy dat 2009+2010.




Obr 26: Plošná distribuce změny dřevinného pokryvu v rámci plochy dat 2009+2010.

5.3 Výsledky objektově orientované klasifikace

Objektově orientovaná klasifikace byla provedena zvlášť na datových sadách 2009+2010 a 2017. Protože se většina druhů dřevin vyskytuje v plošně větších a druhově homogenních celcích, byla „multiresolution“ segmentace parametrizována tak, aby objekty byly co možná největší, ale aby nekřížily hranice jednotlivých porostních celků. Pro klasifikaci jednotlivých datových sad pak byly použité 2 různé algoritmy. Klasifikační algoritmy byly vybírány s ohledem na počet pozorování v danou chvíli použitelný pro trénování a validaci. Výsledné vrstvy klasifikace pak byly použity v dalších analýzách nadzemní biomasy a půdního uhlíku.

5.3.1 Klasifikace dat 2009+2010

Na datové sadě 2009+2010 byla OBIA klasifikace provedena na té části území výsypky, ve které se vyskytují plochy, na nichž probíhalo terénní šetření v roce 2006, a zároveň se v něm v daném termínu vyskytovala značná část dřevinné biomasy celkově nasnímaného území. Segmentace byla provedena ve dvou úrovních pomocí „multiresolution“ segmentace. Detailnější úroveň, kterou byly získány menší objekty pro parametrizaci klasifikátoru kNN, byla získána s parametry *scale* = 7; *shape* = 0,01; *compactness* = 0,99. Druhá vrstva segmentace na prostorově větší objekty, na které probíhala klasifikace a její validace, byla získána na základě parametrů *scale* = 15; *shape* = 0,01; *compactness* = 0,5. Objekty získané druhou segmentací i přes svou velikost respektují hranice porostních celků jednotlivých dřevin. Pomocí kNN algoritmu byla jednotlivým klasifikovaným objektům přiřazena třída příslušnosti k určitému druhu (Obr 27).



Obr 27: Objektově orientovaná klasifikace zájmových druhů dřevin z datové sady 2009+2010.

Pro přehled tříd viz Tab 2.


Pro hodnocení úspěšnosti byla na základě celkem 107 objektů identifikovaných pod původními plochami z roku 2006 vytvořena křížná matice (Tab 19). Klasifikace dosáhla průměrné „producer accuracy“ 79,5 % a průměrné „user accuracy“ 87,3 %. U listnatých druhů docházelo k chybám klasifikace nejčastěji u třídy olše „a“, která byla zaměňována s třídou ostatních dřevin. Z jehličnatých druhů byla nejčastěji špatně klasifikována třída smrk „pc“, která byla zaměňována za třídu borovice „pn“ nebo dubu „q“.

Tab 19: Relativní přesnost OBIA druhové klasifikace zájmových tříd datové sady 2009+2010.

	olše	modřín	smrk	borovice	dub	spontánní	lípa	user acc.
olše	97,09	9,91	0,83	0,00	0,00	0,00	0,00	96,37
modřín	0,00	90,09	0,00	4,82	0,00	0,08	0,00	97,04
smrk	0,00	0,00	18,96	0,00	0,00	0,00	0,00	100,00
borovice	0,00	0,00	40,22	95,18	0,00	6,20	0,00	65,59
dub	2,69	0,00	39,99	0,00	100,00	0,00	38,39	59,24
spontánní	0,00	0,00	0,00	0,00	0,00	93,72	0,00	100,00
lípa	0,22	0,00	0,00	0,00	0,00	0,00	61,61	93,00
producer acc.	97,09	90,09	18,96	95,18	100,00	93,72	61,61	

5.3.2 Klasifikace dat 2017

Plošný rozsah datové sady 2017 umožnil provedení objektově orientovanou klasifikace druhů na celém území výsypky (Příloha 1). Jelikož prostorové rozlišení vstupních dat a velikost objektů (monokulturních ploch) ve scéně byly velmi podobné datové sadě 2009+2010 (Tab 3), byla „multiresolution“ segmentace provedena s totožnými parametry jako první úroveň segmentace předchozí datové sady: $scale = 7$; $shape = 0,01$; $compactness = 0,99$. Z této segmentace bylo pro trénování klasifikátoru identifikováno 889 objektů, které byly použity pro trénování klasifikátoru SVM. Na základě trénovacích objektů byly zjištěny optimální parametry SVM klasifikátoru: $kernel$ – radial basis function; $C = 10$; $gamma = 0,005$. S těmito parametry bylo na trénovacím souboru dosaženo celkové shody 79,5 %. Tento model byl pak aplikován na vyexportované segmenty a výsledky klasifikace (Obr 28) byly validovány oproti nezávislému vzorku objektů ($n = 257$) identifikovaných pod zkusnými plochami 2006 (Tab 20).



Obr 28: Objektově orientovaná klasifikace druhů z datové sady 2017; zde území rozsahem odpovídající klasifikaci datové sady 2009+2010.

Pro přehled tříd viz Tab 2.

Nezávislou validací byla zjištěna průměrná „producer accuracy“ 73,6 % a průměrná „user accuracy“ 72 %. K největšímu podílu chybné klasifikace docházelo u třídy spontánní sukcese „s“, která byla nejvíce zaměňována za třídu lípa „t“. K významnější chybovosti docházelo i u třídy olše „a“ a dub „q“, které byly nejčastěji chybně klasifikovány jako třída smrk „pc“ (Tab 20).

Tab 20: Relativní přesnost OBIA druhové klasifikace datové sady 2017.


	olše	modřín	smrk	borovice	dub	spontánní	lípa	user acc.
olše	64,90	0,00	18,42	0,00	8,23	7,64	8,57	56,97
modřín	0,03	97,04	8,27	0,00	0,00	3,93	0,17	86,80
smrk	6,90	0,00	40,33	3,68	0,00	5,59	3,10	74,77
borovice	4,51	0,00	9,79	85,87	0,00	12,80	0,58	70,85
dub	0,00	0,00	18,14	0,00	91,77	0,00	0,00	72,87
spontánní	12,83	0,00	5,06	10,45	0,00	70,04	22,25	66,53
lípa	10,83	2,96	0,00	0,00	0,00	0,00	65,33	75,30
producer acc.	64,90	97,04	40,33	85,87	91,77	70,04	65,33	

5.4 Odhad množství uhlíku nadzemní biomasy dřevin

Prostorový odhad množství uhlíku obsaženém v nadzemní biomase dřevin byl proveden pro obě datové sady. Vzhledem k charakteristice dat ALS (Tab 4) byl odhad pro datovou sadu 2009+2010 proveden plošným přístupem na úrovni pixelů a pro datovou sadu 2017 byl využit přístup založený na identifikaci jednotlivých stromů.


5.4.1 Množství uhlíku odhadnuté z dat 2009

Korelační analýza byla provedena zvlášť pro listnaté dřeviny, jehličnaté dřeviny a pro sloučenou datovou sadu bez rozlišení druhů. V případě sloučené sady byly pozorovány nižší hodnoty korelace než pro jednotlivé skupiny. Ve sloučené datové sadě byla pro množství uhlíku v nadzemní biomase zjištěna nejvyšší statisticky významná korelace vůči 85% výškovému kvantilu porostů ($r = 0,63$; $p < 0,01$). Mezi další vysvětlující proměnné, pro které byla zjištěna statisticky významná závislost, patří: průměrná výška vegetace, směrodatná odchylka výšky vegetace a 25–95% výškové kvantily. Pro samostatnou skupinu jehličnatých stromů byla zjištěna nejvyšší korelace mezi uhlíkem nadzemní biomasy a 75, resp. 85% výškovým kvantilem (každý $r = 0,9$; $p < 0,01$). Pro jehličnaté dřeviny byl sestaven lineární regresní model mezi množstvím uhlíku nadzemní biomasy a 85% výškovým kvantilem (Obr 29).



Obr 29: Verifikace modelu pro odhad množství uhlíku v nadzemní biomase. C_AGB_{OBS} množství uhlíku odhadnuté na základě terénních měření; C_AGB_{PRED} množství uhlíku predikované z dat DPZ. *l* – *Larix decidua*, *pc* – *Picea* sp., *pn* – *Pinus* sp.

Nejvyšší hodnoty korelace ve vztahu množství uhlíku v nadzemní biomase ve skupině listnatých stromů vykazovaly průměrné hodnoty a směrodatné odchylky reflektance v pásmech blízkého infračerveného záření. Jako proměnná s nejvyšší hodnotou korelace byla v případě listnatých stromů označena směrodatná odchylka reflektance v 707 nm ($r = -0,6$; $p < 0,01$), další statisticky významné hodnoty korelace byly zjištěny u průměrné hodnoty reflektance v rozsahu vlnových délek 840–950 nm ($r = 0,6$; $p < 0,01$). Pomocí těchto dvou proměnných lze odvodit statisticky významný model predikce množství uhlíku nadzemní biomasy ($R^2 = 0,56$; $p < 0,01$). Vzhledem k tomu, že reflektance představuje nepřímý ukazatel nadzemní biomasy, je interpretace tohoto vztahu obtížná, a proto byl pro predikci množství nadzemní biomasy použit lineární model založený na všech pozorováních a používající 85% výškový kvantil jako nezávislou proměnnou (Obr 30).



Obr 30: Pozorované ($C_{AGB_{OBS}}$) a predikované ($C_{AGB_{PRED}}$) hodnoty množství uhlíku nadzemní biomasy bez rozlišení druhu.

5.4.2 Množství uhlíku odhadnuté z dat 2017

Odvození množství uhlíku nadzemní biomasy pro termín 2017 bylo založeno na analýze dat DPZ. Prvním krokem byla algoritmická identifikace jednotlivých stromů z dat ALS, na kterou navazoval odhad množství nadzemní biomasy a vázaného uhlíku prostřednictvím druhově specifických alometrických rovnic.

5.4.2.1 Identifikace stromů z dat ALS

Druhově specifická parametrizace algoritmu identifikace byla provedena pod maskou druhové klasifikace 2017. Použitý algoritmus vyžaduje pro jeden z kroků identifikace jednotlivých stromů hodnotu výčetní tloušťky (DBH). Jelikož tuto hodnotu není možné z dat ALS získat přímo, byly z dat pozemního šetření sestaveny druhově specifické modely pro odhad DBH na základě výšky stromů. Pro všechny sledované třídy byla zjištěna statisticky významná korelace ($\alpha = 0,05$) mezi výškou stromů a DBH s průměrnou hodnotou 0,82. Následně byly pro jednotlivé druhy sestaveny lineární modely mezi výškou a DBH (Tab 21).

Tab 21: Druhově specifické koeficienty lineárního modelu ($y = ax + b$) pro výpočet DBH na základě výšky, odvozené na základě terénních měření.

	a	l	o	pc	pn	q	s	t
a	1,0257	1,1331	1,0634	1,7793	1,0986	1,5364	1,1750	1,2508
b	0,4460	-1,4333	-1,4030	-4,1827	1,8949	-1,0919	0,1736	-3,7182
R ²	0,70	0,86	0,62	0,81	0,48	0,67	0,69	0,60

Pro přehled tříd viz Tab 2.


Na základě rastrové vrstvy výšky vegetace (CHM) byly algoritmicky identifikovány jednotlivé stromy, přičemž pro parametrizaci algoritmu byly využity druhově specifické alometrické rovnice pro výpočet průměru koruny (Tab 11). Počet algoritmicky identifikovaných stromů byl v průměru asi o 7 % nadhodnocený oproti počtu identifikovanému vizuálně. Největší rozdíl mezi počtem vizuálně identifikovaných a počtem algoritmicky identifikovaných stromů dosahovaly třídy dub „q“ a spontánní sukcese „s“ (Tab 22). Jelikož byl počet stromů zjišťován na plochách, kde probíhalo vzorkování v roce 2006, bylo možné provést srovnání i vůči tomuto stavu. V průměru došlo k poklesu počtu stromů asi 2,3 krát. Výjimku tvořily porosty spontánní sukcese, na kterých naopak došlo ke zvýšení počtu stromů asi o 10 %.

Tab 22: Srovnání počtu vizuálně a algoritmicky identifikovaných stromů ($ks \cdot ha^{-1}$) na plochách odběrů 2006.

třída	vizuální identifikace		algoritmická identifikace	
	průměr	std	průměr	std
a	1237,6	101,3	1348,1	263,6
l	779,0	182,6	773,5	184,9
pc	1044,2	252,9	988,9	288,9
pn	1502,8	651,4	1602,3	376,9
q	889,5	85,4	1071,9	89,3
s	955,8	326,5	1155,4	432,5
t	1453,1	231,3	1480,7	303,6

Pro přehled tříd viz Tab 2.

Druhou proměnnou, která je při odhadu množství biomasy prostřednictvím dat ALS klíčovou, je výška vegetace. Srovnání výšky automaticky identifikovaných stromů bylo provedeno na základě výšek změřených v terénu v roce 2017. Pro srovnání byla použita hodnota Pearsonova korelačního koeficientu. Mezi výškou změřenou v terénu a výškou získanou pomocí dat ALS byla zjištěna statisticky významná korelace ($r = 0,91$; $p < 0,01$). Výška vegetace zjištěná z dat ALS byla oproti výšce stromů změřené v terénu nadhodnocována v průměru asi o 1,3 m (Obr 31).




Obr 31: Srovnání středních hodnot výšky stromů změřených na zkušných plochách 2017 v terénu a identifikovaných algoritmicky.


5.4.2.2 Odhad množství uhlíku nadzemní biomasy

Odhad množství uhlíku nadzemní biomasy pro termín 2017 byl proveden na základě jednotlivých identifikovaných stromů, které nesly informaci o druhu, výšce a výčetní tloušťce. Z těchto informací byla pro každý identifikovaný strom vypočtena hodnota množství uhlíku obsaženého v nadzemní biomase (Obr 32).

Distribuci množství uhlíku nadzemní biomasy alokované do jednotlivých stromů pod pracovními třídami znázorňuje Obr 33. Pod třídami „pc, q, t“ byly zastoupeny i větší stromy obsahující větší množství uhlíku. Ve zbývajících třídách byly zastoupeny především menší stromy.




Obr 32: Množství nadzemní biomasy jednotlivých stromů identifikovaných z dat DPZ.



Obr 33: Množství uhlíku v nadzemní biomase jednotlivých stromů identifikovaných v datech laserového skenování 2017. | stř. hodnota - median, box - IQR, dolní whisk. - minimum nebo $Q1 - 1,5IQR$; horní whisk. - maximum nebo $Q3 + 1,5IQR$
Pro přehled tříd viz Tab 2.


U zkusných ploch 2017 byla pozorována statisticky významná korelace ($r = 0,53$, $p < 0,01$) mezi věkem porostu a množstvím uhlíku v nadzemní biomase stromů. Statisticky významné hodnoty korelace ($\alpha = 0,05$) byly pozorovány i u samostatných kategorií listnatých a jehličnatých druhů (Obr 34).



Obr 34: Regresní vztah věku porostů a množství uhlíku v nadzemní biomase. Odvozeno na základě dat 2017.

5.4.3 Celková zásoba uhlíku nadzemní biomasy


Celková zásoba uhlíku ve sledovaném území, pod maskou HS dat nasnímaných v roce 2009, byla vypočtena na základě map prostorové distribuce nadzemní biomasy (Přílohy 2 a 3) a map klasifikace druhů (kap. 5.3). Pod plochami, které byly shodně klasifikovány v obou termínech, bylo pro jednotlivé třídy vypočteno množství uhlíku nadzemní biomasy vztažené na jednotku plochy (Obr 35). Nejvyšší koncentrace biomasy byla v obou termínech pozorována v případě třídy lípa „t“. Největší změnu koncentrace uhlíku v nadzemní biomase dosáhla třída smrk „pc“.



Obr 35: Množství biomasy na jednotku plochy vypočtené na základě plochy zájmového území.

Pro přehled tříd viz Tab 2.

Celková zásoba uhlíku nadzemní biomasy byla vypočtena pod maskou HS dat 2009. Suma uhlíku byla spočtena samostatně pro termíny: 1/ 2006; 2/ 2017 pod plochou dřevin 2009; 3/ 2017 mimo plochu dřevin 2009 (Obr 36). Celková zásoba uhlíku v nadzemní biomase ve sledovaném území tvořila v roce 2006 4,5 tis. tun, s největším podílem porostů olše 30 %. V roce 2017 bylo celkové množství uhlíku 7,6 tis. tun, s největším podílem porostů smrku a olše.




Obr 36: Celkové množství uhlíku nadzemní biomasy v zájmovém území.

Pro přehled tříd viz Tab 2.

