

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE
FAKULTA ŽIVOTNÍHO PROSTŘEDÍ
KATEDRA APLIKOVANÉ GEOINFORMATIKY A ÚZEMNÍHO PLÁNOVÁNÍ

Vliv struktury vegetace a terénu posttěžební lokality na druhovou diverzitu ptáků

DIPLOMOVÁ PRÁCE

Vedoucí práce: Ing. Vítězslav Moudrý, Ph.D.

Diplomant: Bc. Soňa Müllerová

2018

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Soňa Müllerová

Ochrana přírody

Název práce

Vliv struktury vegetace a terénu posttěžební lokality na druhovou diverzitu ptáků

Název anglicky

Effect of vegetation and terrain structure of post-mining site on bird species diversity

Cíle práce

Cílem diplomové práce je posoudit vliv struktury vegetace a terénu na Radovesické výsypce a v jejím blízkém okolí na druhovou diverzitu ptáků. Formulace dílčích cílů je úkolem autorky.

Metodika

Druhová diverzita je celosvětově ohrožena neustále rostoucími environmentálními změnami způsobenými člověkem. Abychom mohli druhy účinně chránit, je třeba znát jejich biotopové nároky. Nicméně sběr dat o struktuře biotopů je časově náročný a tudíž omezený svým prostorovým rozsahem. Současné metody dálkového průzkumu Země umožňují monitoring rozsáhlých oblastí a tím překonání omezení, které má terénní sběr dat. Mezi v poslední době často využívaná data patří bodová mračna získaná z leteckého laserového skenování, která umožňují detailní popis vertikální a horizontální struktury vegetace.

Úkolem autorky bude klasifikovat bodové mračno, vypočítat základní charakteristiky vegetace a terénu a s využitím techniky modelování druhové distribuce prozkoumat vztahy mezi vertikální a horizontální strukturou prostředí a druhovou diverzitou ptáků. Náplní literární rešerše bude zejména možné využití leteckého laserového skenování pro popis struktury vegetace a terénu a praktická aplikace v modelech druhové distribuce.

Doporučený rozsah práce

40 – 60 stran

Klíčová slova

Formulace klíčových slov je úkolem autora.

Doporučené zdroje informací

- Farrell, S. L., Collier, B. A., Skow, K. L., Long, A. M., Campomizzi, A. J., Morrison, M. L., ... & Wilkins, R. N. (2013). Using LiDAR-derived vegetation metrics for high-resolution, species distribution models for conservation planning. *Ecosphere*, 4(3), 1-18.
- Graf, R. F., Mathys, L., & Bollmann, K. (2009). Habitat assessment for forest dwelling species using LiDAR remote sensing: Capercaillie in the Alps. *Forest Ecology and Management*, 257(1), 160-167.
- Huber, N., Kienast, F., Ginzler, C., & Pasinelli, G. (2016). Using remote-sensing data to assess habitat selection of a declining passerine at two spatial scales. *Landscape ecology*, 31(9), 1919-1937.
- Müller, J., Stadler, J., & Brandl, R. (2010). Composition versus physiognomy of vegetation as predictors of bird assemblages: The role of lidar. *Remote Sensing of Environment*, 114(3), 490-495.
- Šálek, M. (2012). Spontaneous succession on opencast mining sites: implications for bird biodiversity. *Journal of Applied Ecology*, 49(6), 1417-1425.
- Vogeler, J. C., Hudak, A. T., Vierling, L. A., Evans, J., Green, P., & Vierling, K. T. (2014). Terrain and vegetation structural influences on local avian species richness in two mixed-conifer forests. *Remote sensing of environment*, 147, 13-22.

Předběžný termín obhajoby

2017/18 LS – FŽP

Vedoucí práce

Ing. Vítězslav Moudrý, Ph.D.

Garantující pracoviště

Katedra aplikované geoinformatiky a územního plánování

Elektronicky schváleno dne 17. 3. 2018

doc. Ing. Petra Šímová, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 18. 3. 2018

prof. RNDr. Vladimír Bejček, CSc.

Děkan

V Praze dne 16. 04. 2018

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně a uvedla všechny literární prameny a zdroje informací, ze kterých jsem čerpala.

V Praze dne 18. 4. 2018

.....

Poděkování

Na tomto místě bych ráda poděkovala zejména vedoucímu práce Ing. Vítězslavu Moudrému, Ph.D. za čas věnovaný konzultacím, pomoc při zpracování dat, vstřícný přístup a spolupráci. Děkuji také prof. Mgr. Miroslavu Šálkovi, Dr. a kolektivu za poskytnutí dat získaných z mapování ptačích druhů v oblasti Radovesické výsypky. Velké poděkování patří rovněž mým nejbližším za všestrannou podporu jak při tvorbě této práce, tak během celého studia.

Abstrakt

Úbytek biodiverzity a ztráta biotopů vlivem lidské činnosti je v současnosti celosvětově diskutovaným problémem. Souvisejícím kontroverzním tématem jsou území ovlivněná těžbou nerostných surovin, která s sebou často přináší významné změny v krajině. Ochrany přírody se dotýkají zejména tzv. posttěžební lokality, které mohou poskytovat vhodná stanoviště pro řadu druhů mizejících z okolní krajiny. Nezbytným předpokladem pro zajištění účinné ochrany diverzity druhů je znalost jejich biotopových nároků. Základním faktorem ovlivňujícím diverzitu v lokálním měřítku je heterogenita habitatu ve smyslu struktury vegetace a terénu, kterou lze využít také pro posouzení úspěšnosti ekologické obnovy. Terénní sběr takových dat je však obtížný, časově náročný a tedy prostorově omezený. Možné řešení představuje letecké laserové skenování jako jedna z moderních metod dálkového průzkumu Země umožňující sběr detailních prostorových dat, ze kterých lze s vysokou přesností odvozovat řadu charakteristik. Tato diplomová práce se zabývá využitím dat získaných z leteckého laserového skenování pro posouzení vlivu struktury prostředí na diverzitu ptačích druhů v oblasti Radovesické výsypky, která je jednou z největších posttěžebních lokalit České republiky. Cílem bylo provést klasifikaci bodového mračka, vytvořit digitální model terénu a model výšky vegetace, provést výpočet charakteristik vertikální a horizontální struktury vegetace a terénu a následně pomocí zobecněných lineárních modelů posoudit, které z charakteristik mohou být významnými prediktory diverzity ptačích druhů. Ukázalo se, že mezi proměnné vysvětlující nejvíce variability patří směrodatná odchylka výšky vegetace, densita vegetace v keřovém patře a celková pokrývnost. Z topografických charakteristik je patrně nejvýznamnější proměnnou směrodatná odchylka křivosti profilu, která dobře vystihuje členitost terénu. Výsledným modelem bylo vysvětleno 59 % variability, což lze považovat za vysokou hodnotu. Výsledky potvrzují, že data získaná z leteckého laserového skenování jsou dobře využitelná pro popis struktury prostředí posttěžební lokality a umožňují výpočet užitečných charakteristik, které mohou vysvětlovat zaznamenaný počet ptačích druhů.

Klíčová slova: LiDAR, struktura prostředí, ptáci, GLM, výsypky

Abstract

Problem of decreasing biodiversity and habitat loss due to human activities is currently discussed at global scale. Related controversial issue is represented by regions affected by mining, which results in considerable changes of landscape. In context of nature conservation, post-mining sites are often mentioned because of their potential promote suitable habitat for declining species. The primary prerequisite for efficient biodiversity conservation is knowledge of habitat requirements. Species richness is known to be primarily influenced by habitat heterogeneity in terms of vegetation and terrain structure, which is also used for assessing ecological restoration success. However, field collection of such data is quite difficult, time-consuming and thus spatially limited. Current progress of remote sensing methods such as airborne laser scanning enables collection of detailed spatial data which could be used for derivation of various habitat structure metrics. This diploma thesis presents utilization of airborne laser scanning data for assessing significance of habitat structure for bird species diversity on Radovesická spoil bank, which is one of the largest postmining sites in the Czech Republic. The aim was to classify point cloud data, create digital terrain model and canopy height model, compute variables of vegetation and terrain structure and explore the significance of these variables for diversity using generalized linear models. Results show that most variability was explained by standard deviation of vegetation height, vegetation density in shrub storey and total canopy cover. Most significant variable of topography is evidently standard deviation of profile curvature, which is good measure of terrain roughness. The resulting model explained 59 % of variability, which is considered to be high value. Airborne laser scanning data thus provide a useful source for measuring habitat structure of postmining site and enable derivation of many characteristic which can be good predictors of recorded bird species diversity.