5.5 Zásoba půdního uhlíku

5.5.1 Analýza dat 2009+2010

Korelační analýza mezi množstvím půdního uhlíku a charakteristikami odvozenými z dat DPZ (Tab 10) byla provedena zvlášť pro skupiny jehličnatých, listnatých dřevin a pro směsný vzorek bez rozlišení druhů. Hodnoty korelace pro půdní uhlík dosahovaly nižších hodnot než pro uhlík nadzemní biomasy. Pro organominerální A horizont bez rozlišení druhů byla nejvyšší korelace zjištěna u průměrné hodnoty reflektance v 820 nm ($r = 0,55$; $p < 0,01$) a zároveň i další stat. významné proměnné pocházely z reflektančních dat. Pro skupinu jehličnatých stromů naopak převládaly proměnné odvozené z LiDARových dat. Nejvyšších hodnot dosahovaly 50–95% výškové percentily ($r = 0,77$; $p < 0,01$), následované průměrnou výškou vegetace. Na Obr 37 je prezentován lineární model mezi množstvím půdního uhlíku v A horizontu a 75% výškovým kvantilem pro kategorii jehličnatých dřevin.



Obr 37: Verifikace modelu pro odhad množství uhlíku ($t \cdot ha^{-1}$) v organominerálním (A) horizontu. $C_{ORG_{OBS}}$ množství půdního uhlíku stanovené na základě terénních měření; $C_{ORG_{PRED}}$ množství půdního uhlíku predikované z dat DPZ. l – *Larix decidua*, pc – *Picea sp.*, pn – *Pinus sp.*


5.5.2 Vztah obsahu uhlíku v půdě a nadzemní biomasy na zkušných plochách

Pomocí Pearsonova korelačního koeficientu bylo testováno, zda existuje statisticky významná vazba mezi množstvím nadzemní biomasy a zásobou uhlíku v půdě zjištěnou na zkušných plochách. Analýzou byla zjištěna slabá stat. významná korelace u skupiny jehličnatých dřevin ($r = 0,28$). U třídy „s“ - spontánní sukcese byly zjištěny střední hodnoty korelace nadzemní biomasy vůči zásobě recentního uhlíku v půdě vypočteného pomocí normalizace C horizontem ($r = 0,65$). Mírně vyšší hodnoty korelace vůči nadzemní biomase byly u třídy „s“ sledovány u celkové zásoby uhlíku v A horizontu a z něj přímo odvozeného množství uhlíku recentního ($r = 0,73$).


Proti množství uhlíku nadzemní biomasy byl otestován i obsah uhlíku v půdě (%). Pro jehličnaté druhy byla pozorována silnější korelace s obsahem půdního uhlíku než s jeho zásobou, a pro listnaté druhy bylo pozorováno opačné chování, tj. nízká hodnota korelace s obsahem a silnější se zásobou půdního uhlíku.

5.5.3 Prostorová distribuce půdního uhlíku 2017

Hodnoty obsahu/zásoby půdního organického uhlíku byly testovány proti faktorům prostředí a množství uhlíku nadzemní biomasy. Analýzou vztahu zásoby uhlíku a faktorů prostředí nebyl zjištěn silný vztah, který by umožňoval predikovat zásobu uhlíku v půdě pro všechny druhy dřevin. Prostorová distribuce obsahu/zásoby půdního uhlíku byla získána pomocí prostorové interpolace metodou „Radial Basis Function“. Parametrizace pro interpolaci jednotlivých atributů hodnoty obsahu/zásoby uhlíku probíhala na základě 60 trénovacích a 58 validačních bodů (Obr 38, 39). S ohledem na charakter území (prázdný klín uprostřed území) a vzdálenosti vzorkování dvou nejbližších míst odběrů (13–250 m) se volba hlavních a vedlejších poloos pohybovala v rozmezí 300–450 m, minimální počet bodů 5, maximální 10, kernel parametr 0,167 až 13,3.



Obr 38: Validace RBF interpolace obsahu uhlíku v horizontech A a C.




Obr 39: Validace RBF interpolace zásoby uhlíku v horizontu A.

Pomocí interpolace byly v zájmovém území pod maskou dat 2009 získány mapy relativního množství uhlíku (%) pro horizonty A a C; zásoba celkového uhlíku ($\text{kg} \cdot \text{m}^{-2}$) v horizontu A; zásoba recentního uhlíku v horizontu A vypočtená 3 přístupy A_C_{RADIO}, A_C_{KRIB}, A_A_{RADIO} (Příloha 4–9).

V obou mapách relativního množství uhlíku je možné sledovat nižší až střední, prostorově vyrovnané hodnoty v severní části zájmového území, kterému dominují nejstarší porosty s převahou lípy, jasanu a v severovýchodní části pak i olše. V jihozápadní části území lze v obou horizontech pozorovat vysoký relativní obsah uhlíku. V centrální části zájmového území je patrná disproporce relativního obsahu uhlíku v horizontu A vůči okolí, která se ale výrazně neprojevuje v horizontu C.

Ve všech mapách zásoby půdního uhlíku lze pozorovat oblast výrazně vyšší zásoby půdního uhlíku oproti zbytku zájmového území, dominantním druhem dub. Dále lze ve všech mapách zásoby uhlíku pozorovat nízké hodnoty v jihozápadní části zájmové oblasti, kde dominují spíše mladší porosty (cca 20 let) spontánní sukcese, modřínů a smrku. Další oblast nízké zásoby recentního uhlíku, v centrální části, lze pozorovat na mapách, pro které do výpočtu vstupoval horizont C.

Překryvnou analýzou vrstev zásoby půdního uhlíku a vrstvy klasifikace tříd druhů byla pro jednotlivé třídy vypočtena průměrná hodnota celkové zásoby půdního uhlíku v horizontu A, a průměrná hodnota zásoby recentního uhlíku na základě třech aplikovaných metod (Obr 40).



Obr 40: Zásoba uhlíku pod jednotlivými třídami druhů vypočtená na základě statistiky celého zájmového území.

Pro přehled tříd viz Tab 2.

6 Diskuse

6.1 Změna pokryvu

Vegetační pokryv pozitivně působí na vznik organominerálního horizontu, teplotní a vodní režim stanoviště, snižuje náchylnost povrchu k erozi, a také představuje zdroj potravy a úkryt pro zvěř (Frouz et al. 2009; Brom a Pokorný 2009; Moreno-de las Heras 2009; Olsoy et al. 2015). Na základě analýzy časové řady satelitních snímků Landsat popsali Brom et al. (2012) v oblasti Velké podkrušnohorské výsypky časoprostorový vývoj množství vegetace na základě hodnoty vegetačního indexu NDVI. Z analýzy je patrné, že k výraznému zvyšování plochy vegetace dochází zhruba od roku 2000. Výsledky analýzy změny pokryvu v této práci přidávají k výše zmiňované časové řadě další termín – 2017. Zároveň rozšiřují analýzu o vyšší prostorové rozlišení a rozlišení bylinné a dřevinné vegetace. Využitím dat DPZ v oblastech po těžbě uhlí se zabýval Antwi et al. (2008), který popsal pomocí dat Landsat změny v diverzitě a fragmentaci krajiny důlních výsypek. V oblasti Sokolova popsal osidlování ploch různými druhy na základě mikro-orografie zkusných ploch (Frouz et al. 2015; 2018). Při kolonizaci území dřevinnou vegetací se často tvoří nejprve skupinky jednotlivých stromů, které se postupně zahušťují a rozšiřují. Identifikace těchto raných stádií je v případě satelitních dat Landsat těžko proveditelná. Postupem prezentovaným v této studii by bylo možná navázat na časovou řadu, kterou analyzovali Brom et al. (2012). Prezentovaný postup není závislý na využití hyperspektrálních dat a bylo by jej možné provést i na základě multispektrálních dat pořízených leteckými senzory, nebo i satelitních dat s velmi vysokým prostorovým rozlišením. Podobné postupy využívající data DPZ již byly

aplikovány při studiu degradace lučních porostů (McGlynn a Okin 2006; Cao et al. 2018).

6.2 Klasifikace tříd druhů

Dosažená přesnost klasifikací je v porovnání s jinými studii nižší. Dalponte et al. (2014) dosáhli při klasifikaci jednotlivých stromů celkové přesnosti kolem 85 %, i další studie uvádějí přesnost mezi 80 – 90 % (Stoffels et al. 2015; Sheeren et al. 2016). Naopak Voss a Sugumaran (2008) pozorovali při použití objektově orientovaného přístupu nižší hodnoty celkové přesnosti. Pro účely mapování pokryvu by celková přesnost měla dosahovat min. 80 procent (Thomlinson et al. 1999).

Objektově orientovaná klasifikace byla aplikována v území s porosty tvořenými převážně monokulturami dřevin. Zvolené parametry segmentace probíhající v rámci OBIA produkovaly objekty, které byly svou plochou větší než je plocha jednotlivých korun. Aplikace objektově orientované analýzy obrazu pro klasifikaci druhů na úrovni porostních celků je uváděna jako vhodný přístup (Fassnacht et al. 2016). Při klasifikaci větších územních celků je ovšem třeba věnovat pozornost variabilitě signálu objektů jednoho druhu, protože může docházet k jejímu nárůstu např. vlivem rozdílného korunového zápoje.

Pro klasifikaci jednotlivých datových sad byly použity dva různé algoritmy. Datová sada 2009+2010, pro kterou byl nižší počet pozorování, byla klasifikována pomocí algoritmu „nearest neighbor“ (kNN). Druhá datová sada 2017 byla klasifikována pomocí algoritmu „support vector machine“ (SVM). Dalponte et al. (2008) pozorovali při analýze kombinovaných HS a LiDAR dat výrazně vyšší úspěšnost klasifikátoru SVM oproti kNN, přičemž jako možnou příčinu uvádějí mnohorozměrnost vstupní datové sady způsobenou především použitím hyperspektrálních dat v podobě reflektance. Jedním z možných důvodů pozorované přesnosti kNN klasifikátoru v této práci může být použití dat po MNF transformaci, která mají méně dimenzí. Dalponte et al. (2009) dále uvádějí, že při vyšším spektrálním rozlišení dosahuje SVM oproti jiným klasifikačním algoritmům lepších výsledků v úlohách klasifikace lesních porostů. Přesnost klasifikace druhů dřevin v závislosti na způsobu redukce mnohorozměrného prostoru hodnotil Fassnacht et al. (2014a), kteří zjistili, že stabilně nejlepších výsledků bylo dosaženo kombinací MNF transformace a SVM klasifikátoru při použití 10–20 MNF komponent.

Do klasifikace obou vrstev vstupovala vrstva CHM odvozená z ALS dat. Pro klasifikaci první datové sady byla z vrstvy CHM odvozena maska, pod kterou probíhaly další kroky objektově orientované analýzy. V případě analýzy druhé datové sady byly kromě masky odvozeny i vrstvy znázorňující vertikální distribuci výšky vegetace, které vstupovaly do vlastní klasifikace. Voss a Sugumaran (2008) uvádějí, že kombinací

pasivních optických dat a vrstvy výšky vegetace došlo ke zlepšení přesnosti klasifikace z důvodů zlepšení separability tříd s podobným spektrálním projevem, ale různou výškou. Fassnacht et al. (2016) naopak uvádějí výšku vegetace jako proměnnou, která při klasifikaci většího území, na kterém se vyskytují různé věkové kategorie, nemusí mít na odlišitelnost tříd vliv.

Klasifikace byla provedena na dvou datových sadách nasnímaných v rozdílné části vegetačního období. V případě listnatých druhů bylo mírně větší přesnosti dosaženo u klasifikace datové sady 2009+2010, která byla snímána v období plně vyvinutého listoví. Nižší přesnost klasifikace listnatých druhů v případě datové sady 2017 (snímání 15. 5.) může být z části dána do souvislosti s fenologií jednotlivých druhů, kdy některé druhy v době snímání nebyly plně olistěné. V podmínkách, kdy některé druhy už nejsou nebo naopak ještě nejsou olistěné, narůstá vliv pozadí (půdy nebo podrostu) a klesá tak separabilita studovaných tříd (Sheeren et al. 2016). I když fenologie druhů je někdy zmiňována jako vhodný prostředek k jejich odlišení, jiné studie naopak uvádějí srovnatelnou přesnost klasifikace dosaženou z různých termínů snímání (Voss a Sugumaran 2008). Postup využívající fenologii ovšem vyžaduje získání zdrojových dat ve specifických časových obdobích, což v případě pasivních optických dat může být komplikováno výskytem oblačnosti. Praktické uplatnění fenologie v klasifikaci lze pozorovat například v případě klasifikace plodin v zemědělství. Z důvodu potlačení vlivu oblačnosti a vysokého časového rozlišení jsou pro tento účel využívána satelitní radarová data (Sonobe et al. 2014; Bargiel 2017), a analýza je prováděna na úrovni časových řad.

Pro zvýšení přesnosti klasifikace by bylo možné otestovat postup, kdy by segmentací byly získány prostorově menší objekty (zhruba velikosti korun). Na těchto teoreticky spektrálně čistších objektech by byla provedena klasifikace a větším objektům by po překryvu byla přiřazena třída na základě nejčastější třídy nebo třída zaujímající největší plochu v rámci většího objektu.

6.3 Uhlík nadzemní biomasy

Identifikace stromů

Metody automatické identifikace stromů na základě DPZ dat mají tendenci identifikovat méně stromů, než je zjištěno terénním šetřením. Počet automaticky identifikovaných stromů se nejčastěji pohybuje mezi 40 a 90 % skutečného počtu (Dalponte et al. 2014; Kwak et al. 2007). Jako důvod je nejčastěji zmiňována víceúrovňovost porostů, jelikož většina neidentifikovaných stromů je tvořena stromy podúrovňovými (Hamraz et al. 2017).

Pozorovaný nadhodnocený počet listnatých stromů může být způsoben tvarem koruny, která je v případě vysazených monokultur plošší. Zároveň fakt, že porosty jsou většinou jednoúrovňové, pravděpodobně způsobil, že nebylo pozorováno výrazné podhodnocování počtu stromů. Dalším faktorem je chybovost vizuální interpretace obrazu, vůči které bylo srovnání provedeno.

Výška porostů

van Leeuwen a Nieuwenhuis (2010) udávají, že chyba odhadu výšky vegetace z dat ALS se pohybuje do 1,5 m, přičemž vztah s měřenými hodnotami je většinou těsný $R^2 > 0,8$. Studie zároveň poukazují, že odhadnutá výška je spíše podhodnocená, než nadhodnocená. Průměrný rozdíl skutečné a odhadované výšky i hodnota koeficientu determinace v této práci jsou blízko této hranici. Naproti výše zmiňované tendenci k podhodnocování Gatziolis et al. (2010) pozoroval výrazné nadhodnocování výšky vegetace (i více než 10 % výšky) pro více než 50 % pozorovaných stromů nezávisle na druhovém složení. Mírné nadhodnocování výšky odhadnuté z dat ALS oproti nepřímému, terénnímu měření pozorovali i Sibona et al. (2016), zatímco ve srovnání s přímým měřením výšky stromů byly pozorované rozdíly jen minimální nebo záporné.

Chyba odhadu výšky je nejčastěji dávana do souvislosti s: a) frekvencí skenování, b) interakcí pulzu s vrcholem koruny, c) přesností klasifikace bodů terénu.

a) Vliv frekvence skenování/hustoty pulzů je dán čistě pravděpodobností zasažení vrcholu koruny.

b) Od interakce pulzu s korunou a použité metody dekompozice signálu se odvíjí výsledná pozice identifikovaného odrazu. Nárůst intenzity signálu, který je určujícím faktorem při dekompozici, je závislý na tvaru a hustotě koruny. Odlišnou interakci lze tedy očekávat zejména u opadavých druhů (Awaya a Takahashi 2017).

c) Digitální model terénu se používá pro normalizaci výšky bodů odražených od vegetace. Vliv přesnosti jeho určení může vést k podhodnocování výšky až o 20 %. Největší vliv přesnost DTM má hustota korunového zápoje, výskyt podrostu a svažitost terénu (Gatziolis et al. 2010; Reutebuch et al. 2003; Meng et al. 2010).

Studované porosty lze z hlediska potencionálních zdrojů chyby v odhadu výšky charakterizovat nízkou svažitostí. Vyšší hodnoty svažitosti byly zjištěny pouze u třídy „s“ v důsledku terénních vln. Hlavním faktorem, který může způsobovat pozorované nadhodnocování oproti provedeným pozemním nepřímým měřením, může být nepřesné zaměření vrcholu koruny, ke kterému mohlo docházet zejména při měření výšky stejnověkých porostů opadavých druhů.

Uhlík nadzemní biomasy

Zjištěné hodnoty množství uhlíku v nadzemní biomase 20–100 t·ha⁻¹ jsou srovnatelné s těmi, které pro srovnatelné věkové stupně popsal (Cienciala et al. 2011). Hodnoty zásoby 100 t·ha⁻¹ pro smrkové porosty ve věku 15–20 let popsal na rekultivovaných plochách také (Shrestha a Lal 2010).