Key words: LiDAR, habitat structure, birds, GLM, spoil banks

OBSAH

1. ÚVOD	1
2. LITERÁRNÍ REŠERŠE	3
2.1 Význam ALS v modelování druhové distribuce	3
2.2 Využití ALS pro popis struktury prostředí	5
2.2.1 Základní princip	5
2.2.2 Využití pro popis struktury vegetace	7
2.2.3 Využití pro popis struktury terénu	11
3. METODIKA	13
3.1 Charakteristika řešeného území	13
3.2 Charakteristika vstupních data	15
3.2.1 Nálezová data	15
3.2.2 Data získaná z leteckého laserového skenování	15
3.3 Použitý software	16
3.4 Zpracování dat	16
3.4.1 Úprava nálezových dat	16
3.4.2 Zpracování dat leteckého laserového skenování	17
3.5 Tvorba prediktorů	25
3.5.1 Charakteristiky vegetace	25
3.5.2 Charakteristiky terénu	27
3.6 Výběr prediktorů	30
3.7 Tvorba modelu	35
4. VÝSLEDKY	37
4.1 Analýza deviance a výběr prediktorů	37
4.2 Výběr modelu	40
4.3 Významnost prediktorů	41
5. DISKUZE	45
6. ZÁVĚR	48
7. POUŽITÁ LITERATURA	49
8. PŘÍLOHY	54

1. ÚVOD

Úbytek biodiverzity a ztráta biotopů vlivem lidské činnosti je v současnosti celosvětově diskutovaným problémem. Jedním ze souvisejících kontroverzních témat jsou území ovlivněná těžbou nerostných surovin, která s sebou často přináší významné změny v krajině. Ochrany přírody se nejvíce dotýkají tzv. posttěžební lokality, což jsou v rámci České republiky zejména výsypky vznikající v souvislosti s povrchovou těžbou hnědého uhlí (Prach 2009, Prach et al. 2009). Tato území představují velký potenciál pro nový rozvoj společenstev s vysokou biodiverzitou, zvláště jsou-li alespoň zčásti ponechána přirozenému vývoji, tzv. spontánní sukcesi. Tím mohou vzniknout refugia pro řadu druhů mizejících z okolní krajiny (Vojar et al. 2012). Příkladem z oblasti střední Evropy je výrazný úbytek ptačích druhů vázaných na dříve běžnou extenzivní zemědělskou krajinu, způsobený sníženou dostupností vhodných habitatů následkem intenzivního způsobu hospodaření (Šálek 2012). Právě ptáci jsou považováni za jednu z nejlepších skupin živočichů indikující efektivní ochranu a kvalitu ekosystémů a jsou proto předmětem zájmu mnoha studií (např. Goetz et al. 2007, Graf et al. 2009, Müller et al. 2010, Lesak et al. 2011, Šálek 2012, Vogeler et al. 2014, Huber et al. 2016).

Nezbytným předpokladem pro zajištění účinné ochrany diverzity druhů je znalost jejich biotopových nároků. Jedním ze základních faktorů ovlivňujících diverzitu v lokálním měřítku je heterogenita habitatu zahrnující v případě ptačích druhů zejména rozmanitost vegetace ve smyslu výšky či hustoty, kterou lze souhrnně popsat jako horizontální a vertikální strukturu porostu (Bradbury et al. 2005, Goetz et al. 2007, Eldegard et al. 2014). Struktura vegetace pak přímo závisí na lokální topografii terénu, kterou může v případě posttěžebních lokalit významně ovlivňovat realizovaný způsob rekultivace (Frouz et al. 2018). Význam struktury vegetace a terénu v souvislosti s diverzitou druhů byl potvrzen řadou studií a často se využívá právě za účelem zhodnocení úspěšnosti realizovaných opatření v rámci ekologické obnovy krajiny narušené těžbou nerostných surovin. Terénní sběr takových dat je však značně obtížný, časově náročný a tedy prostorově omezený (Graf et al. 2009, Müller et al. 2010). Možné efektivní řešení představují moderní metody dálkového průzkumu Země umožňující sběr detailních prostorových dat. Jednou z nich je letecké laserové skenování (*ALS, airborne laser scanning*), jehož prostřednictvím lze realizovat komplexní mapování rozsáhlých oblastí. Ze získaných trojrozměrných dat v podobě tzv. bodového mráčka je možné s vysokou přesností odvozovat celou řadu charakteristik popisujících jak horizontální, tak vertikální strukturu biotopů (Bergen et al. 2009, Evans et al. 2009, Huber et al. 2016).

Posouzení vlivu prostředí na druhovou diverzitu a distribuci umožňuje technika modelování druhové distribuce (SDM, *species distribution modelling*). Cílem je mimo jiné objasnění ekologických vztahů na základě nalezení klíčových proměnných, které distribuci nebo diverzitu ovlivňují a související porozumění ekologickým procesům (Elith et Leathwick 2009, Miller 2010, Pearson 2010). Pro vytvoření takového modelu je dnes dostupná řada modelovacích technik (Franklin 2009). Vhodnou variantou pro modelování druhové diverzity jsou často používané zobecněné lineární modely (GLMs), které patří mezi klasické statistické metody založené na lineární regresi (Šmilauer 2007, Zuur et al. 2009, Li et Wang 2013).

Přestože metody dálkového průzkumu Země nemohou ve všech případech zcela nahradit terénní průzkum, prokazatelně přispívají k poznání detailní struktury prostředí na rozsáhlých plochách, jako jsou právě posttěžební lokality, kde jsou tyto metody zatím využívány minimálně. V rámci této diplomové práce bude posouzen vliv struktury vegetace a terénu na druhovou diverzitu ptáků v oblasti Radovesické výsypky, která je největší vnější výsypkou na Mostecku a zároveň jednou z nejznámějších lokalit v souvislosti s ekologickou obnovou krajiny.

Cíle práce:

- (1) zpracovat poskytnutá data získaná z leteckého laserového skenování pokrývající území Radovesické výsypky a blízkého okolí, tzn. zejména
 - a) provést klasifikaci terénu,
 - b) provést klasifikaci vegetace a nadzemních objektů,
 - c) vytvořit digitální model terénu (*digital terrain model*) a model výšky vegetace (*canopy height model*),
- (2) provést výpočet charakteristik horizontální a vertikální struktury vegetace a terénu,
- (3) s využitím zobecněných lineárních modelů posoudit, které z charakteristik jsou významnými prediktory druhové diverzity ptáků v oblasti Radovesické výsypky.

2. LITERÁRNÍ REŠERŠE

2.1 Význam ALS v modelování druhové distribuce

Technika modelování druhové distribuce (SDM, *species distribution modelling*) je známa jako numerický nástroj hledající vztah mezi distribucí druhů a podmínkami prostředí. Klasický přístup spočívá v modelování distribuce jednotlivých druhů, kdy jsou vysvětlovanou proměnnou data o jejich výskytu (tzv. nálezová data), nejčastěji v podobě záznamů z konkrétních lokalit, která mohou být jak pouze prezenční (*presence-only*), tak tzv. *presence-absence* zahrnující ideálně také lokality s potvrzenou absencí. Druhou součástí modelů tvoří tzv. environmentální proměnné (prediktory), které vyjadřují různé podmínky prostředí, které distribuci potenciálně ovlivňují a jsou tedy v modelech proměnnými vysvětlujícími (Elith et Leathwick 2009, Miller 2010, Pearson 2010).

Uvedený základní princip vychází z teorie ekologické niky, kterou představil již Hutchinson (1957). Na niku pohlíží jako na část myšleného, n -rozměrného prostoru, ve kterém je druh schopen přežít, přičemž dimenze v tomto prostoru představují jednotlivé faktory prostředí ve formě environmentálních proměnných (Hutchinson 1957 in Miller 2010). Kromě řady variant modelování, pro které je tento princip základem, existují také případy, kde již teorie ekologické niky zcela relevantní není. Jednou z takových variant mohou být modely, ve kterých je vysvětlovanou proměnnou nikoli výskyt konkrétního druhu, ale druhová diverzita vyjádřená např. jako celkový počet druhů v určité oblasti (*species richness*) (Franklin 2009).

Mezi klíčové předpoklady pro vytvoření dobrého modelu patří získání kvalitních vstupních dat obou typů a zahrnutí všech důležitých environmentálních prediktorů ovlivňujících distribuci či diverzitu druhů (Lassueur et al. 2006, Elith et Leathwick 2009, Miller 2010). Zároveň by však neměla být pravidlem snaha zahrnout co nejvíce nejrůznějších proměnných, ale naopak jejich počet vhodně zvolenou metodou zredukovat a pro použití v modelu zvolit smysluplnou kombinaci pouze několika z nich. Výběr proměnných proto patří k nejobtížnějším krokům v celém procesu (Guissan et Zimmermann 2000). V případě, že jsou prediktory voleny pouze na základě dostupných dat a není uvažováno nad skutečnými nároky druhů, může dojít kromě snížení kvality vlastního modelu také k získání celkově nerelevantních výsledků (Franklin 2009, Pearson 2010, Austin et Van Niel 2011). Po splnění těchto podmínek by měl vytvořený model splňovat kritérium reálnosti, obecnosti a zároveň vysoké přesnosti (Guissan et Zimmermann 2000).

V případě ptačích druhů by mělo dojít k zahrnutí takových proměnných, které odrážejí mechanismy výběru habitatu ve smyslu hnízdění, hledání potravy apod. (Bradbury et al. 2005). K modelování těchto procesů se nabízí proměnné popisující strukturu habitatu. Současné metody dálkového průzkumu Země, zejména technologie leteckého laserového skenování, umožňují komplexní reprezentaci prostředí včetně terénu a vegetační struktury a poskytují data pro odvození řady proměnných s velice vysokou přesností (Evans et al. 2009). Popisem těchto charakteristik prostředí se pobrobněji zabývá další kapitola.

Proměnné získané právě z dat leteckého laserového skenování případně jiných metod dálkového průzkumu Země jsou mimo jiné často používány jako vysvětlující proměnné ve studiích modelujících druhovou diverzitu (Franklin 2009). Co se týče ptačích druhů, prvním příkladem může být studie zabývající se využitím leteckého laserového skenování pro popis heterogenity habitatu jako prediktoru diverzity ptáků v lesích mírného pásma ve státě Maryland (Goetz et al. 2007). Modelováním druhové diverzity pěvců s použitím charakteristik popisujících strukturu lesních porostů ve státě Wisconsin se zabývali Lesak et al. (2011). Součástí studie, kterou provedli Eldegard et al. (2014), bylo modelování druhové diverzity ptáků boreálních lesů v jihovýchodním Norsku, opět s využitím leteckého laserového skenování. Vliv struktury vegetace a terénu na lokální diverzitu ptačích druhů v jehličnatých lesích posuzovali Vogeler et al. (2014). Proměnné získané z leteckého laserového skenování jsou využívány také v mnoha studiích modelujících distribuci konkrétních druhů (např. Graf et al. 2009, García-Feced et al. 2011, Farrell et al. 2013, Hill et Hinsley 2015, Huber et al. 2016).

Častým nedostatkem objevujícím se ve studiích kombinujících nálezová data s těmito proměnnými, je mnohdy poměrně značná časová prodleva ve sběru obou typů dat (Vierling et al. 2014). Prvním příkladem je studie, kterou provedl Huber et al. (2016), kde proběhl sběr nálezových dat téměř o 10 let později (2010 – 2012) než letecké laserové skenování (2001 – 2002). Hill et Hinsley (2015) ve své studii naopak použili starší nálezová data (1997 – 2001) v kombinaci s aktuálnějším leteckým laserovým skenováním (2000 – 2012). V tomto případě se při kombinaci nejstarších nálezových dat s nejnovějšími daty leteckého laserového mohlo jednat o rozdíl až 15 let. Zde je vhodné zmínit konkrétní případovou studii, jejímž cílem bylo porovnat rozdíl v predikované distribuci a celkové druhové diverzitě ptačích druhů v jehličnatých lesích, založené na aktuálních datech leteckého laserového skenování (2009) ve srovnání se staršími daty (2003). Ukázalo se, že časová prodleva 6 let nehraje významnou roli, nicméně, jak sami autoři uvádí, jde pouze o jednu případovou studii v jednom typu

ekosystému. Otázkou tedy zůstává, do jaké míry by se výsledky lišily v jiném typu ekosystému a jak velký časový rozdíl je pro různé typy ekosystémů přijatelný. Problém může dále nastat v případě, je-li letecké laserové skenování provedeno v jiné sezóně než sběr náleзовých dat, tedy například mimo vegetační období. To se týká zejména mapování porostů s převažujícím zastoupením opadavých dřevin, kdy se laserové paprsky namísto listů odrazí pouze od kmenů a větví, což logicky vede k vyššímu podílu terénních odrazů (viz níže) ve srovnání s vegetačním obdobím (Huber et al. 2016).


2.2 Využití ALS pro popis struktury prostředí

2.2.1 Základní princip

Letecké laserové skenování je jedna z moderních technologií dálkového průzkumu Země umožňující detailní snímání zemského povrchu a rychlý sběr polohopisných a výškopisných dat na rozsáhlých plochách. Tato metoda je nejčastěji spojována s označením LiDAR (*light detection and ranging*), přestože termín označuje laserové skenování obecně, nikoli jen variantu leteckou (John 2011). Systém je založen na detekci objektů a měření vzdálenosti s využitím laserového záření. Laserové paprsky, tzv. pulzy (*pulse*), jsou vysílány pod různými úhly (*scan angle*) směrem k zemskému povrchu ze skeneru umístěného na leteckém nosiči a následně odráženy zpět k senzoru ve formě tzv. odrazů (*returns*). K odrazu dochází v okamžiku dopadu paprsku na terén, vegetaci, budovy a další objekty nacházející se v trase paprsku. Senzor pak na základě záznamu času uplynulého od emise paprsku do okamžiku odrazu dokáže určit přesnou polohu odrazu v prostoru. Výsledkem je tedy soubor nepravidelně a velmi hustě rozmístěných bodů, tzv. bodové mračno (*point cloud*), kde každý bod nese mimo jiné informaci o poloze zanesené v souřadnicích X, Y a Z. Původní data jsou nejčastěji, dle standardů ASPRS (*American Society for Photogrammetry and Remote Sensing*) ve formátu LAS (Dolanský 2004, Bergen et al. 2009, Evans et al. 2009, Cibulka 2013).

V případě, že se v trase laserového paprsku nachází menší nebo částečně prostupné překážky jako vegetace, okraj budovy nebo např. různé typy nadzemního vedení, část impulzu se odrazí a část prostupuje níže k zemskému povrchu. Z jednoho emitovaného paprsku tedy může být postupně zaznamenáno až několik odrazů, což souvisí s velikostí tzv. stopy paprsku (*footprint size*), která závisí také na výšce letu – například při letu asi 500 m nad terénem je průměr stopy paprsku na zemi okolo 0,3 m, při vysokých letových výškách může dosáhnout průměru až 3 metry, běžné hodnoty se pohybují v řádech několika desítek centimetrů (Dolanský 2004, Uhlířová 2010, John 2011).

Několikanásobné odrazy (*multiple returns*) lze s výhodou využít např. při analýzách vegetace jako je určení prostorové skladby, struktury jednotlivých pater nebo analýzy výšky porostu (Dolanský 2004, Cibulka 2013). Jak je patrné z obr. 1, část světelného impulzu je zpravidla odražena od svrchních či středních pater korun stromů, tzv. první odraz (*first return*) a část může procházet mezerami mezi listy až k terénu, kde dojde k poslednímu odrazu (*last return*), který obvykle reprezentuje terén (Dolanský 2004, García-Feced et al. 2011).



Obr. 1: Znázornění principu několikanásobných odrazů (převzato z: García-Feced et al. 2011).

Získaná data v podobě bodového mračka jsou standardně upravována několika způsoby. Hlavním cílem úprav je rozlišení jednotlivých typů povrchů, zejména separace odrazů reprezentujících terén od odrazů reprezentujících vegetaci a budovy. Základním způsobem úpravy je tzv. filtrace, kdy jsou vyhledávány a odděleny body ležící na jednom určitém druhu povrchu (zpravidla terén). Druhý, komplexnější proces zpracování představuje klasifikace, kdy jsou odrazy postupně v několika krocích tříděny do předdefinovaných tříd (Dolanský 2004, Evans 2009). Oba z uvedených procesů přitom mohou být jak automatické, tak poloautomatické – zcela automatizovanou klasifikací totiž nemusí být vždy dosaženo optimálních výsledků, zejména vyznačuje-li se území značnými rozdíly v krajinném pokryvu, kdy např. souvislá vegetace navazuje na hustou zástavbu (Cibulka 2013). Nástroje pro automatickou klasifikaci bodového mračka nabízí např. LAStools (M. Isenburg, <http://rapidlasso.com/LAStools>).

Takto upravená data jsou pak zpravidla základem pro tvorbu několika základních typů digitálních modelů dle skupin odrazů, které do výpočtu vstupují. Digitální model terénu (DTM, *digital terrain model*), v zahraničních zdrojích označovaný také jako DEM (*digital elevation model*), vzniká interpolací odrazů klasifikovaných jako terén, případně posledních odrazů, a reprezentuje zemský povrch bez vegetace a objektů vytvořených lidskou činností (Evans et al. 2009, Franklin 2009). Tentýž model označuje také termín digitální model reliéfu (DMR) používaný v České republice (VÚGTK 2018). Druhý základní model, digitální model povrchu (DSM, *digital surface model*) obecně vzniká interpolací všech prvních odrazů a představuje kompletní model všech objektů v krajině (Evans et al. 2009, John 2011). Za jeho upravenou variantu lze považovat model výšky vegetace, tzv. CHM (*canopy height model*) zahrnující pouze povrch vegetačního krytu. CHM se může shodovat s tzv. nDSM (*normalized digital surface model*, např. Graf et al. 2009, Huber et al. 2016), v případě, že zahrnuje pouze vegetaci bez budov a prvků infrastruktury.