Pro odhad množství nadzemní biomasy plošným přístupem byla v literatuře popsána řada charakteristik odvoditelných z ALS dat na úrovni pixelu, které popisují 30–90 % variability. Výškové percentily samostatně použité pro plošný způsob odhadu množství nadzemní biomasy vysvětlují ve většině případů 75–90 % variability (Man et al. 2014; Sheridan et al. 2014; Bouvier et al. 2015), čemuž odpovídají i výsledky této práce pozorované u datové sady 2009+2010. Rovněž byla pozorována i nižší predikční schopnost výškových percentilů v případě listnatých druhů dřevin (Kandare et al. 2017). Podobně jako v případě klasifikací byl i pro odhad množství nadzemní biomasy pozorován pozitivní efekt kombinace spektrálních a ALS dat, který byl větší u přirozených lesních porostů oproti porostům obhospodařovaným (Luo et al. 2017). Naproti tomu jiné studie popisují jen minimální efekt kombinace dat ALS s HS daty (Fassnacht et al. 2014b).

Využití metod, které odhadují biomasu jednotlivých stromů, je na doplňkových obrazových nebo hyperspektrálních datech závislé více než plošné přístupy. Pro odhad biomasy a v některých případech už pro fázi identifikaci stromů je vhodné znát druhové složení. Chyba v odhadu množství nadzemní biomasy na úrovni jednotlivých stromů je nižší v případě použití druhově specifických alometrických rovnic, a to i v případě vysoké chybovosti klasifikace až 50 % (Tompalski et al. 2014).

Oba zde použité postupy mohou za určitých podmínek poskytovat kvalitní odhad množství nadzemní biomasy (Yu et al. 2010; Coomes et al. 2017). Postup je potřeba volit zejména na základě kombinace charakteru porostu (hustota, výskyt podrostu) a charakteristikách dostupných dat DPZ, které se na výsledném odhadu podílejí nejvíce (Fassnacht et al. 2014b).

Zde použitý postup pro odhad množství uhlíku nadzemní biomasy, založený na identifikaci jednotlivých stromů, poskytl v průměru hodnověrné výsledky. Pro jeho uplatnění by však bylo potřeba provést validaci výsledků (počtu identifikovaných stromů, množství nadzemní biomasy) na plochách standardně provedeného inventarizačního šetření.

6.4 Půdní uhlík

Z výsledků opakovaného vzorkování v roce 2015 na plochách, na kterých probíhalo vzorkování i v roce 2006, je patrný nárůst zásoby uhlíku v organominerálním horizontu. U vzorků 2017 jsou průměrné hodnoty obsahu organického uhlíku v horizontu A nižší oproti vzorkům 2006. Při srovnání těchto dvou vzorkování je nutné přihlédnout k faktu, že vzorkování neprobíhalo na stejných zkusných plochách. Vzorkování 2017 bylo dále tvořeno větším počtem vzorků a bylo navrhováno tak, aby zahrnovalo větší rozsah výšek porostu a tudíž i věkových kategorií. I když jsou hodnoty obsahu uhlíku ve vzorcích 2017 v průměru nižší, jejich rozsah odpovídá rozsahům, které jsou pro tuto lokalitu uváděny i jinými autory (Frouz et al. 2009; Bujalský et al. 2014; Frouz 2017).

Mezi jednotlivými třídami nebyl pozorován rozdíl v obsahu uhlíku (%) v horizontu A. Sekvestrace uhlíku v půdě rekultivovaných výsypek je značně dynamický proces. Na rekultivovaných výsypkách byla popsána nelineární závislost rychlosti akumulace půdního uhlíku na věku porostů (Shrestha a Lal 2010; Zhou et al. 2017). K maximu akumulace půdního uhlíku v listnatých porostech dochází ve věku asi 10, v případě jehličnatých pak asi 35 let (Vindušková a Frouz 2013). Přibližně ve stejném věku, tj. asi 20 let dosahují hodnoty obsahu uhlíku na rekultivovaných plochách hodnot pozorovaných před těžbou (Zhou et al. 2017). Rovněž podíl C/N se v tomto věku přibližuje hodnotám zjištěným v půdách nezasažených těžbou (Kříbek a Macurová 1996). Rychlost akumulace půdního uhlíku se po dosažení maxima snižuje, nebo může dosáhnout i mírně záporných hodnot (Frouz 2017). Vzhledem k věku sledovaných porostů, který se v průměru pohyboval od 20 do 30 let pro jehličnaté a listnaté druhy, může již u některých porostů docházet ke zpomalování akumulace uhlíku, v důsledku čehož se obsah uhlíku na jednotlivých plochách v horizontu A začíná vyrovnávat.

Statisticky významné rozdíly obsahu uhlíku v horizontu C prokázaly výrazně nižší hodnoty pro třídy „t“ a „o“. Vzhledem k prostorové blízkosti těchto ploch lze očekávat, že důvodem může být podobné složení původního jílovcového materiálu, a že zároveň pod oběma třídami dochází v důsledku podobných orografických charakteristik v hlubším horizontu k podobným dějům.

Pro výpočet zásoby uhlíku ($\text{kg} \cdot \text{m}^{-2}$) v horizontu A byly měřeny hodnoty objemové hmotnosti a hloubky půdního horizontu. Tyto charakteristiky bývají spolu s procesem separace částic organické hmoty při přípravě vzorků k analýze označovány za hlavní zdroje nejistoty při vzorkování půd za účelem stanovení zásoby organického uhlíku (Vanguelova et al. 2016). Odběr vzorků z horizontu A probíhal pomocí Kopeckého válečku, což by měl být postup, který má menší vliv na výsledné hodnoty objemové hmotnosti. Zjištěné hodnoty objemové hmotnosti u vzorků 2015 a 2017 byly výrazně vyšší oproti hodnotám zjištěným v roce 2006. V porovnání s dalšími, časově bližšími

studiemi prováděnými v dané oblasti (Kuráž et al. 2012; Frouz et al. 2018) byly hodnoty objemové hmotnosti srovnatelné. Rovněž rozdíly v objemové hmotnosti sukcesních a rekultivovaných ploch jsou srovnatelné (Frouz et al. 2018). Ve srovnání s objemovou hmotností lesních půd $400\text{--}1700\text{ kg}\cdot\text{m}^{-3}$, kterou udávají De Vos et al. (2015), jsou pozorované hodnoty objemové hmotnosti blíže spíše horní hranici, což pravděpodobně souvisí s vysokým obsahem jílových částic ve zkoumané lokalitě.

U všech tříd byla pozorována vysoká variabilita hloubky půdního horizontu A, přičemž u listnatých druhů (var. koef. 0,53) byla pozorována větší variabilita než u druhů jehličnatých (var. koef. 0,35). Vyšší variabilita listnatých druhů může být dána chemických složením opadu, případně reakcí půdního edafonu na další faktory prostředí (Frouz et al. 2013). Měření hloubky horizontu A je značně subjektivní proces, zejména v případě využití sondýrky, kdy nelze vizuálně sledovat profil hloubky horizontu a určit tak jeho hranici. Přitom chyba 1 cm v hloubce A horizontu odpovídá v lesních půdách rozdílu v zásobě uhlíku $2\text{--}5\text{ t}\cdot\text{ha}^{-1}$ (Vanguelova et al. 2016). Z hlediska přesnosti určení hranice horizontu a počtu opakování měření hloubky horizontu by pro stanovení hloubky A horizontu by bylo vhodné využít kopané sondy jako v případě studie (Frouz et al. 2009).

Zásoba recentního uhlíku v horizontu A byla vypočtena pomocí třech postupů, přičemž dva využívaly pro korekci hodnotu obsahu uhlíku v horizontu C a jeden přístup byl založen na regresním vztahu mezi celkovým obsahem uhlíku a obsahem recentního uhlíku v horizontu A. Hodnoty zásoby uhlíku jsou blízké těm, které jsou pro rekultivované porosty srovnatelného stáří uváděny v ostatních studiích (Vindušková a Frouz 2013; Zhou et al. 2017). Zároveň odpovídá i hodnotám, které pro lesní půdy v této oblasti ČR uvádí Cienciala et al. (2011). Jako nejpřesnější metoda pro určení množství recentního uhlíku v materiálech s příměsí uhlíku fosilního je považována ^{14}C radiokarbonová hmotnostní spektrometrie, která je substituována jednoduššími a finančně dostupnějšími postupy (Vindušková et al. 2015). Mezi nejčastěji používané postupy patří odečtení množství uhlíku v minerálním horizontu v místě odběru, odečtení množství uhlíku v čerstvě vytěženém (s nejkratší dobou uložení na výsypce) materiálu nebo odvozením množství fosilního uhlíku k odečtení na základě rovnice pro zásoby uhlíku v závislosti na čase (Vindušková a Frouz 2013).

Vztahy mezi nadzemní biomasou a půdním uhlíkem

První korelační analýza provedená na vzorcích 2006 odhalila střední až vyšší hodnoty korelace mezi množstvím nadzemní biomasy, její výškou a zásobou uhlíku v půdě (Frouz et al. 2009). Tato korelace se částečně projevila i při analýze vůči výškovým charakteristikám odvozeným z dat ALS. Posléze bylo provedeno testování na základě hodnot zjištěných z terénního šetření 2017. Jelikož byl vztah mezi množstvím nadzemní biomasy a množstvím půdního uhlíku pozorován několika studiemi a biomasa pro rok

2017 byla odhadem obsahujícím chybu, byla provedena i korelační analýza vůči výšce biomasy změřené v terénu v roce 2017. Ani vůči této v terénu měřené výšce nebyla zjištěna statisticky významnější hodnota korelace.

Interpolace hodnot množství půdního uhlíku

Při srovnání geostatistických metod pro interpolaci hodnot půdního uhlíku na území v řádu stovek km² dosahoval metoda RBF méně přesných výsledků než ostatní interpolační geostatistické metody (Bhunias et al. 2018). Burgess a Webster (1980) uvádějí krigging jako vhodnou metodu pro tvorbu map půdního uhlíku na základě bodových odběrů a to zejména pokud byly odebírány v pravidelné síti.


Jedním z hlavních zdrojů variability půdního uhlíku je množství opadu (Vanguelova et al. 2016). V jehličnatých lesích byla pro fermentační a humusový horizont analýzou semivariance zjištěna hraniční vzdálenost 75–225 cm (Muukkonen et al. 2009). Burgess a Webster (1980) uvádějí hodnotu prostorové vzdálenosti pro praktické půdní vzorkování v rozsahu stovek metrů až dva kilometry.

Oblast s výrazně vyšší zásobou uhlíku v půdě v severní části zkoumaného území je tvořena malou enklávou dubu stáří cca 40 let na výrazně odlišném substrátu. Prostorově vyrovnanější hodnoty obsahu uhlíku v půdě pod porosty lípy, jasanu a olše v severní části zájmového území mohou souviset se stářím porostu, které je v této oblasti nejvyšší. Spíše nižší hodnoty zásoby uhlíku při severním okraji zájmového území mohou souviset s nižší hloubkou A horizontu, která byla pod porosty lípy pozorována (Tab 16). Na vznik organominerálního horizontu v této části území mohou působit a) chemické složení materiálu opadu a rychlost jeho dekompozice; b) intenzita bioturbace; c) hladina podzemní vody.

Hloubka organominerálního horizontu a zásoba uhlíku v půdě je na výsypkách závislá na aktivitě půdního edafonu, zejména žížal, při níž dochází k promíchávání opadu s minerální složkou – bioturbaci (Frouz et al. 2008). Nižší podíl C/N v opadu lípy by měl naopak vytvářet příznivé podmínky pro bioturbaci (Jacob et al. 2009), která by měla vést k větší hloubce A horizontu (Šnajdr et al. 2013; Frouz et al. 2013). Menší pozorovaná hloubka A horizontu pod porosty lípy by mohla být z části vysvětlena vlhkostními podmínkami tohoto území. Severní část zkoumaného území se nachází na mírném severním svahu. Zároveň se nachází pod tělesem bývalé vlečky. V celém severně orientovaném svahu pod touto bariérou lze zejména v jarních měsících sledovat vysokou hladinu podzemní vody, přičemž bylo pozorováno, že vysoká hladina podzemní vody ovlivňuje výskyt žížal v půdě a druhové složení populace žížal ve smyslu snižování počtu druhů preferujících hlubší vrstvy půdy (Roots 1956; Knight et al. 1992).

V centrální části zájmového území lze pozorovat výrazně nižší hodnoty obsahu uhlíku

v A horizontu. K podobnému efektu dochází i západněji pod porosty spontánní sukcese a mladými modřínovými a smrkovými porosty. Příčina pozorovaného snížení zásoby uhlíku v A horizontu může souviset s věkem porostů. Po nasypání skládkového materiálu dochází k transformacím fosilní organické hmoty, která je v substrátu obsažena jako příměs (Pešek et al. 2010; Vindušková et al. 2015). K určité stabilizaci těchto přeměn dochází v souvislosti s akumulací recentní organické hmoty asi po 35 letech (Kříbek a Macurová 1996). Zatímco pod nejmladšími porosty v centrální části ve věku 10–20 let, mohou stále probíhat transformační procesy fosilní organické hmoty, což do určité míry reflektují koncentrace uhlíku v A horizontu a C horizontu. Oproti tomu starší porosty v jihovýchodní části (35 let) a severní části (40 let) zkoumaného území jeví v koncentracích v horizontech A a C jistou prostorovou podobnost. V případě sukcesních ploch (asi 25 let) může na transformace fosilní organické hmoty spolupůsobit i mikro-orografie povrchu. Terénní vlny, na kterých se porosty spontánní sukcese vyskytují, mohou ovlivňovat přístup vzduchu do hlubších vrstev půdy (Obr 41).



Obr 41: Řez bodovým mračnem v oblasti s terénními vlnami na plochách spontánní sukcese. Výška jednotlivých vln je asi 2 - 2,5 m.

Na sukcesních plochách byla zároveň pozorována nejnižší, statisticky odlišná hodnota objemové hmotnosti (Obr 17). Dalším faktorem potencionálně ovlivňujícím transformace fosilní organické hmoty je i rychlost eroze jílovcového materiálu. Zatímco i pod mladšími porosty (smrk, modřín, borovice, olše) byl jílovcový materiál zerodován do té míry, že tvořil souvislou vrstvu jílu, pod staršími porosty spontánní sukcese byly pod povrchovou vrstvou stále přítomné kompaktní kusy jílovce mezi nimiž se nacházel volný prostor (Obr 42).



Obr 42: Stupeň zvětrání substrátu na spontánních plochách (nahore) a ploše borovice (dole).

Rozdílné zvětrání původního materiálu popisují i Frouz et al. (2018), který jej zdůvodňuje rychlejším vyplnění volných prostorů v případě ploch urovnaných mechanizací a následným nasycením povrchu dešťovou vodou. V případě terénních vln jsou erodované částice transportovány a nedochází tak k vyplnění volných prostor mezi bloky původního materiálu. Na rychlosti zvětrávání se může spolupodílet i druhové složení, např. pod porosty smrku bylo popsáno zvětrávání minerální hmoty dvakrát až třikrát rychlejší než v případě listnatých druhů (Augusto et al. 2002). Vliv rozdílného zvětrávání na terénních vlnách vůči okolním plochám na transformace fosilní organické hmoty popsán není.

7 Závěry

Práce byla řešena v rámci několika dílčích úloh, které kombinovaly data dálkového průzkumu Země a data z terénních šetření. V rámci práce byla provedena: analýza plošné změny vegetačního pokryvu, klasifikace dat DPZ do tříd podle druhů, odhad množství uhlíku nadzemní biomasy a její prostorové distribuce na základě dat DPZ, analýza závislosti množství půdního uhlíku na faktorech prostředí a odhad prostorové distribuce množství půdního uhlíku v zájmovém území.

Úlohy byly řešeny na základě dvou sad leteckých hyperspektrálních a LiDARových dat, převzatých dat z terénního šetření z roku 2006 a originálních dat získaných při terénních šetřeních v roce 2015 a 2017.

Analýza změny vegetačního pokryvu byla provedena prostřednictvím zjednodušené klasifikace pomocí rozhodovacích stromů a překryvné analýzy. Bylo zjištěno, že v období mezi lety 2009 a 2017 došlo k výraznému navýšení podílu keřů a stromů. Na části plochy došlo pravděpodobně v souvislosti s terénními úpravami k odkrytí holé půdy. Tato analýza z části navazuje na podobnou studii, která řešila vliv vegetace na termální chování výsypky. Tento typ analýzy ve spojení druhovou klasifikací má do budoucna potenciál pro sledování šíření dřevinné vegetace v rámci plochy výsypky.

Klasifikace dat DPZ do tříd druhů byla provedena pro obě sady dat DPZ. Pro klasifikaci byla použita metoda objektově orientovaná analýzy obrazu. Tato metoda umožnila provést segmentaci na objekty, jejichž hranice dobře respektovaly hranice porostních celků jednotlivých dřevin. Celková přesnost klasifikací se pohybovala na dolní hranici přesnosti doporučené pro mapování tříd pokryvu. Některé pozorované chyby v klasifikaci jsou pravděpodobně spojené s termínem snímání dat, ve kterém se některé druhy nacházely v různém stádiu olistění. Těchto rozdílů ve fenologii druhů lze využít pro klasifikaci druhů, avšak taková analýza by vyžadovala dostatečně hustou časovou řadu dat DPZ. Vrstvy klasifikace pro jednotlivé termíny byly využity v navazujících úlohách. Mapa klasifikace tříd druhů, které byla za rok 2017 připravena pro celé území Velké podkrušnohorské výsypky, je využitelná i pro potencionální budoucí úlohy, např. pro stratifikované návrhy vzorkování.

Pro obě datové sady DPZ (2009+2010, 2017) byl proveden odhad množství uhlíku v nadzemní biomase zájmových dřevin. Pro odhad na základě datové sady 2009+2010 byla použita metoda plošného odhadu založeném na výškových charakteristikách vegetace odvozených z laserového leteckého skenování. Nejvyšší hodnoty korelace byly pozorovány pro 70–90% výškové kvantily ($r \approx 0,85$), což odpovídá výsledkům studií používajících stejné proměnné a metody. Datová sada 2017 umožnila pro odhad množství nadzemní biomasy použít postup založený na identifikaci jednotlivých stromů a druhově specifických alometrických rovnicích. Algoritmickou identifikací se podařilo získat počty stromů, které byly blízké počtu získaném vizuální interpretací dat. Odhadnuté množství uhlíku v nadzemní biomase dřevin se pohybovalo v rozmezí 20–100 t·ha⁻¹, což odpovídá hodnotám, které jsou pro odpovídající věkové stupně udávány v literatuře. Korelační analýzou nebyl zjištěn statisticky významný vztah mezi množstvím nadzemní biomasy a svažitostí na zkusných plochách 2017. Před dalším využitím těchto map distribuce uhlíku nadzemní biomasy by byla nutná jejich validace oproti standardizovanému inventarizačnímu šetření. Možnost spolupráce na takovéto validaci již byla diskutována s výzkumnými partnery.

Na základě terénního šetření byla vypočtena zásoba ($\text{t} \cdot \text{ha}^{-1}$) celkového a recentního uhlíku v organominerálním horizontu. Pozorované hodnoty zásoby uhlíku se pohybovaly v rozsahu, který je obvykle na rekultivovaných výsypkách pozorován. Zásoba recentního uhlíku v organominerálním horizontu byla vypočtena pomocí tří postupů, z nichž dva byly založené na ^{14}C radionuklidové analýze a jeden byl založen na analýze transformací organické hmoty ve výsypkovém materiálu. Mezi jednotlivými postupy nebyl zjištěn statisticky významný rozdíl v průměrné zásobě recentního uhlíku. Statisticky významné rozdíly mezi druhy byly pozorovány pouze u zásoby recentního uhlíku, která byla vypočtena pomocí korekce obsahem uhlíku v minerálním horizontu. Analýzou variance (ANOVA) byly zjištěny rozdíly mezi třídami druhů olše (*Alnus sp.*) a borovice (*Pinus sp.*). Párovým testem pak byly zjištěny statisticky významné rozdíly rozdíly v zásobě recentního uhlíku i mezi skupinami listnatých a jehličnatých druhů. Korelační analýzou byla zjištěna statisticky významná hodnota korelace mezi množstvím uhlíku v nadzemní biomase a množstvím recentního uhlíku pro skupinu jehličnatých dřevin ($r = 0,28$) a střední hodnota korelace pro třídu spontánní sukcese ($r = 0,65$). Dále byl korelační analýzou posuzován vztah zásoby recentního uhlíku vůči svažitosti. Touto analýzou byla zjištěna slabá statisticky významná hodnota korelace ($r = -0,24$). Dále byla negativní hodnota korelace pozorována pro skupinu listnatých druhů a vysoká absolutní hodnota korelace pro třídu lípa (*Tilia cordata* L.). Na základě těchto výsledků byla prostorová distribuce uhlíku odhadnuta pomocí geostatistické interpolační metody „Radial basis function“.

Překryvnou analýzou map zásoby recentního uhlíku v organominerálním horizontu a množstvím uhlíku v nadzemní biomase s vrstvou klasifikace bylo zjištěno celkové množství uhlíku v těchto dvou zásobnících: 7,6 tis. tun uhlíku vázaného v nadzemní biomase a 8,1–12,2 tis. tun recentního uhlíku v organominerálním horizontu A v závislosti na zvolené metodě výpočtu.

Na základě pozorovaných hodnot zásoby recentního půdního uhlíku, vztahů vůči faktorům prostředí a metod pro jeho stanovení by bylo vhodné zaměřit se na zjištění prostorové variability uhlíku v minerálním horizontu ve vysokém prostorovém rozlišení a na průběh transformací fosilního uhlíku v jednotlivých horizontech v závislosti na podmínkách prostředí.

8 Seznam literatury

- AHOKAS, E., H. KAARTINEN a Juha HYYPPÄ, 2003. A quality assessment of airborne laser scanner data. *International Archives of Photogrammetry and Remote Sensing*. 34(part 3), W13.
- ANDERSON, J, L PLOURDE, M MARTIN, B BRASWELL, M SMITH, R DUBAYAH, M HOFTON a J BLAIR, 2008. Integrating waveform lidar with hyperspectral imagery for inventory of a northern temperate forest. *Remote Sensing of Environment* [online]. 112(4), 1856–1870. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2007.09.009
- ANDREWS, G. S., 1942. Alaska Highway Survey in British Columbia. *The Geographical Journal* [online]. 100(1), 5. ISSN 00167398. Dostupné z: doi:10.2307/1789229
- ANTROPOV, O., Y. RAUSTE, A. VÄÄNÄNEN, T. MUTANEN a T. HÄME, 2016. Mapping forest disturbance using long time series of Sentinel-1 data: Case studies over boreal and tropical forests. In: *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS): 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* [online]. s. 3906–3909. Dostupné z: doi:10.1109/IGARSS.2016.7730014
- ANTWI, Effah Kwabena, Rene KRAWCZYNSKI a Gerhard WIEGLEB, 2008. Detecting the effect of disturbance on habitat diversity and land cover change in a post-mining area using GIS. *Landscape and Urban Planning* [online]. 87(1), 22–32. ISSN 01692046. Dostupné z: doi:10.1016/j.landurbplan.2008.03.009
- ARUP ENVIRONMENTAL AND GREAT BRITAIN. MINERALS DIVISION, 1996. *The Environmental Effects of Dust from Surface Mineral Workings: Technical report* [online]. 1996. B.m.: H.M. Stationery Office. Dostupné z: <https://books.google.cz/books?id=mILLSAAACAAJ>
- AUGUSTO, Laurent, Jacques RANGER, Dan BINKLEY a Andreas ROTHE, 2002. Impact of several common tree species of European temperate forests on soil fertility. *Annals of Forest Science* [online]. 59(3), 233–253. ISSN 1286-4560, 1297-966X. Dostupné z: doi:10.1051/forest:2002020
- AWAYA, Yoshio a Tomoaki TAKAHASHI, 2017. Evaluating the Differences in Modeling Biophysical Attributes between Deciduous Broadleaved and Evergreen Conifer Forests Using Low-Density Small-Footprint LiDAR Data. *Remote Sensing* [online]. 9(6), 572. Dostupné z: doi:10.3390/rs9060572
- AXELSSON, Peter, 2000. DEM Generation From Laser Scanner Data Using Adaptive TIN Models. In: *XIXth ISPRS Congress, Commission IV: International Archives of Photogrammetry and Remote Sensing*. s. 110–117.

BACCINI, A, N LAPORTE, S J GOETZ, M SUN a H DONG, 2008. A first map of tropical Africa's above-ground biomass derived from satellite imagery. *Environmental Research Letters* [online]. 3(4), 045011. ISSN 1748-9326. Dostupné z: doi:10.1088/1748-9326/3/4/045011

BAE, Jeehwan a Youngryel RYU, 2015. Land use and land cover changes explain spatial and temporal variations of the soil organic carbon stocks in a constructed urban park. *Landscape and Urban Planning* [online]. 136, 57–67. ISSN 0169-2046. Dostupné z: doi:10.1016/j.landurbplan.2014.11.015

BARGIEL, Damian, 2017. A new method for crop classification combining time series of radar images and crop phenology information. *Remote Sensing of Environment* [online]. 198, 369–383. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2017.06.022

BCS, INCORPORATED, 2002. *ENERGY AND ENVIRONMENTAL PROFILE OF THE U.S. MINING INDUSTRY* [online]. B.m.: U.S. Department of Energy [vid. 2018-04-20]. Dostupné z: <https://www.energy.gov/sites/prod/files/2013/11/f4/coal.pdf>

BEETS, P. N., A. M. BRANDON, C. J. GOULDING, M. O. KIMBERLEY, T. S. H. PAUL a N. SEARLES, 2011. The inventory of carbon stock in New Zealand's post-1989 planted forest for reporting under the Kyoto protocol. *Forest Ecology and Management* [online]. 262(6), 1119–1130. ISSN 0378-1127. Dostupné z: doi:10.1016/j.foreco.2011.06.012

BEN-DOR, E. a A. BANIN, 1994. Visible and near-infrared (0.4–1.1 μm) analysis of arid and semiarid soils. *Remote Sensing of Environment* [online]. 48(3), 261–274. ISSN 0034-4257. Dostupné z: doi:10.1016/0034-4257(94)90001-9

BEN-DOR, E., K. PATKIN, A. BANIN a A. KARNIELI, 2002. Mapping of several soil properties using DAIS-7915 hyperspectral scanner data - a case study over clayey soils in Israel. *International Journal of Remote Sensing* [online]. 23(6), 1043–1062. ISSN 0143-1161. Dostupné z: doi:10.1080/01431160010006962

BHUIYAN, Mohammad A.H., Lutfar PARVEZ, M.A. ISLAM, Samuel B. DAMPARE a Shigeyuki SUZUKI, 2010. Heavy metal pollution of coal mine-affected agricultural soils in the northern part of Bangladesh. *Journal of Hazardous Materials* [online]. 173(1–3), 384–392. ISSN 03043894. Dostupné z: doi:10.1016/j.jhazmat.2009.08.085

BHUNIA, Gouri Sankar, Pravat Kumar SHIT a Ramkrishna MAITI, 2018. Comparison of GIS-based interpolation methods for spatial distribution of soil organic carbon (SOC). *Journal of the Saudi Society of Agricultural Sciences* [online]. 17(2), 114–126. ISSN 1658-077X. Dostupné z: doi:10.1016/j.jssas.2016.02.001

BIAN, Zhengfu, Hilary I INYANG, John L DANIELS, Frank OTTO a Sue STRUTHERS, 2010. Environmental issues from coal mining and their solutions. *Mining Science and Technology (China)* [online]. 20(2), 215–223. ISSN 16745264. Dostupné z: doi:10.1016/S1674-5264(09)60187-3

- BOND-LAMBERTY, B, C WANG a S T GOWER, 2002. Aboveground and belowground biomass and sapwood area allometric equations for six boreal tree species of northern Manitoba. *Canadian Journal of Forest Research* [online]. 32(8), 1441–1450. ISSN 0045-5067, 1208-6037. Dostupné z: doi:10.1139/x02-063
- BOTKIN, Daniel B., Lloyd G. SIMPSON a Robert A. NISBET, 1993. Biomass and carbon storage of the North American deciduous forest. *Biogeochemistry* [online]. 20(1), 1–17. ISSN 0168-2563, 1573-515X. Dostupné z: doi:10.1007/BF00002803
- BOUVIER, Marc, Sylvie DURRIEU, Richard A. FOURNIER a Jean-Pierre RENAUD, 2015. Generalizing predictive models of forest inventory attributes using an area-based approach with airborne LiDAR data. *Remote Sensing of Environment* [online]. 156, 322–334. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2014.10.004
- BOWERS, S. A. a R. J. HANKS, 1965. Reflection of radiant energy from soil. *Soil Science*. 100(3), 130–138.
- BRADSHAW, Anthony D., 1996. Underlying principles of restoration. *Canadian Journal of Fisheries and Aquatic Sciences*. 53(S1), 3–9.
- BRÆKKE, Finn H., 1986. Distribution and yield of biomass from young *Pinus sylvestris* and *Picea abies* stands on drained and fertilized peatland. *Scandinavian Journal of Forest Research* [online]. 1(1–4), 49–66. ISSN 0282-7581. Dostupné z: doi:10.1080/02827588609382400
- BREIDENBACH, Johannes, Erik NÆSSET a Terje GOBAKKEN, 2012. Improving k-nearest neighbor predictions in forest inventories by combining high and low density airborne laser scanning data. *Remote Sensing of Environment* [online]. 117, 358–365. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2011.10.010
- BROM, Jakub, Václav NEDBAL, Jan PROCHÁZKA a Emilie PECHAROVÁ, 2012. Changes in vegetation cover, moisture properties and surface temperature of a brown coal dump from 1984 to 2009 using satellite data analysis. *Ecological Engineering* [online]. 43, 45–52. ISSN 09258574. Dostupné z: doi:10.1016/j.ecoleng.2011.03.001
- BROM, Jakub a Jan POKORNÝ, 2009. Temperature and humidity characteristics of two willow stands, a peaty meadow and a drained pasture and their impact on landscape functioning. *Boreal Environment Research*. 14, 389–403. ISSN 1239-6095.
- BUJALSKÝ, Luděk, Satoshi KANEDA, Petr DVORŠČÍK a Jan FROUZ, 2014. In situ soil respiration at reclaimed and unreclaimed post-mining sites: Responses to temperature and reclamation treatment. *Ecological Engineering* [online]. 68, 53–59. ISSN 0925-8574. Dostupné z: doi:10.1016/j.ecoleng.2014.03.048

BUNCE, R. G. H., 1968. Biomass and Production of Trees in a Mixed Deciduous Woodland: I. Girth and Height as Parameters for the Estimation of Tree Dry Weight. *Journal of Ecology* [online]. 56(3), 759–775. ISSN 0022-0477. Dostupné z: doi:10.2307/2258105

BURGESS, T. M. a R. WEBSTER, 1980. OPTIMAL INTERPOLATION AND ISARITHMIC MAPPING OF SOIL PROPERTIES: I THE SEMI-VARIOGRAM AND PUNCTUAL KRIGING. *Journal of Soil Science* [online]. 31(2), 315–331. ISSN 00224588. Dostupné z: doi:10.1111/j.1365-2389.1980.tb02084.x

CAMBARDELLA, C. A. a E. T. ELLIOTT, 1993. Methods for physical separation and characterization of soil organic matter fractions. In: L. BRUSSAARD a M. J. KOOISTRA, ed. *Soil Structure/Soil Biota Interrelationships* [online]. Amsterdam: Elsevier, s. 449–457 [vid. 2018-07-16]. ISBN 978-0-444-81490-6. Dostupné z: doi:10.1016/B978-0-444-81490-6.50036-4

CAMPBELL, P. K. Entcheva, B. N. ROCK, M. E. MARTIN, C. D. NEEFUS, J. R. IRONS, E. M. MIDDLETON a J. ALBRECHTOVA, 2004. Detection of initial damage in Norway spruce canopies using hyperspectral airborne data. *International Journal of Remote Sensing* [online]. 25(24), 5557–5584. ISSN 0143-1161, 1366-5901. Dostupné z: doi:10.1080/01431160410001726058

CAO, Quang V., 2004. Predicting Parameters of a Weibull Function for Modeling Diameter Distribution. *Forest Science* [online]. 50(5), 682–685. ISSN 0015-749X. Dostupné z: doi:10.1093/forestscience/50.5.682

CAO, Xin, Yu LIU, Xihong CUI, Jin CHEN a Xuehong CHEN, 2018. Mechanisms, monitoring and modeling of shrub encroachment into grassland: a review. *International Journal of Digital Earth* [online]. 0(0), 1–17. ISSN 1753-8947. Dostupné z: doi:10.1080/17538947.2018.1478004

CARTER, Martin R., 2002. Soil Quality for Sustainable Land Management. *Agronomy Journal* [online]. 94(1), 38–47. ISSN 1435-0645. Dostupné z: doi:10.2134/agronj2002.3800

CÉCILLON, Lauric, Nathalie CASSAGNE, Sonia CZARNES, Raphaël GROS a Jean-Jacques BRUN, 2008. Variable selection in near infrared spectra for the biological characterization of soil and earthworm casts. *Soil Biology and Biochemistry* [online]. 40(7), 1975–1979. ISSN 00380717. Dostupné z: doi:10.1016/j.soilbio.2008.03.016

CIENCIALA, E., M. ČERNÝ, F. TATARINOV, J. APLTAUER a Z. EXNEROVÁ, 2006a. Biomass functions applicable to Scots pine. *Trees* [online]. 20(4), 483–495. ISSN 0931-1890, 1432-2285. Dostupné z: doi:10.1007/s00468-006-0064-4

CIENCIALA, Emil, Jan APLTAUER, Zuzana EXNEROVÁ, Vladimír ZATLOUKAL, Jaromír MACKŮ, Vladimír HENŽLÍK, Luděk ŠEFRNA, Jana JANDERKOVÁ a Michal MAREK V., 2011. Les, uhlík a lesnictví ČR v podmínkách měnícího se prostředí. In: Michal MAREK V., ed. *Uhlík v ekosystémech České republiky v měnícím se klimatu*. s. 129–188. ISBN 978-80-904351-1-7.