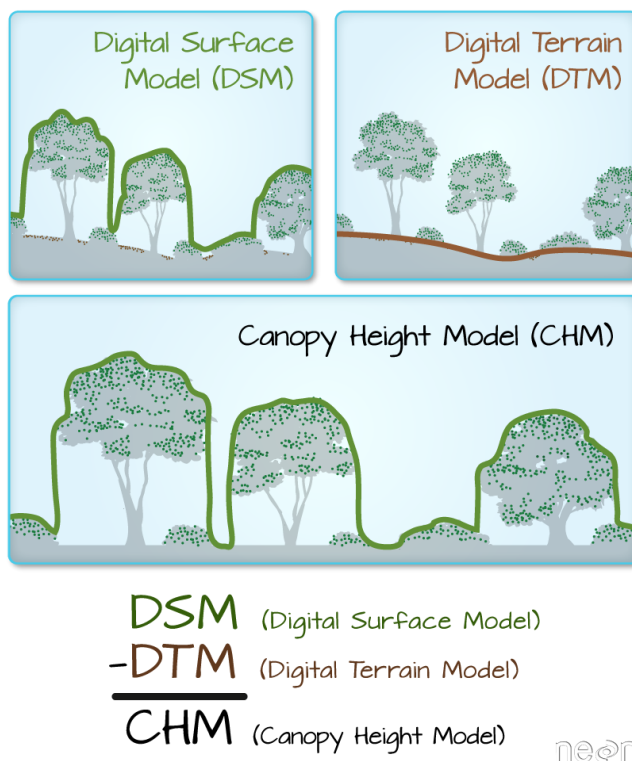
2.2.2 Využití pro popis struktury vegetace

Přestože existuje řada mechanismů ovlivňujících druhovou diverzitu, za jeden ze základních faktorů s významným vlivem v lokálním měřítku je považována skladba a struktura porostu. Vegetace s vyšší strukturální heterogenitou nabízí širší spektrum mikrohabitatů a poskytuje tedy útočiště pro širší spektrum druhů (Bergen et al. 2009, Vogeler et al. 2014). S druhovou diverzitou ptáků je spojována zejména výšková variabilita v distribuci vegetace v jednotlivých patrech a také hustota (*density*) porostu. Tyto charakteristiky hrají významnou roli při vyhledávání vhodného habitatu pro hnízdění a tedy úspěšné rozmnožování, který zároveň zajistí nízké riziko predace a možnost nalezení dostatku úkrytů. Struktura porostu přímo souvisí také se schopností pohybu a úspěšností při hledání potravy (Bradbury et al. 2005, Lesak et al. 2011, Vogeler et al. 2014). Souvislostí mezi komplexností, heterogenitou vegetace a druhovou diverzitou se zabývala již jedna z prvních studií (MacArthur et MacArthur 1961 in Bergen et al. 2009). Tato skutečnost byla potvrzena zjištěním pozitivního vztahu mezi diverzitou ve výšce olistění (*foliace height diversity*) a diverzitou ptačích druhů (Bergen et al. 2009, Vierling et al. 2014).

Letecké laserové skenování umožňuje detailní popis jak horizontální, tak vertikální struktury vegetace prostřednictvím řady charakteristik. Jak uvádí Huber et al. (2016), při hodnocení struktury vegetace je relevantní rozlišovat, zda popisujeme pouze svrchní vrstvu vegetačního krytu (tzv. *canopy*) nebo zahrnujeme do výpočtu všechna vegetační

patra, což umožní detailní popis vertikálního profilu vegetace zahrnující např. hustotu vegetace v jednotlivých patrech nebo variabilitu ve výšce.


Pro reprezentaci svrchní vrstvy vegetačního krytu je často využíván výše zmiňovaný model výšky vegetace. Jedná se o rastr vyjadřující výšku povrchu vegetačního krytu, tedy absolutní výšku vegetace nad terénem (Khosravipour et al. 2014). Pro jeho tvorbu lze využít dva základní přístupy. První spočívá ve vygenerování rastrů digitálního modelu povrchu a digitálního modelu terénu a jejich následného rozdílu (obr. 2). Tento postup je často používaný a objevuje se v řadě studií (např. Farrell et al. 2013, Hill et Hinsley 2015, Huber et al. 2016). Přesnost výsledného modelu pak úzce souvisí např. se způsobem výpočtu a rozlišením obou vstupních rastrů a nemusí tak být vždy dosaženo vyhovujícího výsledku (Khosravipour et al. 2014).



Obr. 2: Schematické znázornění prvního ze způsobů výpočtu CHM (URL 1).

Základem druhého přístupu je tvorba CHM z bodového mračna s normalizovanou výškou, kdy je interpolací všech prvních odrazů vytvořen konečný CHM (Khosravipour et al. 2014). Nedostatkem tohoto přístupu je však vznik tzv. *data pits*, což je jev související s charakterem vegetace, která typicky vytváří nepravidelný a zejména neuzavřený povrch a laserový paprsek se v mnoha případech poprvé odrazí až v nižších patrech nebo pronikne bez předchozího odrazu až k terénu. Následně vznikají v datech

jakési „díry“ výrazně odchylené od sousedních hodnot, které se ve výsledném rastru projeví jako pixely s nepřírozeně nízkou hodnotou, které narušují spojitý povrch korun stromů a mohou představovat problém při další analýze (Isenburg 2014, Khosravipour et al. 2014). V současné době je možné tento problém řešit vytvořením tzv. pit-free CHM, který představili Khosravipour et al. (2014). Základní myšlenkou je postupné vytvoření několika dílčích rastrů a jejich následné spojení ve výsledný CHM, přičemž dílčí rastry si lze představit jako vrstvy vytvořené interpolací v jednotlivých úrovních výšky, jejichž překrytím se zamezí vzniku „mezer“ v datech (obr. 3 vlevo).



Obr. 3: Srovnání nežádoucí podoby CHM s tzv. pit-free CHM (převzato z: Isenburg 2014).

Horizontální struktura

Důležitou charakteristikou horizontální struktury je tzv. *canopy cover* vyjadřující pokryvnost území vegetací (Evans et al. 2009), která je nejčastěji uváděna v procentech případně v intervalu hodnot 0 – 1. Tato proměnná určuje míru vhodnosti prostředí pro výskyt druhů z řady taxonomických skupin. Pro diverzitu ptačích druhů je významným faktorem procentuální pokrytí vegetací v jednotlivých vertikálních úrovních, tedy zda je pokryv soustředěn spíše v keřovém (1 – 3 m), nižším stromovém (3 – 10 m), či vyšším patře a je proto relevantní provést výpočet pro jednotlivé úrovně, resp. nad stanovenými hranicemi výšky (Bergen et al. 2009). Příkladem je proměnná *canopy cover above 3 m* (Huber et al. 2016) nebo *woody canopy cover* od úrovně 1 m nad terénem (Farrell et al. 2013). Doporučená dostačující přesnost při odvozování těchto proměnných je $\pm 10\%$ (Bergen et al. 2009).

Vertikální struktura

Jednu ze skupin charakteristik vertikální struktury mohou tvořit charakteristiky výšky vegetace, často souhrnně označované jako *canopy height*. Do této skupiny lze zařadit běžné proměnné jako průměr (např. *mean canopy height*, Farrell et al. 2013), maximum (např. *maximum height of canopy*, Müller et al. 2010) nebo tzv. výškové percentily (*height percentiles*) včetně mediánu, který je 50 % percentilem (Eldegard et al. 2014, Hill et Hinsley 2015). Tyto metriky se objevují v řadě variant a lze je využít jak k popisu vegetace jako celku, tak odděleně pro jednotlivá patra, chceme-li např. odlišit podrost od stromového patra a získat lepší reprezentaci vyšší vegetace (např. *mean height of tree canopies*, Graf et al. 2009; *mean canopy height above 3 m*, Huber et al. 2016). Maximální výšku vegetace lze vyjádřit přímo z bodového mračka jako hodnotu nejvyššího vegetačního odrazu, dále jako maximum z rastru CHM a nakonec také formou percentilů (95 nebo 99 %), které nezahrnují 5 resp. 1 % nejvyšších odrazů a jsou tedy méně citlivé na případné odlehle hodnoty (Huber et al. 2016).

Druhou skupinu tvoří proměnné popisující vertikální variabilitu vegetace nejčastěji prostřednictvím směrodatné odchylky (*standard deviation*) nebo variačního koeficientu (*coefficient of variance*, Eldegard et al. 2014), které mohou být rovněž počítány jak souhrnně, tak separovaně pro jednotlivá patra, zajímá-li nás např. pouze variabilita stromového patra (*standard deviation of canopy height above 3 m*, Huber et al. 2016).

Do třetí skupiny lze zařadit metriky vyjadřující vertikální stratifikaci porostu, tzn. distribuci vegetace v jednotlivých patrech, a to několika způsoby. Jedním z příkladů je stratifikovaná hustota porostu (*stratified canopy density*), kterou lze vyjádřit jako $[n_i/n]*100$, kde n_i = počet vegetačních odrazů v určitém intervalu výšek a n = celkový počet vegetačních odrazů (Evans et al. 2009). Konkrétními proměnnými mohou být např. *understorey density* jako procentuální podíl odrazů ve výškách 1 – 2,5 m (Vogeler et al. 2014) nebo *upper canopy density* pro horní patra vegetace (Vierling et al. 2014). Lze se setkat také s velice podrobnými variantami těchto proměnných, kdy byly např. vegetační odrazy rozděleny do 10 výškových pater (úrovní) na základě percentilů a hustota počítána nad těmito výškovými úrovněmi (Eldegard et al. 2014). *Canopy density* lze také vyjádřit souhrnně jako celkovou hustotu vegetace podílem počtu vegetačních odrazů a počtu všech odrazů (Evans et al. 2009). V tomto případě by ale šlo spíše o popis horizontální struktury, obdobně jako *canopy cover*.