CIENCIALA, Emil, Radek RUSS, Jan APLTAUER, Zuzana EXNEROVÁ, Miroslav MICHALEC a Pavel MÁLEK, 2006b. *Stanovení zásob dřevní biomasy (uhlíku) na zalesněných plochách lokality Vintířov*. Jílové u Prahy: IFER – Ústav pro výzkum lesních ekosystémů.

CLARK, Matthew L., Dar A. ROBERTS, John J. EWEL a David B. CLARK, 2011. Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors. *Remote Sensing of Environment* [online]. 115(11), 2931–2942. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2010.08.029

COOMES, David A., Michele DALPONTE, Tommaso JUCKER, Gregory P. ASNER, Lindsay F. BANIN, David F. R. P. BURSLEM, Simon L. LEWIS, Reuben NILUS, Oliver L. PHILLIPS, Mui-How PHUA a Lan QIE, 2017. Area-based vs tree-centric approaches to mapping forest carbon in Southeast Asian forests from airborne laser scanning data. *Remote Sensing of Environment* [online]. 194, 77–88. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2017.03.017

CORTES, Corinna a Vladimir VAPNIK, 1995. Support-vector networks. *Machine Learning* [online]. 20(3), 273–297. ISSN 0885-6125, 1573-0565. Dostupné z: doi:10.1007/BF00994018

COVER, T. a P. HART, 1967. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory* [online]. 13(1), 21–27. ISSN 0018-9448. Dostupné z: doi:10.1109/TIT.1967.1053964

ČERNÝ, Martin, 1990. Biomass of picea abies (L.) Karst. in midwestern bohemia. *Scandinavian Journal of Forest Research* [online]. 5(1–4), 83–95. ISSN 0282-7581. Dostupné z: doi:10.1080/02827589009382595

ČIHÁK, Tomáš, Tomáš HLÁSNÝ, Radka STOLARIKOVÁ, Monika VEJPUSTKOVÁ a Róbert MARUŠÁK, 2014. Functions for the aboveground woody biomass in Small-leaved lime (*Tilia cordata* Mill.) / Funkce pro hodnocení biomasy nadzemních částí lípy malolisté (*Tilia cordata* Mill.). *Central European Forestry Journal* [online]. 60(3), 150–158. ISSN 2454-0358. Dostupné z: doi:10.2478/forj-2014-0016

DALPONTE, Michele, Lorenzo BRUZZONE a Damiano GIANELLE, 2008. Fusion of Hyperspectral and LIDAR Remote Sensing Data for Classification of Complex Forest Areas. *IEEE Transactions on Geoscience and Remote Sensing* [online]. 46(5), 1416–1427. ISSN 0196-2892. Dostupné z: doi:10.1109/TGRS.2008.916480

DALPONTE, Michele, Lorenzo BRUZZONE a Damiano GIANELLE, 2012. Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data. *Remote Sensing of Environment* [online]. 123, 258–270. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2012.03.013

DALPONTE, Michele, Lorenzo BRUZZONE, Loris VESCOVO a Damiano GIANELLE, 2009. The role of spectral resolution and classifier complexity in

the analysis of hyperspectral images of forest areas. *Remote Sensing of Environment* [online]. 113(11), 2345–2355. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2009.06.013

DALPONTE, Michele, Hans Ole ØRKA, Liviu Theodor ENE, Terje GOBAKKEN a Erik NÆSSET, 2014. Tree crown delineation and tree species classification in boreal forests using hyperspectral and ALS data. *Remote Sensing of Environment* [online]. 140, 306–317. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2013.09.006

DE VOS, Bruno, Nathalie COOLS, Hannu ILVESNIEMI, Lars VESTERDAL, Elena VANGUELOVA a Stefano CARNICELLI, 2015. Benchmark values for forest soil carbon stocks in Europe: Results from a large scale forest soil survey. *Geoderma* [online]. 251–252, 33–46. ISSN 0016-7061. Dostupné z: doi:10.1016/j.geoderma.2015.03.008

DONG, Jiarui, Robert K. KAUFMANN, Ranga B. MYNENI, Compton J. TUCKER, Pekka E. KAUPPI, Jari LISKI, Wolfgang BUERMANN, V. ALEXEYEV a Malcolm K. HUGHES, 2003. Remote sensing estimates of boreal and temperate forest woody biomass: carbon pools, sources, and sinks. *Remote Sensing of Environment* [online]. 84(3), 393–410. ISSN 0034-4257. Dostupné z: doi:http://dx.doi.org/10.1016/S0034-4257(02)00130-X

DONG, Shaochun, Sergey SAMSONOV, Hongwei YIN, Suping YAO a Chong XU, 2015. Spatio-temporal analysis of ground subsidence due to underground coal mining in Huainan coalfield, China. *Environmental Earth Sciences* [online]. 73(9), 5523–5534. ISSN 1866-6280, 1866-6299. Dostupné z: doi:10.1007/s12665-014-3806-4

DUBE, Timothy, Richard MUCHENA, Mhosisi MASOCHA a Cletah SHOKO, 2018. Estimating soil organic and aboveground woody carbon stock in a protected dry Miombo ecosystem, Zimbabwe: Landsat 8 OLI data applications. *Physics and Chemistry of the Earth, Parts A/B/C* [online]. [vid. 2018-04-28]. ISSN 1474-7065. Dostupné z: doi:10.1016/j.pce.2018.03.007

EGBERTH, Mikael, Gert NYBERG, Erik NÆSSET, Terje GOBAKKEN, Ernest MAUYA, Rogers MALIMBWI, Josiah KATANI, Nurudin CHAMUYA, George BULENGA a Håkan OLSSON, 2017. Combining airborne laser scanning and Landsat data for statistical modeling of soil carbon and tree biomass in Tanzanian Miombo woodlands. *Carbon Balance and Management* [online]. 12(1), 8. ISSN 1750-0680. Dostupné z: doi:10.1186/s13021-017-0076-y

ELKHRACHY, Ismail, 2017. Vertical accuracy assessment for SRTM and ASTER Digital Elevation Models: A case study of Najran city, Saudi Arabia. *Ain Shams Engineering Journal* [online]. [vid. 2018-07-16]. ISSN 2090-4479. Dostupné z: doi:10.1016/j.asej.2017.01.007

EUROPEAN SPACE AGENCY, 2014. *ICESat-2 (Ice, Cloud and land Elevation Satellite-2)* [online]. Dostupné z: https://directory.eoportal.org/web/eoportal/satellite-missions/i/icesat-2

FASSNACHT, Fabian E., Carsten NEUMANN, Michael FORSTER, Henning BUDDENBAUM, Aniruddha GHOSH, Anne CLASEN, Pawan Kumar JOSHI a Barbara KOCH, 2014a. Comparison of Feature Reduction Algorithms for Classifying Tree Species With Hyperspectral Data on Three Central European Test Sites. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* [online]. 7(6), 2547–2561. ISSN 1939-1404, 2151-1535. Dostupné z: doi:10.1109/JSTARS.2014.2329390

FASSNACHT, Fabian Ewald, Hooman LATIFI, Krzysztof STERENĆZAK, Aneta MODZELEWSKA, Michael LEFSKY, Lars T. WASER, Christoph STRAUB a Aniruddha GHOSH, 2016. Review of studies on tree species classification from remotely sensed data. *Remote Sensing of Environment* [online]. 186, 64–87. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2016.08.013

FASSNACHT, F.E., F. HARTIG, H. LATIFI, C. BERGER, J. HERNÁNDEZ, P. CORVALÁN a B. KOCH, 2014b. Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. *Remote Sensing of Environment* [online]. 154, 102–114. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2014.07.028

FERSTER, Colin J., Nicholas C. COOPS a J. A. (Tony) TROFYMOW, 2009. Aboveground large tree mass estimation in a coastal forest in British Columbia using plot-level metrics and individual tree detection from lidar. *Canadian Journal of Remote Sensing* [online]. 35(3), 270–275. ISSN 1712-7971. Dostupné z: doi:10.5589/m09-014

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS, 2015. *Global Forest Resources Assessment 2015 - How are the world's forests changing?* [online] [vid. 2016-05-22]. Dostupné z: <http://www.fao.org/resources/infographics/infographics-details/en/c/325836/>

FOODY, Giles M., Doreen S. BOYD a Mark E.J. CUTLER, 2003. Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. *Remote Sensing of Environment* [online]. 85(4), 463–474. ISSN 00344257. Dostupné z: doi:10.1016/S0034-4257(03)00039-7

FRANKLIN, J., 1986. Thematic mapper analysis of coniferous forest structure and composition. *International Journal of Remote Sensing* [online]. 7(10), 1287–1301. ISSN 0143-1161. Dostupné z: doi:10.1080/01431168608948931

FREDEN, Stanley C., Enrico P. MERCANTI a Margaret A. BECKER, 1974. *Third Earth Resources Technology Satellite-1 Symposium: The Proceedings of a Symposium Held by Goddard Space Flight Center at Washington, DC on December 10-14, 1973: Prepared at Goddard Space Flight Center*. B.m.: Scientific and Technical Information Office, National Aeronautics and Space Administration.

FROUZ, Jan, 2008. The effect of litter type and macrofauna community on litter decomposition and organic matter accumulation in post-mining sites. *Biologia*. 63(2), 249–253. ISSN 1336-9563.

FROUZ, Jan, 2017. Effects of Soil Development Time and Litter Quality on Soil Carbon Sequestration: Assessing Soil Carbon Saturation with a Field Transplant Experiment along a Post-mining Chronosequence. *Land Degradation & Development* [online]. 28(2), 664–672. ISSN 1099-145X. Dostupné z: doi:10.1002/ldr.2580

FROUZ, Jan, Jiří KALČÍK a Václava VELICHOVÁ, 2011. Factors causing spatial heterogeneity in soil properties, plant cover, and soil fauna in a non-reclaimed post-mining site. *Ecological Engineering* [online]. 37(11), 1910–1913. ISSN 0925-8574. Dostupné z: doi:10.1016/j.ecoleng.2011.06.039

FROUZ, Jan, Beate KEPLIN, Václav PIŽL, Karel TAJOVSKÝ, Josef STARÝ, Alena LUKEŠOVÁ, Alena NOVÁKOVÁ, Vladimír BALÍK, Ladislav HÁNĚL, Jan MATERNA, Christian DÜKER, Josef CHALUPSKÝ, Josef RUSEK a Thomas HEINKELE, 2001. Soil biota and upper soil layer development in two contrasting post-mining chronosequences. *Ecological Engineering* [online]. 17(2–3), 275–284. ISSN 0925-8574. Dostupné z: doi:10.1016/S0925-8574(00)00144-0

FROUZ, Jan, Miluše LIVEČKOVÁ, Jana ALBRECHTOVÁ, Alica CHROŇÁKOVÁ, Tomáš CAJTHAML, Václav PIŽL, Ladislav HÁNĚL, Josef STARÝ, Petr BALDRIAN, Zuzana LHOTÁKOVÁ, Hana ŠIMÁČKOVÁ a Šárka CEPÁKOVÁ, 2013. Is the effect of trees on soil properties mediated by soil fauna? A case study from post-mining sites. *Forest Ecology and Management* [online]. 309, Influence of tree species on forest soils: New evidence from field studies, 87–95. ISSN 0378-1127. Dostupné z: doi:10.1016/j.foreco.2013.02.013

FROUZ, Jan, Ondřej MUDRÁK, Erika REITSCHMIEDOVÁ, Alena WALMSLEY, Pavla VACHOVÁ, Hana ŠIMÁČKOVÁ, Jana ALBRECHTOVÁ, Jabbar MORADI a Jiří KUČERA, 2018. Rough wave-like heaped overburden promotes establishment of woody vegetation while leveling promotes grasses during unassisted post mining site development. *Journal of Environmental Management* [online]. 205, 50–58. ISSN 0301-4797. Dostupné z: doi:10.1016/j.jenvman.2017.09.065

FROUZ, Jan, Václav PIŽL, Emil CIENCIALA a Jiří KALČÍK, 2009. Carbon storage in post-mining forest soil, the role of tree biomass and soil bioturbation. *Biogeochemistry* [online]. 94(2), 111–121. ISSN 0168-2563, 1573-515X. Dostupné z: doi:10.1007/s10533-009-9313-0

FROUZ, Jan, Karel PRACH, Václav PIŽL, Ladislav HÁNĚL, Josef STARÝ, Karel TAJOVSKÝ, Jan MATERNA, Vladimír BALÍK, Jiří KALČÍK a Klára ŘEHOUNKOVÁ, 2008. Interactions between soil development, vegetation and soil fauna during spontaneous succession in post mining sites. *European Journal of Soil Biology* [online]. 44(1), 109–121. ISSN 1164-5563. Dostupné z: doi:10.1016/j.ejsobi.2007.09.002

FROUZ, Jan, Veronika VOBORŇILOVÁ, Ivana JANOUŠOVÁ, Štěpánka KADOCHOVÁ a Luboš MATĚJÍČEK, 2015. Spontaneous establishment of late successional tree species English oak (*Quercus robur*) and European beech (*Fagus sylvatica*) at reclaimed alder plantation and unreclaimed post mining sites. *Ecological*

Engineering [online]. 77, 1–8. ISSN 0925-8574. Dostupné z: doi:10.1016/j.ecoleng.2015.01.001

GALE, John, John BRADSHAW, Zhenlin CHEN, Amit GARG, Dario GOMEZ, Hans-Holger ROGNER, Dale SIMBECK, Robert WILLIAMS, Ferenc TOTH a Detlef VAN VUUREN, 2005. Sources of CO₂. In: Bert METZ, Ogunlade DAVIDSON, Heleen DE CONINCK, Manuela LOOS a Leo MEYER, ed. *IPCC Special Report on Carbon dioxide Capture and Storage*. B.m.: Cambridge University Press, s. 75–104.

GARCIA-GUTIERREZ, Jorge, Eduardo GONZALEZ-FERREIRO, Jose C. RIQUELME-SANTOS, David MIRANDA, Ulises DIEGUEZ-ARANDA a Rafael M. NAVARRO-CERRILLO, 2014. Evolutionary feature selection to estimate forest stand variables using LiDAR. *International Journal of Applied Earth Observation and Geoinformation* [online]. 26, 119–131. ISSN 03032434. Dostupné z: doi:10.1016/j.jag.2013.06.005

GARCIA-PAUSAS, Jordi, Pere CASALS, Lluís CAMARERO, Carme HUGUET, Maria-Teresa SEBASTIÀ, Roy THOMPSON a Joan ROMANYÀ, 2007. Soil organic carbon storage in mountain grasslands of the Pyrenees: effects of climate and topography. *Biogeochemistry* [online]. 82(3), 279–289. ISSN 0168-2563, 1573-515X. Dostupné z: doi:10.1007/s10533-007-9071-9

GATZIOLIS, Demetrios, Jeremy S. FRIED a Vicente S. MONLEON, 2010. Challenges to Estimating Tree Height via LiDAR in Closed-Canopy Forests: A Parable from Western Oregon. *Forest Science*. 56(2), 139–155. ISSN 1938-3738.

GHOSE, Mrinal K, 2001. Management of topsoil for geo-environmental reclamation of coal mining areas. *Environmental Geology* [online]. 40(11–12), 1405–1410. ISSN 0943-0105, 1432-0495. Dostupné z: doi:10.1007/s002540100321

GHOSH, Aniruddha, Fabian Ewald FASSNACHT, P. K. JOSHI a Barbara KOCH, 2014. A framework for mapping tree species combining hyperspectral and LiDAR data: Role of selected classifiers and sensor across three spatial scales. *International Journal of Applied Earth Observation and Geoinformation* [online]. 26, 49–63. ISSN 0303-2434. Dostupné z: doi:10.1016/j.jag.2013.05.017

GREEN, A. A., M. BERMAN, P. SWITZER a M. D. CRAIG, 1988. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. *IEEE Transactions on Geoscience and Remote Sensing* [online]. 26(1), 65–74. ISSN 0196-2892. Dostupné z: doi:10.1109/36.3001

GRINAND, C., G. Le MAIRE, G. VIEILLEDENT, H. RAZAKAMANARIVO, T. RAZAFIMBELO a M. BERNOUX, 2017. Estimating temporal changes in soil carbon stocks at ecoregional scale in Madagascar using remote-sensing. *International Journal of Applied Earth Observation and Geoinformation* [online]. 54, 1–14. ISSN 0303-2434. Dostupné z: doi:10.1016/j.jag.2016.09.002

HAMRAZ, Hamid, Marco A. CONTRERAS a Jun ZHANG, 2017. Vertical stratification of forest canopy for segmentation of understory trees within small-footprint airborne LiDAR point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing* [online]. 130, 385–392. ISSN 0924-2716. Dostupné z: doi:10.1016/j.isprsjprs.2017.07.001

HANUŠ, Jan, Jan NOVOTNÝ a O. BROVKINA, 2017. Softwarový nástroj Biomass Mapper. In: *GIS Ostrava: GIS Ostrava 2017*.

HANZL, Vlastimil, Jan NOVOTNÝ, Miloš CIBULKA a Lucie HOMOLOVÁ, 2014. Letecké a pozemní laserové skenování. In: František ZEMEK, ed. *Letecký dálkový průzkum Země: teorie a příklady hodnocení terestrických ekosystémů*. Brno: Centrum výzkumu globální změny AV ČR, v.v.i, s. 61–72. ISBN 978-80-87902-07-3.

HEINZEL, Johannes a Barbara KOCH, 2011. Exploring full-waveform LiDAR parameters for tree species classification. *International Journal of Applied Earth Observation and Geoinformation* [online]. 13(1), 152–160. ISSN 03032434. Dostupné z: doi:10.1016/j.jag.2010.09.010

HELBIG, Manuel, Laura E. CHASMER, Ankur R. DESAI, Natascha KLJUN, William L. QUINTON a Oliver SONNENTAG, 2017. Direct and indirect climate change effects on carbon dioxide fluxes in a thawing boreal forest–wetland landscape. *Global Change Biology* [online]. 23(8), 3231–3248. ISSN 1365-2486. Dostupné z: doi:10.1111/gcb.13638

HODGSON, Michael E. a Patrick BRESNAHAN, 2004. Accuracy of Airborne Lidar-Derived Elevation. *Photogrammetric Engineering & Remote Sensing*. 70(3), 331–339. ISSN 1938-3738.

HOCHBICHLER, Eduard, 2002. *Inventur von Biomasse- und Nährstoffvorräten in Waldbeständen: Vorläufige Ergebnisse von Biomasseninventuren in Buchen- und Mittelwaldbeständen*. Technical Report 186. München: Forstliche Forschungsberichte.

HOMOLOVÁ, Lucie a Marek PIVOVARNÍK, 2014. Teoretické základy dálkového průzkumu Země. In: František ZEMEK, ed. *Letecký dálkový průzkum Země: teorie a příklady hodnocení terestrických ekosystémů*. Brno: Centrum výzkumu globální změny AV ČR, v.v.i, s. 15–34. ISBN 978-80-87902-07-3.

HOUGHTON, R. A., 2005. Aboveground Forest Biomass and the Global Carbon Balance. *Global Change Biology* [online]. 11(6), 945–958. ISSN 1365-2486. Dostupné z: doi:10.1111/j.1365-2486.2005.00955.x

HOVI, A., L. KORHONEN, J. VAUHKONEN a I. KORPELA, 2016. LiDAR waveform features for tree species classification and their sensitivity to tree- and acquisition related parameters. *Remote Sensing of Environment* [online]. 173, 224–237. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2015.08.019

- HU, Baoxin, Jili LI, Linhai JING a Aaron JUDAH, 2014. Improving the efficiency and accuracy of individual tree crown delineation from high-density LiDAR data. *International Journal of Applied Earth Observation and Geoinformation* [online]. 26, 145–155. ISSN 0303-2434. Dostupné z: doi:10.1016/j.jag.2013.06.003
- HUBER, Silvia, Mathias KNEUBÜHLER, Achilleas PSOMAS, Klaus ITTEN a Niklaus E. ZIMMERMANN, 2008. Estimating foliar biochemistry from hyperspectral data in mixed forest canopy. *Forest Ecology and Management* [online]. 256(3), Impacts of forest ecosystem management on greenhouse gas budgets, 491–501. ISSN 0378-1127. Dostupné z: doi:10.1016/j.foreco.2008.05.011
- CHAGAS, César da Silva, Waldir DE CARVALHO JUNIOR, Silvio Barge BHERING a Braz CALDERANO FILHO, 2016. Spatial prediction of soil surface texture in a semiarid region using random forest and multiple linear regressions. *CATENA* [online]. 139, 232–240. ISSN 0341-8162. Dostupné z: doi:10.1016/j.catena.2016.01.001
- CHENG, Yuan-Ping, Lei WANG a Xiao-Lei ZHANG, 2011. Environmental impact of coal mine methane emissions and responding strategies in China. *International Journal of Greenhouse Gas Control* [online]. 5(1), 157–166. ISSN 17505836. Dostupné z: doi:10.1016/j.ijggc.2010.07.007
- CHIRICI, Gherardo, Ronald E. MCROBERTS, Lorenzo FATTORINI, Matteo MURA a Marco MARCHETTI, 2016. Comparing echo-based and canopy height model-based metrics for enhancing estimation of forest aboveground biomass in a model-assisted framework. *Remote Sensing of Environment* [online]. 174, 1–9. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2015.11.010
- CHROUST, L., 1985. Above-ground biomass of young pine forests (*Pinus sylvestris*) and its determination. *Communicationes Instituti Forestalis Cechosloveniae*. 14, 127–145.
- CHROUST, L. a J. TESAŘOVÁ, 1985. Quatification of above-ground components of 20 years old Norway spruce (*Picea abies* (L.) Karsten). *Communicationes Instituti Forestalis Cechosloveniae*. 14, 111–126.
- ICIMOD, 2015. *Multi-scale forest biomass assessment and monitoring in the Hindu Kush Himalayan Region: a geospatial perspective*. Kathmandu, Nepal: International Centre for Integrated Mountain Development, Nepal. Special publication. ISBN 978-92-9115-336-7.
- JACOB, Mascha, Nadine WELAND, Christian PLATNER, Matthias SCHAEFER, Christoph LEUSCHNER a Frank M. THOMAS, 2009. Nutrient release from decomposing leaf litter of temperate deciduous forest trees along a gradient of increasing tree species diversity. *Soil Biology and Biochemistry* [online]. 41(10), 2122–2130. ISSN 0038-0717. Dostupné z: doi:10.1016/j.soilbio.2009.07.024
- JENKS, George F., 1977. *Optimal Data Classification For Choropleth Maps*. 1977. B.m.: University of Kansas.

JOBÁGY, Esteban G. a Robert B. JACKSON, 2000. THE VERTICAL DISTRIBUTION OF SOIL ORGANIC CARBON AND ITS RELATION TO CLIMATE AND VEGETATION. *Ecological Applications* [online]. 10(2), 423–436. ISSN 1051-0761. Dostupné z: doi:10.1890/1051-0761(2000)010[0423:TVDOSO]2.0.CO;2

JOHANSSON, T., 2000. Biomass equations for determining fractions of common and grey alders growing on abandoned farmland and some practical implications. *Biomass and Bioenergy* [online]. 18(2), 147–159. ISSN 0961-9534. Dostupné z: doi:10.1016/S0961-9534(99)00078-1

JOHANSSON, Tord, 1999a. Biomass equations for determining fractions of European aspen growing on abandoned farmland and some practical implications. *Biomass and Bioenergy* [online]. 17(6), 471–480. ISSN 0961-9534. Dostupné z: doi:10.1016/S0961-9534(99)00073-2

JOHANSSON, Tord, 1999b. Dry matter amounts and increment in 21- to 91-year-old common alder and grey alder and some practical implications. *Canadian Journal of Forest Research* [online]. 29(11), 1679–1690. ISSN 0045-5067. Dostupné z: doi:10.1139/x99-126

JOHNSON, D. Barrie, 2003. Chemical and microbiological characteristics of mineral spoils and drainage waters at abandoned coal and metal mines. *Water, Air and Soil Pollution: Focus*. 3(1), 47–66. ISSN 1573-2932.

JOHNSON, D. Barrie a Kevin B. HALLBERG, 2005. Acid mine drainage remediation options: a review. *Science of The Total Environment* [online]. 338(1–2), 3–14. ISSN 0048-9697. Dostupné z: doi:10.1016/j.scitotenv.2004.09.002

KANDARE, Kaja, Michele DALPONTE, Hans Ole ØRKA, Lorenzo FRIZZERA a Erik NÆSSET, 2017. Prediction of Species-Specific Volume Using Different Inventory Approaches by Fusing Airborne Laser Scanning and Hyperspectral Data. *Remote Sensing* [online]. 9(5), 400. ISSN 1032-9714. Dostupné z: doi:10.3390/rs9050400

KE, Yinghai, Lindi J. QUACKENBUSH a Jungho IM, 2010. Synergistic use of QuickBird multispectral imagery and LIDAR data for object-based forest species classification. *Remote Sensing of Environment* [online]. 114(6), 1141–1154. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2010.01.002

KER, M. F., 1980. *Tree biomass equations for ten major species in Cumberland County, Nova Scotia* [online]. Information report M-X-108. B.m.: Maritimes Forest Research Centre [vid. 2018-06-30]. Dostupné z: <https://cfs.nrcan.gc.ca/publications?id=7731>

KNIGHT, D., P. W. ELLIOTT, J. M. ANDERSON a D. SCHOLEFIELD, 1992. The role of earthworms in managed, permanent pastures in Devon, England. *Soil Biology and Biochemistry* [online]. 24(12), 1511–1517. ISSN 0038-0717. Dostupné z: doi:10.1016/0038-0717(92)90142-K

KÖHL, Michael, Rodel LASCO, Miguel CIFUENTES, Örjan JONSSON, Kari T. KORHONEN, Philip MUNDHENK, Jose DE JESUS NAVAR a Graham STINSON, 2015. Changes in forest production, biomass and carbon: Results from the 2015 UN FAO Global Forest Resource Assessment. *Forest Ecology and Management* [online]. 352, Changes in Global Forest Resources from 1990 to 2015, 21–34. ISSN 0378-1127. Dostupné z: doi:10.1016/j.foreco.2015.05.036

KORPELA, Ilkka, Hans Ole ØRKA, Matti MALTAMO, Timo TOKOLA, Juha HYYPÄ a OTHERS, 2010. Tree species classification using airborne LiDAR—effects of stand and tree parameters, downsizing of training set, intensity normalization, and sensor type. *Silva Fennica*. 44(2), 319–339. ISSN 2242-4075.

KRISTENSEN, Terje, Erik NÆSSET, Mikael OHLSON, Paul V. BOLSTAD a Randall KOLKA, 2015. Mapping Above- and Below-Ground Carbon Pools in Boreal Forests: The Case for Airborne Lidar. *PLOS ONE* [online]. 10(10), e0138450. ISSN 1932-6203. Dostupné z: doi:10.1371/journal.pone.0138450

KŘÍBEK, B a H. MACUROVÁ, 1996. Weathering effects on the agrochemical properties of rock deposited in coal-mine spoil banks, tips and quarry dumpings. In: B KŘÍBEK, ed. *Weathering of Fossil Organic Matter*. Prague: Czech Geological Survey. ISBN 80-7075-237-8.

KUMAR, Pavan, Prem Chandra PANDEY, B. K. SINGH, Swati KATIYAR, V. P. MANDAL, Meenu RANI, Vandana TOMAR a Shashikanta PATAIRIYA, 2016. Estimation of accumulated soil organic carbon stock in tropical forest using geospatial strategy. *The Egyptian Journal of Remote Sensing and Space Science* [online]. 19(1), 109–123. ISSN 1110-9823. Dostupné z: doi:10.1016/j.ejrs.2015.12.003

KUMAR, Sanjoy, Subodh Kumar MAITI a Subrato CHAUDHURI, 2015. Soil development in 2–21 years old coalmine reclaimed spoil with trees: A case study from Sonapur-Bazari opencast project, Raniganj Coalfield, India. *Ecological Engineering* [online]. 84, 311–324. ISSN 0925-8574. Dostupné z: doi:10.1016/j.ecoleng.2015.09.043

KURÁŽ, V., J. FROUZ, M. KURÁŽ, A. MAKO, V. SHUSTR, J. CEJPEK, O. V. ROMANOV a E. V. ABAKUMOV, 2012. Changes in some physical properties of soils in the chronosequence of self-overgrown dumps of the Sokolov quarry-dump complex, Czechia. *Eurasian Soil Science* [online]. 45(3), 266–272. ISSN 1064-2293, 1556-195X. Dostupné z: doi:10.1134/S1064229312030076

KUTER, Nazan, 2013. Reclamation of Degraded Landscapes due to Opencast Mining. In: Murat OZYAVUZ, ed. *Advances in Landscape Architecture* [online]. B.m.: InTech [vid. 2015-07-19]. ISBN 978-953-51-1167-2. Dostupné z: <http://www.intechopen.com/books/advances-in-landscape-architecture/reclamation-of-degraded-landscapes-due-to-opencast-mining>

KWAK, Doo-Ahn, Woo-Kyun LEE, Jun-Hak LEE, Greg S. BIGING a Peng GONG, 2007. Detection of individual trees and estimation of tree height using LiDAR data. *Journal of Forest Research* [online]. 12(6), 425–434. ISSN 1341-6979, 1610-7403. Dostupné z: doi:10.1007/s10310-007-0041-9

LATIFI, Hooman, Fabian FASSNACHT a Barbara KOCH, 2012. Forest structure modeling with combined airborne hyperspectral and LiDAR data. *Remote Sensing of Environment* [online]. 121, 10–25. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2012.01.015

LAWRENCE, Rick a M. LABUS, 2003. Early detection of Douglas-fir beetle infestation with subcanopy resolution hyperspectral imagery. *Western Journal of Applied Forestry*. 18(3), 202–206. ISSN 1938-3770.

LE MAIRE, Gueric, Christophe FRANÇOIS, Kamel SOUDANI, Daniel BERVEILLER, Jean-Yves PONTAILLER, Nathalie BRÉDA, Hélène GENET, Hendrik DAVI a Eric DUFRÊNE, 2008. Calibration and validation of hyperspectral indices for the estimation of broadleaved forest leaf chlorophyll content, leaf mass per area, leaf area index and leaf canopy biomass. *Remote Sensing of Environment* [online]. 112(10), 3846–3864. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2008.06.005

LEFSKY, M. A., W. B. COHEN, S. A. ACKER, G. G. PARKER, T. A. SPIES a D. HARDING, 1999. Lidar Remote Sensing of the Canopy Structure and Biophysical Properties of Douglas-Fir Western Hemlock Forests. *Remote Sensing of Environment* [online]. 70(3), 339–361. ISSN 0034-4257. Dostupné z: doi:http://dx.doi.org/10.1016/S0034-4257(99)00052-8

LEI, Yang, Robert TREUHAFT, Michael KELLER, Maiza DOS-SANTOS, Fabio GONÇALVES a Maxim NEUMANN, 2018. Quantification of selective logging in tropical forest with spaceborne SAR interferometry. *Remote Sensing of Environment* [online]. 211, 167–183. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2018.04.009

LI, Wang, Zheng NIU, Xinlian LIANG, Zengyuan LI, Ni HUANG, Shuai GAO, Cheng WANG a Shakir MUHAMMAD, 2015. Geostatistical modeling using LiDAR-derived prior knowledge with SPOT-6 data to estimate temperate forest canopy cover and above-ground biomass via stratified random sampling. *International Journal of Applied Earth Observation and Geoinformation* [online]. 41, 88–98. ISSN 0303-2434. Dostupné z: doi:10.1016/j.jag.2015.04.020

LU, Dengsheng, Emilio MORAN a Mateus BATISTELLA, 2003. Linear mixture model applied to Amazonian vegetation classification. *Remote Sensing of Environment* [online]. 87(4), Large Scale Biosphere Atmosphere Experiment in Amazonia, 456–469. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2002.06.001

LUO, Shezhou, Cheng WANG, Xiaohuan XI, Feifei PAN, Dailiang PENG, Jie ZOU, Sheng NIE a Haiming QIN, 2017. Fusion of airborne LiDAR data and hyperspectral imagery for aboveground and belowground forest biomass estimation. *Ecological Indicators* [online]. 73, 378–387. ISSN 1470-160X. Dostupné z: doi:10.1016/j.ecolind.2016.10.001

MALTAMO, Matti, P. PACKALÉN, J. PEUHKURINEN, A. SUVANTO, A. PESONEN a J. HYYPPÄ, 2007. Experiences and possibilities of ALS based forest inventory in Finland. In: *Proceedings of the ISPRS Workshop on Laser Scanning* [online]. s. 270–

279 [vid. 2016-05-22]. Dostupné z: https://www.researchgate.net/profile/Juha_Hyyppae/publication/228374430_Experiences_and_possibilities_of_ALS_based_forest_inventory_in_Finland/links/0c9605295c6308108b000000.pdf

MAN, Qixia, Pinliang DONG, Huadong GUO, Guang LIU a Runhe SHI, 2014. Light detection and ranging and hyperspectral data for estimation of forest biomass: a review. *Journal of Applied Remote Sensing* [online]. 8(1), 081598–081598. ISSN 1931-3195. Dostupné z: doi:10.1117/1.JRS.8.081598

MARKLUND, Lars Gunnar, 1988. *Biomassfunktioner för tall, gran och björk i Sverige: Biomass functions for pine, spruce and birch in Sweden*. Rapport / Sveriges lantbruksuniversitet, Institutionen för skogstaxering, 0348-0496; 45. ISBN 978-91-576-3524-2.