Proměnné popisující výšku a variabilitu vegetace jsou často odvozovány pouze z CHM, který však zachycuje jen svrchní vrstvu vegetačního krytu a nepopisuje tedy celkovou strukturu podrostu. Současné pokroky v technologii leteckého laserového

skanování již popis této struktury umožňují a to prostřednictvím výpočtu charakteristik přímo z upraveného bodového mračka s tzv. normalizovanou výškou. Tento výpočet umožňuje např. nástroj *lascanopy* (Isenburg 2014). Bodové mračno je základem také pro zjištění vertikální stratifikace. Je známo, že rozmanitá struktura vegetace obecně vytváří vyšší heterogenitu habitatu, což zpravidla vede ke zvýšené druhové diverzitě. Konkrétně zvýšená heterogenita podrostu je obvykle spojována se zvýšenou diverzitou ptačích druhů, nicméně existují i případy, kdy se naopak snižuje. Tyto rozdíly jsou způsobeny lišícími se biotopovými nároky jednotlivých druhů (Davies et Asner 2014).


2.2.3 Využití pro popis struktury terénu

Základem pro popis stanoviště ve smyslu struktury terénu je DTM a z něj odvozené parametry označované jako tzv. topografické proměnné (*topographic variables*). DTM vygenerovaný z dat leteckého laserového skenování se vyznačuje velmi vysokým rozlišením (např. 1 m), které umožňuje výpočet těchto parametrů s vysokou přesností (Franklin 2009, Lassueur et al. 2006). Rozlišují se tzv. primární parametry odvozené přímo z digitálního modelu terénu, a více komplexní, tzv. sekundární parametry, do jejichž výpočtu obvykle vstupují parametry primární (Franklin 2009).

V souvislosti s vysvětlováním druhové diverzity ptáků mají topografické proměnné spíše doplňující význam. Přínosné mohou být jako tzv. nepřímé proměnné. Ty diverzitu přímo neovlivňují, ale vyznačují se výraznou korelací s přímými, obtížně měřitelnými gradienty prostředí a mohou tak sloužit jako jejich zástupci (Miller 2010). V případě ptačích druhů mohou být zastupovanými proměnnými jak gradienty přímo ovlivňující jejich výskyt, tak zejména gradienty přímo ovlivňující charakter vegetace, který je pro distribuci a diverzitu ptáků určující. Na charakter vegetačního krytu má zásadní vliv mikroklima zahrnující teplotní, světelný a hydrologický režim lokality. Nejdůležitějšími primárními parametry se vztahem k uvedeným gradientům jsou svažitost terénu (*slope*) a expozice (*aspect*). Svažitost má dopad zejména na hydrologický režim stanoviště nebo půdní charakteristiky zatímco expozice, tedy orientace svahu ke světovým stranám, významně ovlivňuje množství dopadajícího slunečního záření a určuje tak světelný a teplotní režim stanoviště. Je obecně známo, že lokální, průměrná teplota naměřená na jižně a severně orientovaných svazích se může lišit až o několik stupňů Celsia, což naznačuje významnost lokálního charakteru terénu (Lassueur et al. 2006, Franklin 2009, Austin et Van Niel 2011).

Jedním ze sekundárních parametrů popisujících charakter terénu je křivost povrchu (*curvature*) vyjádřená jako *profile curvature* nebo *plan curvature*, případně kombinací

těchto dílčích složek jako celková křivost. *Profile curvature* vyjadřuje charakter křivosti ve smyslu svažitosti, tzn. ve vertikálním směru, zatímco *plan curvature* vyjadřuje charakter křivosti ve smyslu expozice, tedy ve směru horizontálním. Obě proměnné nabývají záporných hodnot pro konkávní povrch (obr. 4A), kladných hodnot pro konvexní povrch (obr. 4B) a nulových hodnot v případě lineárního průběhu povrchu (obr. 4C). Užitečnou proměnnou může být směrodatná odchylka těchto veličin, zejména *standard deviation of profile curvature*, kterou lze chápat jako míru střídání konvexních a konkávních tvarů reliéfu ve směru svahu a používá se proto jako jedna z metrik vyjadřující tzv. *terrain roughness*, tedy míru členitosti či „zvlnění“ terénu (Grohmann et al. 2011, Tian et al. 2011). Mezi další možná vyjádření členitosti terénu patří směrodatná odchylka nadmořské výšky (*standard deviation of elevation*) nebo směrodatná odchylka svažitosti (*standard deviation of slope*) dobře zachycující změny v hodnotách svažitosti (Grohmann et al. 2011, Tian et al. 2011). Všechny tyto proměnné úzce souvisí zejména s hydrologickým režimem stanoviště a určují např. směr odtoku, hladinu podzemní vody nebo zásobu vody v půdě. Určují také hloubku půdy, způsob akumulace organické hmoty či proces eroze (Lassueur et al. 2006, Franklin 2009).



Obr. 4: Schematické znázornění principu *profile* (nahore) a *plan curvature* (dole) (URL 2).

3. METODIKA

3.1 Charakteristika řešeného území

Radovesická výsypka je rozsáhlá posttěžební lokalita rozkládající se východně od Bíliny v rozloze 1653 ha (obr. 5). Patří mezi tzv. vnější výsypky zakládáné mimo těžební prostor a zároveň jde o největší výsypku tohoto typu na Mostecku a celkově druhou největší v České republice. Byla založena v souvislosti s těžbou hnědého uhlí již v roce 1966 pro zakládání zemin z tehdejšího Velkolomu Maxim Gorkij (dnešní Důl Bílina), přičemž vlastní sypání probíhalo v letech 1969 – 2003. Průměrná mocnost vzniklého tělesa výsypky je 50 – 70 m (Prach et al. 2009, Fraštia et Řehoř 2014).




Obr. 5: Orientální mapa s vyznačením Radovesické výsypky na podkladu ortofoto snímku.

Na jihovýchodě výsypka bezprostředně navazuje na unikátní krajinu CHKO České středohoří známou specifickými přírodními podmínkami a hodnotnými společenstvy. Je důležité si uvědomit, že obdobným charakterem krajiny se vyznačovalo i území dnešní výsypky, kde se také dříve nacházelo 5 obcí – Dřínek, Hetov, Chotovenka, Lyskovice a největší Radovesice (obr. 7 vlevo) zaniklé v letech 1968 – 1971. Poslední památkou na zaniklou obec je kostel Věch svatých, který nebyl zbořen, ale začátkem března 1983 po stržení střechy vyplněn a postupně zasypán skrývkou (obr. 6) Působivé historické snímky jen potvrzují rozsah změn, jakými zdejší krajina procházela (obr. 6 a 7).



Obr. 6: Zanikající obec Radovesice s kostelem Věch svatých pod postupující výsypkou v r. 1982 (vlevo) a 1983 (Prach et al. 2009 a URL 3).

Radovesická výsypka je patrně nejznámější lokalita z hlediska obnovy ekologické stability krajiny. Dnes je již lesnicky či zemědělsky rekultivována s výjimkou dvou výzkumných ploch o celkové rozloze asi 54 ha (20 a 34 ha) ponechaných spontánní sukcesi (obr. 8) (Fraštia et Řehoř 2014), které se vyznačují unikátním prostředím daným specifickým způsobem sypání zeminy (Vojar et al. 2012). Takto vzniklé plochy obývá pestré spektrum druhů z řady taxonomických skupin včetně mnoha specializovaných druhů ptáků (Šálek 2012).



Obr. 7: Charakter krajiny před vznikem výsypky (na snímku obec Radovesice) ve srovnání s dnešní podobou (URL 4 a 5).



Obr. 8: Pohled na části Radovesické výsypky ponechané spontánní sukcesi (URL 6 a Prach et al. 2009)

3.2 Charakteristika vstupních data

3.2.1 Nálezová data

Pro zpracování této práce byla využita existující data získaná v rámci rozsáhlé studie zabývající se ptačími společenstvy posttěžebních lokalit v severozápadních Čechách (Šálek 2012). Pro území Radovesické výsypky a blízkého okolí proběhlo mapování druhů během května 2012. V území bylo vymezeno celkem 8 tras (A – H), v nichž pak konkrétní mapovací body, ke kterým byly přiřazeny záznamy druhů v okruhu do 100 m a nad 100 m. V trasách A, B, C, D a F je vymezeno 30 bodů, v trase E, G a H pak 29, 28 a 24 bodů, celkem tedy 231 bodů rovnoměrně pokrývajících území (příloha č. 1). Data byla poskytnuta ve formě tabulek XLS a bodové vrstvy ve formátu SHP a následně upravena tak, aby byl získán celkový počet druhů zjištěných v okolí bodů (kapitola 3.4).

3.2.2 Data získaná z leteckého laserového skenování

Poskytnutá data pokrývají území rozsahem odpovídající rozmístění bodů. Data jsou tvořena celkem 36 dílčími soubory (dlaždice – *tiles*) v komprimovaném formátu LAZ. Základní specifikace leteckého nosiče, laserového skeneru a související údaje viz tab. 1. Orientační mapa znázorňující rozsah pokrytí území daty v příloze č. 2.