MARSCHALKO, Marian, Işık YILMAZ, Martin BEDNÁRIK a Karel KUBEČKA, 2012. Deformation of slopes as a cause of underground mining activities: three case studies from Ostrava–Karviná coal field (Czech Republic). *Environmental Monitoring and Assessment* [online]. 184(11), 6709–6733. ISSN 0167-6369, 1573-2959. Dostupné z: doi:10.1007/s10661-011-2453-4

MATHUR, A., L. M. BRUCE a J. BYRD, 2002. Discrimination of subtly different vegetative species via hyperspectral data. In: *IEEE International Geoscience and Remote Sensing Symposium: IEEE International Geoscience and Remote Sensing Symposium* [online]. s. 805–807 roč.2. Dostupné z: doi:10.1109/IGARSS.2002.1025692

MCGLYNN, Ian O. a Gregory S. OKIN, 2006. Characterization of shrub distribution using high spatial resolution remote sensing: Ecosystem implications for a former Chihuahuan Desert grassland. *Remote Sensing of Environment* [online]. 101(4), 554–566. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2006.01.016

MELILLO, Jerry M., John D. ABER a John F. MURATORE, 1982. Nitrogen and Lignin Control of Hardwood Leaf Litter Decomposition Dynamics. *Ecology* [online]. 63(3), 621–626. ISSN 1939-9170. Dostupné z: doi:10.2307/1936780

MENG, Xuelian, Nate CURRIT a Kaiguang ZHAO, 2010. Ground Filtering Algorithms for Airborne LiDAR Data: A Review of Critical Issues. *Remote Sensing* [online]. 2(3), 833–860. ISSN 1032-9714. Dostupné z: doi:10.3390/rs2030833

MEYER, David, 2017. *Support Vector Machines*. 2017. B.m.: FH Technikum Wien.

MOHR, S.H., J. WANG, G. ELLEM, J. WARD a D. GIURCO, 2015. Projection of world fossil fuels by country. *Fuel* [online]. 141, 120–135. ISSN 0016-2361. Dostupné z: doi:10.1016/j.fuel.2014.10.030

MONGILLO, Michael, 2011. *Choosing Basis Functions and Shape Parameters for Radial Basis Function Methods* [online]. 2011. B.m.: Society for Industrial and Applied Mathematics. [vid. 2018-08-07]. Dostupné z: <http://www.siam.org/students/siuro/vol4/S01084.pdf>

MORELLOS, Antonios, Xanthoula-Eirini PANTAZI, Dimitrios MOSHOU, Thomas ALEXANDRIDIS, Rebecca WHETTON, Georgios TZIOTZIOS, Jens WIEBENSOHN, Ralf BILL a Abdul M. MOUAZEN, 2016. Machine learning based prediction of soil total nitrogen, organic carbon and moisture content by using VIS-NIR spectroscopy. *Biosystems Engineering* [online]. 152, Proximal Soil Sensing – Sensing Soil Condition and Functions, 104–116. ISSN 1537-5110. Dostupné z: doi:10.1016/j.biosystemseng.2016.04.018

MORENO-DE LAS HERAS, M., 2009. Development of soil physical structure and biological functionality in mining spoils affected by soil erosion in a Mediterranean-Continental environment. *Geoderma* [online]. 149(3), 249–256. ISSN 0016-7061. Dostupné z: doi:10.1016/j.geoderma.2008.12.003

MORGENROTH, Gerhard, Wolfgang KRETSCHMER, Andreas SCHARF, Thomas UHL, Ulrich FETTWEIS, Oliver BENS a Reinhard F HÜTTL, 2004. ¹⁴C measurement of soil in post-mining landscapes. *Nuclear Instruments and Methods in Physics Research Section B: Beam Interactions with Materials and Atoms* [online]. 223–224, Proceedings of the Ninth International Conference on Accelerator Mass Spectrometry, 568–572. ISSN 0168-583X. Dostupné z: doi:10.1016/j.nimb.2004.04.105

MORRA, M. J., M. H. HALL a L. L. FREEBORN, 1991. Carbon and Nitrogen Analysis of Soil Fractions Using Near-Infrared Reflectance Spectroscopy. *Soil Science Society of America Journal* [online]. 55(1), 288–291. ISSN 0361-5995. Dostupné z: doi:10.2136/sssaj1991.03615995005500010051x

MUUKKONEN, P., 2007. Generalized allometric volume and biomass equations for some tree species in Europe. *European Journal of Forest Research* [online]. 126(2), 157–166. ISSN 1612-4669, 1612-4677. Dostupné z: doi:10.1007/s10342-007-0168-4

MUUKKONEN, P. a J. HEISKANEN, 2007. Biomass estimation over a large area based on standwise forest inventory data and ASTER and MODIS satellite data: A possibility to verify carbon inventories. *Remote Sensing of Environment* [online]. 107(4), 617–624. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2006.10.011

MUUKKONEN, Petteri, Margareeta HÄKKINEN a Raisa MÄKIPÄÄ, 2009. Spatial variation in soil carbon in the organic layer of managed boreal forest soil—implications for sampling design. *Environmental Monitoring and Assessment* [online]. 158(1–4), 67–76. ISSN 0167-6369, 1573-2959. Dostupné z: doi:10.1007/s10661-008-0565-2

NOVOTNÝ, J, 2014. Tree crown delineation using region growing and active contour: Approach introduction. *Mendel*. 2014, 213–216.

OLSOY, P. J., J. S. FORBEY, J. L. RACHLOW, J. D. NOBLER, N. F. GLENN a L. A. SHIPLEY, 2015. Fearscape: Mapping Functional Properties of Cover for Prey with Terrestrial LiDAR. *BioScience* [online]. 65(1), 74–80. ISSN 0006-3568, 1525-3244. Dostupné z: doi:10.1093/biosci/biu189

PACHAURI, Rajendra K., ed., 2008. *Climate change 2007: contribution of ... to the fourth assessment report of the Intergovernmental Panel on Climate Change. 4: Synthesis report: [a report of the Intergovernmental Panel on Climate Change]*. Geneva: IPCC. ISBN 978-92-9169-122-7.

PATENAUDE, Genevieve, Ronald MILNE a Terence P. DAWSON, 2005. Synthesis of remote sensing approaches for forest carbon estimation: reporting to the Kyoto Protocol. *Environmental Science & Policy* [online]. 8(2), 161–178. ISSN 1462-9011. Dostupné z: doi:10.1016/j.envsci.2004.12.010

PEDREGOSA, Fabian, Gaël VAROQUAUX, Alexandre GRAMFORT, Vincent MICHEL, Bertrand THIRION, Olivier GRISEL, Mathieu BLONDEL, Peter PRETTENHOFER, Ron WEISS, Vincent DUBOURG, Jake VANDERPLAS, Alexandre PASSOS, David COURNAPEAU, Matthieu BRUCHER, Matthieu PERROT a Édouard DUCHESNAY, 2011. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*. 12(Oct), 2825–2830. ISSN 1533-7928.

PEÑA, Marco A., Pablo CRUZ a Miguel ROIG, 2013. The effect of spectral and spatial degradation of hyperspectral imagery for the Sclerophyll tree species classification. *International Journal of Remote Sensing* [online]. 34(20), 7113–7130. ISSN 0143-1161. Dostupné z: doi:10.1080/01431161.2013.817712

PERSKI, Zbigniew, 1998. Applicability of ERS-1 and ERS-2 InSAR for land subsidence monitoring in the Silesian coal mining region, Poland. *International Archives of Photogrammetry and Remote Sensing*. 32, 555–558.

PEŠEK, Jiří, Josef ADÁMEK, Rostislav BRZOBOHATÝ, Miroslav BUBÍK, Ivan CICHÁ, Jiřina DAŠKOVÁ, Nela DOLÁKOVÁ, Antonín ELZNIC, Šárka HLADILOVÁ, Katarína HOLCOVÁ, Josef HONĚK, Kerstin HOŇKOVÁ KERSTIN, Jiří KRÁSNÝ, Oldřich KREJČÍ, Jiří KVAČEK, Zlatko KVAČEK, Vlastimil MACŮREK, Stanislav OPLUŠTIL, Mikuláš RADEK, Peter PÁLENSKÝ, Petr ROJÍK, Petr SKUPIEN, Jiří SPUDIL, Ivana SÝKOROVÁ, Jan ŠIKULA, Lilian ŠVÁBENICKÁ, Vasilis TEODORIDIS, František TITL, Pavla TOMANOVÁ-PETROVÁ, Jaromír ULRYCH, Juraj FRANCŮ, Oldřich FEJFAR a Zuzana JURKOVÁ, 2010. *Terciérní pánve a ložiska hnědého uhlí České republiky* [online]. B.m.: Česká geologická služba [vid. 2018-07-04]. ISBN 978-80-7075-759-8. Dostupné z: <https://is.muni.cz/publication/929397>

PETERSON, Birgit, Ralph DUBAYAH, Peter HYDE, Michelle HOFTON, J. Bryan BLAIR a JoAnn FITES-KAUFMAN, 2005. Use of LIDAR for forest inventory and forest management application. In: *Seventh Annual Forest Inventory and Analysis Symposium* [online]. [vid. 2016-05-22]. Dostupné z: <http://www.treesearch.fs.fed.us/pubs/30425>

PRACH, Karel, Klára ŘEHOUNKOVÁ, Jiří ŘEHOUNEK a Petra KONVALINKOVÁ, 2011. Ecological Restoration of Central European Mining Sites: A Summary of a Multi-site Analysis. *Landscape Research* [online]. 36(2), 263–268. ISSN 0142-6397, 1469-9710. Dostupné z: doi:10.1080/01426397.2010.547571

- PRETZSCH, Hans, Peter BIBER, Enno UHL, Jens DAHLHAUSEN, Thomas RÖTZER, Juan CALDENTY, Takayoshi KOIKE, Tran VAN CON, Aurélia CHAVANNE, Thomas SEIFERT, Ben du TOIT, Craig FARNDEN a Stephan PAULEIT, 2015. Crown size and growing space requirement of common tree species in urban centres, parks, and forests. *Urban Forestry & Urban Greening* [online]. 14(3), 466–479. ISSN 1618-8667. Dostupné z: doi:10.1016/j.ufug.2015.04.006
- RASEL, S. M. M., T. A. GROEN, Y. A. HUSSIN a I. J. DITI, 2017. Proxies for soil organic carbon derived from remote sensing. *International Journal of Applied Earth Observation and Geoinformation* [online]. 59, 157–166. ISSN 0303-2434. Dostupné z: doi:10.1016/j.jag.2017.03.004
- REINEKE, L. H., 1933. PERFECTING A STAND-DENSITY INDEX FOR EVEN-AGED FORESTS. *Journal of Agricultural Research*. 46(7), 627–638. ISSN 0095-9758.
- REUTEBUCH, Stephen E, Robert J MCGAUGHEY, Hans-Erik ANDERSEN a Ward W CARSON, 2003. Accuracy of a high-resolution lidar terrain model under a conifer forest canopy. *Canadian Journal of Remote Sensing* [online]. 29(5), 527–535. ISSN 0703-8992, 1712-7971. Dostupné z: doi:10.5589/m03-022
- ROCK, Joachim, 2007. Suitability of published biomass equations for aspen in Central Europe—Results from a case study. *Biomass and Bioenergy* [online]. 31(5), 299–307. ISSN 0961-9534. Dostupné z: doi:10.1016/j.biombioe.2007.01.003
- ROOTS, Betty I., 1956. The Water Relations of Earthworms: II. Resistance to Desiccation and Immersion, and Behaviour When Submerged and When Allowed a Choice of Environment. *Journal of Experimental Biology*. 33(1), 29–44. ISSN 0022-0949, 1477-9145.
- ROUSSEL, Jean-Romain, John CASPERSEN, Martin BÉLAND, Sean THOMAS a Alexis ACHIM, 2017. Removing bias from LiDAR-based estimates of canopy height: Accounting for the effects of pulse density and footprint size. *Remote Sensing of Environment* [online]. 198, 1–16. ISSN 0034-4257. Dostupné z: doi:10.1016/j.rse.2017.05.032
- ROY, P. S. a Shirish A. RAVAN, 1996. Biomass estimation using satellite remote sensing data—an investigation on possible approaches for natural forest. *Journal of Biosciences*. 21(4), 535–561. ISSN 0973-7138.
- RUMPEL, C., I. KÖGEL-KNABNER a R. F. HÜTTL, 1999. Organic matter composition and degree of humification in lignite-rich mine soils under a chronosequence of pine. *Plant and Soil* [online]. 213(1–2), 161–168. ISSN 0032-079X, 1573-5036. Dostupné z: doi:10.1023/A:1004454826537
- SALES, Marcio H., Carlos M. SOUZA, Phaedon C. KYRIAKIDIS, Dar A. ROBERTS a Edson VIDAL, 2007. Improving spatial distribution estimation of forest biomass with geostatistics: A case study for Rondônia, Brazil. *Ecological Modelling* [online]. 205(1), 221–230. ISSN 0304-3800. Dostupné z: doi:10.1016/j.ecolmodel.2007.02.033

SARIYILDIZ, T. a J. M. ANDERSON, 2005. Variation in the chemical composition of green leaves and leaf litters from three deciduous tree species growing on different soil types. *Forest Ecology and Management* [online]. 210(1), 303–319. ISSN 0378-1127. Dostupné z: doi:10.1016/j.foreco.2005.02.043

SASTRY, V.R., K. Ram CHANDAR, K.V. NAGESHA, E. MURALIDHAR a Md. Shoeb MOHIUDDIN, 2015. Prediction and Analysis of Dust Dispersion from Drilling Operation in Opencast Coal Mines. *Procedia Earth and Planetary Science* [online]. 11, 303–311. ISSN 1878-5220. Dostupné z: doi:10.1016/j.proeps.2015.06.065

SEIBERT, Jan, Johan STENDAHL a Rasmus SØRENSEN, 2007. Topographical influences on soil properties in boreal forests. *Geoderma* [online]. 141(1), 139–148. ISSN 0016-7061. Dostupné z: doi:10.1016/j.geoderma.2007.05.013

SHAFRI, Helmi ZM, Affendi SUHAILI a Shattri MANSOR, 2007. The performance of maximum likelihood, spectral angle mapper, neural network and decision tree classifiers in hyperspectral image analysis. *Journal of Computer Science*. 3(6), 419. ISSN 1552-6607.