Tab. 1: Základní informace o provedeném leteckém laserovém skenování.

Zhotovitel	ÚVGZ AV ČR, v.v.i. - CzechGlobe	Letecký laserový skener	Riegl LMS Q780
Letové okno	1. 5. – 31. 6. 2017	Šířka snímané linie [m]	1190
Letecký nosič	Cessna 208B	Maximální dosah [m]	5800
Výška letu nad povrchem [m]	1030	Vlnová délka [nm]	1064
Letová rychlost [m/s]	60	Zorný úhel [°]	60

Protože letecké laserové skenování oblasti proběhlo v roce 2017, nevýhodou je tak logicky časová prodleva 5 let ve sběru obou datových sad. Velkou výhodou je naopak shodné sezónní načasování v období května, což je klíčové pro odpovídající charakter vegetačního krytu a aktivitu pozorovaných druhů.

3.3 Použitý software

Data leteckého laserového skenování byla zpracována s využitím nástrojů LAStools, verze 171231 (Isenburg M., <https://rapidlasso.com>), přehled použitých nástrojů a způsob jejich použití shrnuje tab. 2. Související analýzy byly provedeny v prostředí ArcGIS for Desktop 10.4.1. Za účelem přípravy dat pro modelování byl použit Microsoft Office Excel 2007 a vlastní tvorba modelu proběhla v prostředí R 3.4.3.

Tab. 2: Přehled použitých nástrojů LAStools (<https://rapidlasso.com/lastools>).

Nástroj	Způsob použití
lasground_new	Klasifikace terénu
lasview	Kontrola správnosti klasifikace terénu
lasheight	Výpočet výšky odrazů nad terénem
lasclassify	Klasifikace vegetace a budov
lasnoise	Automatická klasifikace izolovaných odrazů
blast2dem	Tvorba dílčích rastrů CHM
lasthin	Tvorba vstupního souboru pro tvorbu dílčích rastrů CHM
lasgrid	Tvorba výsledného rastru CHM
lascanopy	Výpočet vegetačních charakteristik z bodového mračna
laszip	Převod mezi formáty LAS a LAZ

3.4 Zpracování dat

3.4.1 Úprava nálezových dat

Původní data tvoří celkem 16 tabulek ve formátu XLS, vždy 2 tabulky pro každou trasu (A – H) představující kontrolu 1 a 2. V řádcích jsou uvedeny jednotlivé druhy a ve sloupcích pak jejich záznamy (početnost). Byla použita pouze data z okruhu do 100 m od bodů z důvodu eliminace záznamů s charakterem přeletů. Tato data byla upravena do formy jednoduchých tabulek s druhovou diverzitou, která je vyjádřena jako celkový počet zaznamenaných druhů v okolí každého bodu. Skripty pro úpravu dat v prostředí R poskytl Vítězslav Moudrý. Celkem bylo pro přehlednost vytvořeno 8 skriptů pro jednotlivé trasy (příklad skriptu pro trasu A viz příloha č. 3). Prvním krokem byla úprava tabulek obou kontrol, která spočívala v nahrazení hodnot početnosti hodnotou 1

(prezence druhu) a chybějících záznamů hodnotou 0 (absence druhu). Následně byly obě tyto kontroly sečteny a získána souhrnná tabulka pro danou trasu, pro kterou byla provedena sumarizace. Výsledná sumarizační tabulka ve formátu DBF je tvořena dvěma sloupci, přičemž první obsahuje označení bodu, druhý pak příslušný počet druhů. Dílčí tabulky byly následně spojeny nástrojem *Merge* do konečné tabulky s počty zaznamenaných druhů pro všech 231 bodů (A01 – H24). Pro výpočet vegetačních a topografických charakteristik byla dále provedena úprava bodové vrstvy. Za tímto účelem byly s využitím funkce *Buffer* okolo bodů vytvořeny kruhy o poloměru 100 m – tím byl aproximován okruh mapování druhů. Tyto kruhy mají shodné označení jako výchozí body a představují oblasti výpočtu jednotlivých charakteristik.

3.4.2 Zpracování dat leteckého laserového skenování

Prvním krokem před vlastním zpracováním bylo seznámení s daty v prostředí softwaru ArcGIS. Pro tyto účely bylo nejprve potřeba data převést z původního, komprimovaného formátu LAZ do formátu LAS, aby bylo možné vytvořit *LAS Dataset*, který je klíčový pro zobrazování, prohlížení a editaci dat, případně jako vstupní dataset do některých funkcí. Nevýhodou formátu LAS je však značná velikost souborů a tedy náročnost na výpočty i kapacitu. Při práci v nástrojích LAStools byl proto používán komprimovaný formát LAZ, se kterým LAStools pracují jako s výchozím formátem, a v případě potřeby dalšího zpracování v prostředí ArcGIS vždy převeden do formátu LAS a načten do *LAS Datasetu*.

Klasifikace

Základem při zpracování dat je jejich klasifikace. Jak již bylo uvedeno, výsledkem leteckého laserového skenování je tzv. bodové mračno, které se v několika krocích klasifikuje do příslušných tříd (tab. 3). Pro seznámení s principem klasifikace byl využit učební text ve formě tutorialu (Moudrý et Gdulová 2015). Pro vlastní klasifikaci byly využity nástroje *lasground*, *lasheight*, *lasclassify* a *lasnoise*. Podrobný popis nástrojů je dostupný jak online (<https://rapidlasso.com/lastools>), tak v podobě textových souborů přímo v adresáři se staženými nástroji. Další použitý tutorial viz např. Isenburg (2014).


Tab. 3: Přehled použitých tříd klasifikace bodového mračna.

Kód	Název	Kód	Název
1	Unassigned	5	High vegetation
2	Ground	6	Building
3	Low vegetation	7	Noise
4	Medium vegetation	15	Transmission tower

Prvním krokem klasifikace je separace odrazů reprezentujících terén, tzn. oddělení terénu od vegetačního krytu, budov a dalších objektů. To umožňuje nástroj *lasground*, resp. *lasground_new* (upravená verze), který na základě zvoleného nastavení klasifikuje body do dvou základních tříd. První z nich obsahuje odrazy reprezentující terén (třída 2 - *ground*), druhá třída je pak tvořena zbývajícími, prozatím podrobněji neklasifikovanými odrazy, které terén nepředstavují (třída 1 - *unassigned*). Nástroj nabízí volbu několika defaultních nastavení pro jednotlivé typy území, lišící se zejména v hodnotě parametru *step*. Tento základní parametr je zadáván v metrech a přeneseně vyjadřuje velikost objektů, které již nemají být součástí terénu a mají být zařazeny do třídy 1. Zmíněná výchozí nastavení, která lze zvolit, jsou *wilderness* (*step* = 3), *nature* (*step* = 5), *town or flats* (*step* = 10), *city or warehouses* (*step* = 25) a *metropolis* (*step* = 50). Kromě těchto nastavení lze využít možnost *custom* umožňující manuální nastavení parametru *step* a pokročilé nastavení dalších parametrů - *bulge*, *spike*, *down spike* a *offset*. Protože přesná separace terénu je jedním z nejdůležitějších kroků při zpracování dat (Goetz et al. 2007), je žádoucí zvolit nastavení tak, aby bylo dosaženo co nejlepšího výsledku. Proto byly ještě před vlastní klasifikací podrobněji prostudovány jednotlivé dlaždice nad ortofoto snímkem v prostředí ArcGIS, zejména z hlediska charakteru krajinného pokryvu. Na základě tohoto seznámení byly dlaždice rozděleny do dvou základních skupin – bez přítomnosti budov a s přítomností budov (tab. 4 a příloha č. 2), která byla ještě orientačně rozdělena dle charakteru zástavby. Poté byla pro jednotlivé dílčí skupiny provedena klasifikace nejprve s odpovídajícím výchozím nastavením - pro skupinu bez budov s nastavením *nature*, pro dlaždice s několika budovami případně vesnickou zástavbou s nastavením *town or flats*, pro zbývající území s městskou zástavbou případně velkými objekty bylo zvoleno nastavení *city or warehouses* nebo *metropolis*. Následně byla postupně u všech výsledných souborů pomocí nástroje *lasview* provedena vizuální kontrola správnosti klasifikace na základě výběru bodů z třídy 2 a zkušebního zobrazení modelu terénu TIN (*triangulated irregular network*). V případě nevyhovujícího výsledku bylo u příslušných souborů potřeba provést klasifikaci znovu, případně opakovaně, s nastavením *custom*, kde byla vždy zvyšována hodnota parametru *step*, dokud nedošlo k vyhovující separaci terénu. U ostatních parametrů bylo vždy ponecháno nastavení výchozí. Příčinou nesprávné klasifikace byla např. přítomnost husté vegetace případně rámcově větších objektů, než je hodnota *step*. V případě okrajových území s rozsáhlými objekty tak bylo potřeba zvolit vysoké hodnoty *step*, čímž došlo ke správné klasifikaci, ale nemusely být vždy zcela zachyceny lokální prvky reliéfu. Protože do těchto území zasahuje pouze několik zájmových ploch, nejedná se o významný nedostatek. Přehled použitých nastavení pro jednotlivé dlaždice v tab. 4.