SHEEREN, David, Mathieu FAUVEL, Veliborka JOSIPOVIĆ, Mailys LOPES, Carole PLANQUE, Jérôme WILLM a Jean-François DEJOUX, 2016. Tree Species Classification in Temperate Forests Using Formosat-2 Satellite Image Time Series. *Remote Sensing* [online]. 8(9), 734. ISSN 2072-4292. Dostupné z: doi:10.3390/rs8090734

SHERIDAN, Ryan, Sorin POPESCU, Demetrios GATZIOLIS, Cristine MORGAN a Nian-Wei KU, 2014. Modeling Forest Aboveground Biomass and Volume Using Airborne LiDAR Metrics and Forest Inventory and Analysis Data in the Pacific Northwest. *Remote Sensing* [online]. 7(1), 229–255. ISSN 2072-4292. Dostupné z: doi:10.3390/rs70100229

SHI, Lei a Shirong LIU, 2017. Methods of Estimating Forest Biomass: A Review. In: Jaya Shankar TUMULURU, ed. *Biomass Volume Estimation and Valorization for Energy* [online]. B.m.: InTech [vid. 2018-04-16]. ISBN 978-953-51-2937-0. Dostupné z: doi:10.5772/65733

SHRESTHA, Raj K. a Rattan LAL, 2010. Carbon and nitrogen pools in reclaimed land under forest and pasture ecosystems in Ohio, USA. *Geoderma* [online]. 157(3), 196–205. ISSN 0016-7061. Dostupné z: doi:10.1016/j.geoderma.2010.04.013

SCHÄDEL, Christina, Martin K.-F. BADER, Edward A. G. SCHUUR, Christina BIASI, Rosvel BRACHO, Petr ČAPEK, Sarah De BAETS, Kateřina DIÁKOVÁ, Jessica ERNAKOVICH, Cristian ESTOP-ARAGONES, David E. GRAHAM, Iain P. HARTLEY, Colleen M. IVERSEN, Evan KANE, Christian KNOBLAUCH, Massimo LUPASCU, Pertti J. MARTIKAINEN, Susan M. NATALI, Richard J. NORBY, Jonathan A. O'DONNELL, Taniya Roy CHOWDHURY, Hana ŠANTRŮČKOVÁ, Gaius SHAVER, Victoria L. SLOAN, Claire C. TREAT, Merritt R. TURETSKY, Mark P. WALDROP a Kimberly P. WICKLAND, 2016. Potential carbon emissions dominated

by carbon dioxide from thawed permafrost soils. *Nature Climate Change* [online]. 6(10), 950–953. ISSN 1758-6798. Dostupné z: doi:10.1038/nclimate3054

SCHUMACHER, Brian A., 2002. *Methods for the determination of total organic carbon (TOC) in soils and sediments* [online]. 2002. B.m.: United States Environmental Protection Agency. Dostupné z: [https://www.researchgate.net/profile/Daniel_Plaza-Bonilla/post/](https://www.researchgate.net/profile/Daniel_Plaza-Bonilla/post/What_would_be_the_best_method_for_soil_organic_C_measurement_having_1_higher_carbonate_and_2_higher_sand_content/attachment/59d61dfd79197b807797c5c1/AS:274579868352514@1442476350438/download/bs116.pdf)

[What_would_be_the_best_method_for_soil_organic_C_measurement_having_1_higher_carbonate_and_2_higher_sand_content/attachment/59d61dfd79197b807797c5c1/AS:274579868352514@1442476350438/download/bs116.pdf](https://www.researchgate.net/profile/Daniel_Plaza-Bonilla/post/What_would_be_the_best_method_for_soil_organic_C_measurement_having_1_higher_carbonate_and_2_higher_sand_content/attachment/59d61dfd79197b807797c5c1/AS:274579868352514@1442476350438/download/bs116.pdf)

SIBONA, Emanuele, Alessandro VITALI, Fabio MELONI, Lucia CAFFO, Alberto DOTTA, Emanuele LINGUA, Renzo MOTTA a Matteo GARBARINO, 2016. Direct Measurement of Tree Height Provides Different Results on the Assessment of LiDAR Accuracy. *Forests* [online]. 8(1), 7. ISSN 1999-4907. Dostupné z: doi:10.3390/f8010007

SIMARD, Marc, Naiara PINTO, Joshua B. FISHER a Alessandro BACCINI, 2011. Mapping forest canopy height globally with spaceborne lidar. *Journal of Geophysical Research* [online]. 116(G4) [vid. 2016-05-17]. ISSN 0148-0227. Dostupné z: doi:10.1029/2011JG001708

SKARŻYŃSKA, Krystyna M., 1995. Reuse of coal mining wastes in civil engineering — Part 1: Properties of minestone. *Waste Management* [online]. 15(1), 3–42. ISSN 0956-053X. Dostupné z: doi:10.1016/0956-053X(95)00004-J

SNORRASON, Arnór a Stefán Freyr EINARSSON, 2006. Single-tree biomass and stem volume functions for eleven tree species used in Icelandic forestry. *Icelandic Agricultural Sciences*. 19, 15–24. ISSN 1670-567X.

SONOBE, Rei, Hiroshi TANI, Xiufeng WANG, Nobuyuki KOBAYASHI a Hideki SHIMAMURA, 2014. Random forest classification of crop type using multi-temporal TerraSAR-X dual-polarimetric data. *Remote Sensing Letters* [online]. 5(2), 157–164. ISSN 2150-704X. Dostupné z: doi:10.1080/2150704X.2014.889863

STENBERG, Bo, Raphael A. VISCARRA ROSSEL, Abdul Mounem MOUAZEN a Johanna WETTERLIND, 2010. Visible and Near Infrared Spectroscopy in Soil Science. In: Donald L. SPARKS, ed. *Advances in Agronomy* [online]. B.m.: Academic Press, s. 163–215 [vid. 2017-02-08]. Dostupné z: doi:10.1016/S0065-2113(10)07005-7

STOFFELS, Johannes, Joachim HILL, Thomas SACHTLEBER, Sebastian MADER, Henning BUDDENBAUM, Oksana STERN, Joachim LANGSHAUSEN, Jürgen DIETZ a Godehard ONTRUP, 2015. Satellite-Based Derivation of High-Resolution Forest Information Layers for Operational Forest Management. *Forests* [online]. 6(6), 1982–2013. ISSN 1999-4907. Dostupné z: doi:10.3390/f6061982

STRNAD, M a B KŘÍBEK, 1996. Changes of Rock-Eval pyrolysis results during the natural weathering of fossil organic matter in spoil banks and heaps of mines. In: B KŘÍBEK, ed. *Weathering of Fossil Organic Matter*. Prague: Czech Geological Survey. ISBN 80-7075-237-8.

ŠNAJDR, Jaroslav, Petra DOBIÁŠOVÁ, Michaela URBANOVÁ, Mirka PETRÁNKOVÁ, Tomáš CAJTHAML, Jan FROUZ a Petr BALDRIAN, 2013. Dominant trees affect microbial community composition and activity in post-mining afforested soils. *Soil Biology and Biochemistry* [online]. 56, Special Issue: Interactions of Soil Minerals with Organic Components and Microorganisms VII and Enzymes in the Environment IV, 105–115. ISSN 0038-0717. Dostupné z: doi:10.1016/j.soilbio.2012.05.004

TANIGUCHI, Shin-ichi, 1961. Forest inventory by aerial photographs. *RESEARCH BULLETINS OF THE COLLEGE EXPERIMENT FORESTS HOKKAIDO UNIVERSITY*. 21(1), 1–80.

TER-MIKAELIAN, Michael T. a Michael D. KORZUKHIN, 1997. Biomass equations for sixty-five North American tree species. *Forest Ecology and Management* [online]. 97(1), 1–24. ISSN 0378-1127. Dostupné z: doi:10.1016/S0378-1127(97)00019-4

THOMLINSON, John R, Paul V BOLSTAD a Warren B COHEN, 1999. Coordinating Methodologies for Scaling Landcover Classifications from Site-Specific to Global: Steps toward Validating Global Map Products. *Remote Sensing of Environment* [online]. 70(1), 16–28. ISSN 0034-4257. Dostupné z: doi:10.1016/S0034-4257(99)00055-3

TOAN, Thuy, Shaun QUEGAN, Ian WOODWARD, Mark LOMAS, Nicolas DELBART a Ghislain PICARD, 2004. Relating Radar Remote Sensing of Biomass to Modelling of Forest Carbon Budgets. *Climatic Change* [online]. 67(2–3), 379–402. ISSN 0165-0009. Dostupné z: doi:10.1007/s10584-004-3155-5

TOMPALSKI, Piotr, Nicholas C. COOPS, Joanne C. WHITE a Michael A. WULDER, 2014. Simulating the impacts of error in species and height upon tree volume derived from airborne laser scanning data. *Forest Ecology and Management* [online]. 327, 167–177. ISSN 0378-1127. Dostupné z: doi:10.1016/j.foreco.2014.05.011

TSUI, Chun-Chih, Zueng-Sang CHEN a Chang-Fu HSIEH, 2004. Relationships between soil properties and slope position in a lowland rain forest of southern Taiwan. *Geoderma* [online]. 123(1), 131–142. ISSN 0016-7061. Dostupné z: doi:10.1016/j.geoderma.2004.01.031

TURNER, David P., Michael GUZY, Michael A. LEFSKY, William D. RITTS, Steve VAN TUYL a Beverly E. LAW, 2004. Monitoring Forest Carbon Sequestration with Remote Sensing and Carbon Cycle Modeling. *Environmental Management* [online]. 33(4) [vid. 2013-08-26]. ISSN 0364-152X, 1432-1009. Dostupné z: doi:10.1007/s00267-003-9103-8

TURSKI, Mieczysław, Cezary BEKER, Katarzyna KAZMIERCZAK a Tomasz NAJGRAKOWSKI, 2008. Allometric equations for estimating the mass and volume of fresh assimilational apparatus of standing scots pine (*Pinus sylvestris* L.) trees. *Forest Ecology and Management* [online]. 255(7), 2678–2687. ISSN 0378-1127. Dostupné z: doi:10.1016/j.foreco.2008.01.028

UTKIN, A.I., D.G. ZAMOLODCHIKOV, T.A. GUL'BE a Ya.I. GUL'BE, 1996. Allometric equations for phytomass based on the data on pine, birch and aspen trees in European Russia. *Lesovedenie*. (6), 36–46. ISSN 0024-1148.

UYSAL, M., A. S. TOPRAK a N. POLAT, 2015. DEM generation with UAV Photogrammetry and accuracy analysis in Sahitler hill. *Measurement* [online]. 73, 539–543. ISSN 0263-2241. Dostupné z: doi:10.1016/j.measurement.2015.06.010

VAGLIO LAURIN, Gaia, Qi CHEN, Jeremy A. LINDSELL, David A. COOMES, Fabio Del FRATE, Leila GUERRIERO, Francesco PIROTTI a Riccardo VALENTINI, 2014. Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. *ISPRS Journal of Photogrammetry and Remote Sensing* [online]. 89, 49–58. ISSN 0924-2716. Dostupné z: doi:10.1016/j.isprsjprs.2014.01.001

VAN LEEUWEN, Martin a Maarten NIEUWENHUIS, 2010. Retrieval of forest structural parameters using LiDAR remote sensing. *European Journal of Forest Research* [online]. 129(4), 749–770. ISSN 1612-4669, 1612-4677. Dostupné z: doi:10.1007/s10342-010-0381-4

VANGUELOVA, E. I., E. BONIFACIO, B. De VOS, M. R. HOOSBEEK, T. W. BERGER, L. VESTERDAL, K. ARMOLAITIS, L. CELI, L. DINCA, O. J. KJØNAAS, P. PAVLENDÁ, J. PUMPANEN, Ü PÜTTSEPP, B. REIDY, P. SIMONČIČ, B. TOBIN a M. ZHIYANSKI, 2016. Sources of errors and uncertainties in the assessment of forest soil carbon stocks at different scales—review and recommendations. *Environmental Monitoring and Assessment* [online]. 188(11), 630. ISSN 0167-6369, 1573-2959. Dostupné z: doi:10.1007/s10661-016-5608-5

VAPNIK, V., 1979. Estimation of Dependences Based on Empirical Data. *Nauka*. (27), 5165–5184.

VINDUŠKOVÁ, Olga, Václav DVOŘÁČEK, Anna PROHASKOVÁ a Jan FROUZ, 2014. Distinguishing recent and fossil organic matter — A critical step in evaluation of post-mining soil development – using near infrared spectroscopy. *Ecological Engineering* [online]. 73, 643–648. ISSN 0925-8574. Dostupné z: doi:10.1016/j.ecoleng.2014.09.086

VINDUŠKOVÁ, Olga a Jan FROUZ, 2013. Soil carbon accumulation after open-cast coal and oil shale mining in Northern Hemisphere: a quantitative review. *Environmental Earth Sciences* [online]. 69(5), 1685–1698. ISSN 1866-6299. Dostupné z: doi:10.1007/s12665-012-2004-5

VINDUŠKOVÁ, Olga, David SEBAG, Guillaume CAILLEAU, Jiří BRUS a Jan FROUZ, 2015. Methodological comparison for quantitative analysis of fossil and recently derived carbon in mine soils with high content of aliphatic kerogen. *Organic Geochemistry* [online]. 89–90, 14–22. ISSN 0146-6380. Dostupné z: doi:10.1016/j.orggeochem.2015.10.001

VISCARRA ROSSEL, R. A. a A. B. MCBRATNEY, 1998. Laboratory evaluation of a proximal sensing technique for simultaneous measurement of soil clay and water content. *Geoderma* [online]. 85(1), 19–39. ISSN 0016-7061. Dostupné z: doi:10.1016/S0016-7061(98)00023-8

VOGEL, J. S., J. R. SOUTHON, D. E. NELSON a T. A. BROWN, 1984. Performance of catalytically condensed carbon for use in accelerator mass spectrometry. *Nuclear Instruments and Methods in Physics Research Section B: Beam Interactions with Materials and Atoms* [online]. 5(2), 289–293. ISSN 0168-583X. Dostupné z: doi:10.1016/0168-583X(84)90529-9

VOSS, Matthew a Ramanathan SUGUMARAN, 2008. Seasonal Effect on Tree Species Classification in an Urban Environment Using Hyperspectral Data, LiDAR, and an Object- Oriented Approach. *Sensors* [online]. 8(5), 3020–3036. ISSN 1424-8220. Dostupné z: doi:10.3390/s8053020

WANG, Chuankuan, 2006. Biomass allometric equations for 10 co-occurring tree species in Chinese temperate forests. *Forest Ecology and Management* [online]. 222(1), 9–16. ISSN 0378-1127. Dostupné z: doi:10.1016/j.foreco.2005.10.074

WHITE, Joanne, CANADIAN FOREST SERVICE a CANADIAN WOOD FIBRE CENTRE, 2013. *A best practices guide for generating forest inventory attributes from airborne laser scanning data using the area-based approach*. ISBN 978-1-100-22385-8.

WIRTH, Christian, Jens SCHUMACHER a Ernst-Detlef SCHULZE, 2004. Generic biomass functions for Norway spruce in Central Europe—a meta-analysis approach toward prediction and uncertainty estimation. *Tree Physiology* [online]. 24(2), 121–139. ISSN 1758-4469. Dostupné z: doi:10.1093/treephys/24.2.121

WORLD ENERGY COUNCIL, 2013. Coal. In: *World Energy Resources: 2013 Survey*. London: World Energy Council. ISBN 978 0 946121 29 8.

YU, Xiaowei, Juha HYYPPÄ, Markus HOLOPAINEN a Mikko VASTARANTA, 2010. Comparison of Area-Based and Individual Tree-Based Methods for Predicting Plot-Level Forest Attributes. *Remote Sensing* [online]. 2(6), 1481–1495. ISSN 2072-4292. Dostupné z: doi:10.3390/rs2061481

YU, Xiaowei, Paula LITKEY, Juha HYYPPÄ, Markus HOLOPAINEN a Mikko VASTARANTA, 2014. Assessment of Low Density Full-Waveform Airborne Laser Scanning for Individual Tree Detection and Tree Species Classification. *Forests* [online]. 5(5), 1011–1031. ISSN 1999-4907. Dostupné z: doi:10.3390/f5051011

ZAVITKOVSKI, J., Allen L. LUNDGREN a Terry STRONG, 1983. *Biomass production of 4- to 9-year-old intensively cultured Larix eurolepis grown in* [online]. Research Paper NC-231. B.m.: U.S. Dept. of Agriculture, Forest Service [vid. 2018-06-30]. Dostupné z: <https://www.fs.usda.gov/treearch/pubs/10752>

ZHOU, Jianhua, Bailang YU a Jun QIN, 2014. Multi-Level Spatial Analysis for Change Detection of Urban Vegetation at Individual Tree Scale. *Remote Sensing* [online]. 6(9), 9086–9103. ISSN 2072-4292. Dostupné z: doi:10.3390/rs6099086

ZHOU, Wei, Ke YANG, Zhongke BAI, Hangxin CHENG a Fei LIU, 2017. The development of topsoil properties under different reclaimed land uses in the Pingshuo opencast coalmine of Loess Plateau of China. *Ecological Engineering* [online]. 100, 237–245. ISSN 0925-8574. Dostupné z: doi:10.1016/j.ecoleng.2016.12.028

9 Přílohy

Příloha 1: Klasifikace dřevin – Velká podkrušnohorská výsypka 2017

Příloha 2: Množství uhlíku nadzemní biomasy 2009

Příloha 3: Množství uhlíku nadzemní biomasy 2017

Příloha 4: Interpolace koncentrace půdního uhlíku A horizont - 2017

Příloha 5: Interpolace koncentrace půdního uhlíku C horizont - 2017

Příloha 6: Interpolace množství půdního uhlíku A horizont - 2017


Příloha 7: Interpolace množství půdního uhlíku A horizont – 2017; korigovaný $Chor_{radio}$

Příloha 8: Interpolace množství půdního uhlíku A horizont – 2017; korigovaný $Chor_{kribek}$


Příloha 9: Interpolace množství půdního uhlíku A horizont – 2017; korigovaný $Ahor_{radio}$

Klasifikace dřevin - Velká podkrušnohorská výsypka 2017


S
↑




Množství uhlíku nadzemní biomasy 2009




Množství uhlíku nadzemní biomasy 2017




Interpolace koncentrace půdního uhlíku A horizont - 2017




Inetrpolace koncentrace půdního uhlíku C horizont - 2017




Interpolace množství půdního uhlíku A horizont - 2017



Interpolace množství půdního uhlíku A horizont - 2017; korigovaný $\text{Chor}_{\text{radio}}$



Interpolace množství půdního uhlíku A horizont - 2017; korigovaný $\text{Chor}_{\text{kribek}}$



Interpolace množství půdního uhlíku A horizont - 2017; korigovaný $A_{hor_{radio}}$