Tab. 4: Použité nastavení nástroje *lasground* pro jednotlivé čtverce.

č. čtverce	budovy	nastavení	č. čtverce	budovy	nastavení
0889	ano	city or warehouses	1087	ano	custom: step 20
0890	ano	custom: step 15	1088	ne	town or flats
0891	ne	town or flats	1089	ne	custom: step 20
0892	ne	town or flats	1090	ne	nature
0893	ne	custom: step 15	1091	ne	custom: step 20
0954	ano	custom: step 20	1152	ano	city or warehouses
0955	ano	town or flats	1153	ano	custom: step 20
0956	ne	custom: step 20	1154	ne	custom: step 20
0957	ne	custom: step 8	1155	ano	custom: step 20
0958	ne	custom: step 8	1156	ano	town or flats
0959	ne	town or flats	1157	ano	custom: step 20
1020	ano	city or warehouses	1218	ano	custom: step 100
1021	ne	custom: step 20	1219	ano	custom: step 100
1022	ne	nature	1220	ano	custom: step 20
1023	ne	nature	1221	ano	custom: step 20
1024	ne	nature	1222	ano	town or flats
1025	ne	custom: step 20	1285	ano	custom: step 100
1086	ano	city or warehouses	1286	ano	custom: step 100




Obr. 9: Detailní výřez z 3D zobrazení bodového mračka po klasifikaci nástrojem *lasground*. Hnědou barvou zobrazeny odrazy reprezentující terén, bílou barvou ostatní odrazy.


Dalším krokem v klasifikaci je výpočet výšky bodů z třídy 1 nad terénem s využitím nástroje *lasheight*. Vstupními daty jsou soubory s již správnou klasifikací z předchozího kroku (obr. 9). Nástroj nejprve vybere pouze body z třídy 2, vytvoří přechodný model

TIN a následně vypočte výšku bodů z třídy 1 nad tímto modelem. Výsledné výšky přitom mohou být uloženy několika způsoby a nabývat různých hodnot. Pro třetí krok klasifikace je nutné, aby výsledná výška byla uložena v atributu *user data*, což odpovídá defaultnímu nastavení *store in user data*. V tomto případě jsou výsledné výšky násobeny hodnotou 10 a převedeny do datového typu *unsigned char*, který nabývá hodnot v intervalu 0 – 255. S tímto výchozím nastavením tak byly vytvořeny soubory, které budou vstupovat do další klasifikace nástrojem *lasclassify*.

Nástroj *lasclassify* přiřazuje podrobnější klasifikaci bodům z třídy 1. Ve výchozím nastavení hledá body s výškou od 2 metrů nad terénem (*ground offset = 2*) a mezi těmito body rozlišuje vysokou vegetaci (*high vegetation*, třída 5) a budovy (*building*, třída 6) na základě hledání skupin sousedících bodů a charakteru ploch, které vytváří - střechy budov jsou tvořeny body v jedné rovině, zatímco vegetace vytváří nepravidelný povrch. Tento nástroj má význam spíše v zastavěném území (obr. 11) a pro účely této práce slouží zejména k odlišení budov a jejich vyloučení při tvorbě CHM a výpočtech vegetačních charakteristik nástrojem *lascanopy* v zájmových plochách. Klasifikace byla provedena s výše zmíněným výchozím nastavením (obr. 10).




Obr. 10: Příklady výřezů bodového mračka po klasifikaci nástrojem *lasclassify*. Nahoře klasifikace území obce Štrbice a okolí, dole klasifikace jedné z ploch ponechaných sukcesí. Plochy bez odrazů (černě) představují vodní plochy, neboť záření o vlnové délce 1064 nm je vodou pohlceno.



Obr. 11: Výřez z 3D zobrazení po klasifikaci nástrojem *lasclassify* – klasifikace konkrétní budovy.


Při automatické klasifikaci může dojít k nesprávnému přiřazení třídy 6 v místech s hustou vegetací nebo vysokou hustotou odrazů, které nástroj považuje za střechu budovy. Proto byla v prostředí ArcGIS provedena vizuální kontrola správnosti - při nalezení místa s neodpovídající klasifikací byla oblast zobrazena v panelu nástrojů *LAS Dataset* pomocí *Profile View*, vybrán požadovaný soubor bodů a nástrojem *Edit* přiřazena správná klasifikace – 5 nebo 1. Stejným způsobem byla provedena manuální klasifikace vedení vysokého napětí (obr. 12), neboť je po klasifikaci automaticky zařazeno do třídy 5 (vysoká vegetace). Stožáry a dráty byly pro zjednodušení klasifikovány do stejné třídy 15 (*transmission tower*).



Obr. 12: Ukázka manuální klasifikace stožáru vysokého napětí.

Další krok spočíval v opětovném použití nástroje *lasheight* – pro následnou analýzu je třeba výšku odrazů přepočítat a získat tak tzv. výškově normalizovaná data (*height-normalized*). V tomto případě je nástroj spuštěn s nastavením *replace z* a výslednou výškou jsou nahrazeny původní hodnoty nadmořské výšky tak, že odrazům *ground* je

přiřazena hodnota 0 a zbývajícím skutečná hodnota výšky nad terénem v metrech s přesností na centimetry (obr. 13). Vhodné je dále ponechat odrazy pouze v intervalu výšek odpovídající vegetaci, resp. odstranění odrazů s chybnými hodnotami pod úrovní terénu a odrazů s výškou nad 40 m (nejvyšší vegetace v oblasti dosahuje výšky 35 m). Za tímto účelem byly použity příkazy `-drop_z_below 0` a `-drop_z_above 40.0`.



Obr. 13: Výřez z bodového mračka s normalizovanou výškou. Nahoře zobrazení z profilu, dole 3D zobrazení. Tmavě modrá barva značí hodnoty blízké 0 (terén), červená nejvyšší vegetaci.

V rámci této úpravy byla zároveň pro úplnost a názornost provedena dodatečná klasifikace vegetačních odrazů do třech předdefinovaných tříd (viz tab. 2). Pro podmínky České republiky byly zvoleny intervaly výšek odpovídající bylinnému, keřovému a stromovému patru, které definoval Moravec (1994). Za bylinné patro je považován porost s výškou do 1 m, keřové patro dosahuje výšek v intervalu 1 – 3 m, porost s výškou nad 3 m se již označuje jako patro stromové. S touto hranicí definující stromové patro se lze setkat i v některých zahraničních studiích (např. Graf et al. 2009, Huber et al. 2016). Bylinné patro (0,1 – 1 m) bylo tedy zařazeno do třídy 3 (*low vegetation*), keřové patro (1 – 3 m) do třídy třídy 4 (*medium vegetation*) a stromové patro (od výšky 3 m) pak do třídy 5 (*high vegetation*) pomocí příkazů `classify_z_between_as 0.1 1.0 3`, resp. `1.0 3.0 4` a `-classify_z_above_as 3.0 5`. Odrazy s výškou do 0,1 m byly ponechány bez klasifikace. Aby nedošlo k nežádoucímu zařazení již klasifikovaných odrazů z tříd 6 a 15, tyto třídy bylo třeba z klasifikace vyloučit doplněním příkazů `-ignore_class 6`, resp. `15`.

Nakonec byla nástrojem *lasnoise* provedena automatická klasifikace izolovaných odrazů (tzv. *outliers*), které by mohly představovat problém při výpočtech charakteristik. Parametry nástroje byly nastaveny tak, aby byly vyloučeny pouze ty nejodlehlejší odrazy - *step 5* a *isolated 1*. Takto jsou připravena vstupní data pro vytvoření modelu výšky vegetace a pro výpočet vegetačních charakteristik pomocí nástroje *lascanopy*.

Tvorba modelu výšky vegetace

Pro tvorbu CHM byl použit upravený postup pro LAsTools ve formě online tutorialu (Isenburg 2014) vycházející z algoritmu, který představili Khosravipour et al. (2014). Použitý algoritmus viz příloha č. 4.

Postup lze rozdělit do čtyř základních kroků. Prvním z nich je tvorba rastru, který reprezentuje úroveň terénu a tvoří v modelu podkladovou vrstvu. Vstupem je bodové mračno s normalizovanou výškou (36 souborů ve formátu LAZ), ze kterého nástroj vybere pouze body s výškou do 0,1 m, resp. z výpočtu vyloučí body s výškou nad 0,1 m příkazem *-drop_z_above 0.1*. Výstupním souborem je rastr „*chm_ground.bil*“ uložený do předem vytvořeného adresáře „*tmp_chm*“, kam budou ukládány všechny dílčí rastry. Aby bylo možné provést výpočet zároveň pro celé zájmové území a vytvořit tak jeden výsledný soubor, byl pro účely této práce využit nástroj *blast2dem*. Jedná se o variantu nástroje *las2dem* uvedeného v tutorialu, který je z hlediska funkce zcela identický, ale umožňuje výpočet s velkými vstupními soubory s desítkami milionů bodů (Isenburg 2013). Tento nástroj z bodů nejprve vytvoří přechodný model TIN, který převede na finální rastr ve zvoleném rozlišení a formátu.

Ve druhém kroku je vytvořen vstupní soubor sloužící pro tvorbu dílčích rastrů reprezentující jednotlivé úrovně vegetace. Tento soubor je vytvořen úpravou původních dat nástrojem *lasthin*. Nejprve jsou všechny body nahrazeny kruhy o poloměru 5 cm (lepší reprezentace laserového paprsku) příkazem *-subcircle 0.05*, nad daty vytvořen pomyslný grid v dvojnásobném rozlišení (*step*), než budou mít konečné rastry, tj. 0,5 m. V každé buňce je následně ponechán pouze jeden bod s nejvyšší hodnotou výšky příkazem *-highest* a a vytvořen soubor „*temp.laz*“. Výsledkem jsou tedy zředěná původní data, kde každá pomyslná buňka obsahuje pouze jeden bod s nejvyšší hodnotou výšky. Dvojnásobné rozlišení je použito proto, aby pro následnou interpolaci nebylo vyloučeno příliš mnoho bodů. Úprava nástrojem *lasthin* je vhodnější alternativou k postupu, který tvoří rastry nikoli z nejvyšších bodů, ale ze všech prvních odrazů. Aby se do výsledného modelu zahrnula pouze vegetace a terén (hodnoty 0), byly z výpočtů v prvních dvou krocích pomocí filtru vyloučeny třídy 6, 7 a 15 příkazy *-drop_classification 6, 7 a 15*.

Třetím krokem je tvorba dílčích rastrů pro jednotlivé úrovně vegetace nad terénem, opět nástrojem *blast2dem*. V tomto případě je vždy vstupem předem připravený soubor „temp.laz“. První rastr „chm_00.bil“ je vytvořen ze všech bodů souboru. Tento rastr v řadě studií představuje standardní a konečný CHM a je vytvářen ze všech prvních odrazů (Khosravipour et al. 2014). Dalším rastrem je „chm_02.bil“, který je vytvořen z bodů s výškou 2 m a výše příkazem *-drop_z_below 2*. Obdobně je vytvořen další rastr „chm_05.bil“ od výšky 5 metrů a následně zbývající rastry v intervalu 5 m až po „chm_35.bil“. Hodnota 35 metrů je odhadem hranice, kam dosahuje většina nejvyšší vegetace v území. Společný pro tvorbu všech rastrů v tomto kroku je příkaz *-kill 3*, který zajistí, aby při tvorbě rastrů nebyly rastrovány trojúhelníky s délkou hrany více než 3 m.

V posledním kroku jsou všechny dílčí rastry z adresáře „tmp_chm“ spojeny v jeden výsledný rastr nástrojem *lasgrid*. Spojení rastrů je zadáno příkazem *-merged*. Buňkám ve výsledném rastru je přiřazena nejvyšší hodnota ze všech rastrů překrývajících se v místě buňky příkazem *-highest*. Pro lepší vizualizaci a export jako obrázek je vhodné nastavit v *color options* nepravé barvy a nastavit minimum a maximum dle rozsahu výšky příkazem *-false -set_min_max 0 35*. Pro ponechání aktuálních hodnot a tedy získání rastru se skutečnými hodnotami výšky vegetačního krytu pro další analýzy je třeba ponechat výchozí nastavení a exportovat např. ve formátu BIL. Rastr byl exportován oběma uvedenými způsoby. Společný pro tvorbu rastrů ve všech krocích je příkaz *elevation*, který označuje rastrováný atribut a použité rozlišení (*step*) výchozí 1 m (s výjimkou druhého kroku), a ve skriptu se neuvádí.

Uvedený postup, kromě zamezení vzniku *data pits*, zároveň zajistí, aby nedošlo k nesprávnému propojení a interpolaci odrazů napříč místy s absencí odrazů, např. vodní plochy (Isenburg 2014). Výsledný CHM (výřez viz příloha č. 5) bude vstupem pro výpočet výškových metrik popisujících svrchní vrstvu vegetačního krytu (*canopy*) a výpočet pokryvnosti.

Tvorba digitálního modelu terénu

Digitální model terénu slouží pro výpočet topografických charakteristik, které mají potenciální vliv na diverzitu ptačích druhů. Vstupem pro jeho tvorbu je bodové mračno získané z prvního kroku klasifikace nástrojem *lasground*. Model byl vytvořen v prostředí ArcGIS. V panelu nástrojů *LAS Dataset* pomocí *Filters* s možností *Ground* byly nejprve zobrazeny pouze terénní odrazy. Následně byl použit nástroj *LAS Dataset to Raster*, kde byl ponechán typ interpolace *Binning – average* a nastaveno rozlišení výsledného rastru (*cell size*) na 1 m. Výřez ze stínovaného modelu viz příloha č. 6.

3.5 Tvorba prediktorů

Tvorba prediktorů jako vysvětlujících proměnných, které budou vstupovat do modelu, spočívá ve výpočtu charakteristik vegetace a terénu z připravených dat – CHM, bodové mračno s normalizovanou výškou a DTM. Pro zadání výsledných hodnot charakteristik v jednotlivých kruzích byla připravena tabulka ve formátu XLS, kde první 3 sloupce tvoří data přenesená z atributové tabulky souboru SHP s kruhovými polygony a jejich diverzitou, a to sloupce *FID* (0 – 230), *nazev* (A01 – H24) a *diverzita*. Sloupce *FID* a *nazev* slouží pro identifikaci jednotlivých zón v rámci funkcí *Zonal Statistics*, *Zonal Statistics as Table* a nástroje *lascanopy*. Přehled všech připravených proměnných viz tab. 6.

3.5.1 Charakteristiky vegetace

Charakteristiky byly rozděleny na dvě základní skupiny dle principu, který uvádí Huber et al. (2016), a to na proměnné popisující pouze svrchní vrstvu vegetačního krytu s označením *canopy* a proměnné popisující všechna vegetační patra (podrost) s označením *vegetation*. Výpočet první skupiny proměnných byl proveden v prostředí ArcGIS z modelu výšky vegetace. Pro identifikaci zón je použit atribut *nazev*. V případě druhé skupiny byl výpočet proveden nástrojem *lascanopy* a pro identifikaci zón je automaticky použit atribut *FID*. V obou případech byly z výpočtu vyloučeny hodnoty výškou pod 0,1 m, které nemusí vždy reprezentovat nízkou přízemní vegetaci a mohlo by dojít k nadhodnocení jejího zastoupení.

Proměnné odvozené z CHM

Pokryvnost

Celkem bylo odvozeno 6 proměnných popisujících procentuální pokrytí vegetací – celková pokryvnost (nad výškou 0,1 m), pokryvnost nad výškou 1 m, pokryvnost nad výškou 3 m zahrnující stromové patro jako celek a dále pokryvnost nad výškou 10, 15 a 20 m popisující stromové patro podrobněji (1. skupina v tab. 4). Nejprve byla potřeba z původního CHM vytvořit několik nových rastrů pro výpočty ve zmíněných úrovních. K tomuto účelu byla využita funkce *Set Null*, která přiřadí danému intervalu hodnot dle zadaného kritéria (např. $Value < 0,1$ pro získání rastru k výpočtu celkové pokryvnosti) hodnotu *NoData* a vytvoří nový rastr bez těchto hodnot. Následně byla použita funkce *Zonal Statistics as Table*, jejíž výstupy byly využity mimo výpočet pokryvnosti také pro výpočet proměnných v dalších krocích. Klíčovým pro výpočet pokryvnosti je atribut *AREA* vyjadřující plochu, kterou v dané zóně vegetace zaujímá. Výsledná hodnota

v procentech je pak získána zadáním $(AREA/31379)*100$ do *Field Calculator* v novém sloupci, přičemž hodnota 31 379 je rovna celkovému počtu buněk v jedné zóně (celkové rozloze v m² odpovídající 100 % pokrytí).

Výška a variabilita výšky vegetačního krytu (*canopy*)

Pro popis výšky vegetačního krytu byl zvolen průměr (atribut *MEAN*) a maximum (atribut *MAX*). Byl vybrán celkový průměr a průměr zahrnující pouze stromové patro. Maximum odpovídá nejvyšší hodnotě buňky rastru v dané zóně. Jako ukazatel variability výšky vegetačního krytu byla použita směrodatná odchylka (atribut *STD*), která byla podobně jako průměr vypočtena jak celkově, tak pouze pro stromové patro.

Proměnné odvozené z bodového mračna

Společným krokem pro výpočet všech proměnných bylo vyloučení tříd 6, 7 a 15 příkazy *-drop_classification 6, 7 a 15*, nastavení zón výpočtu proměnných pomocí vrstvy ve formátu SHP obsahující jednotlivé kruhové polygony (*list of polygons*) příkazem *-lop buffer_diverzita.shp*. Jako výstupní formát byl vždy zvolen soubor CSV obsahující hodnoty všech proměnných v jednom souhrnném textovém souboru. Pro zmiňované vyloučení odrazů s výškou do 0,1 m byl zadán příkaz *-drop_z_below 0.1*.

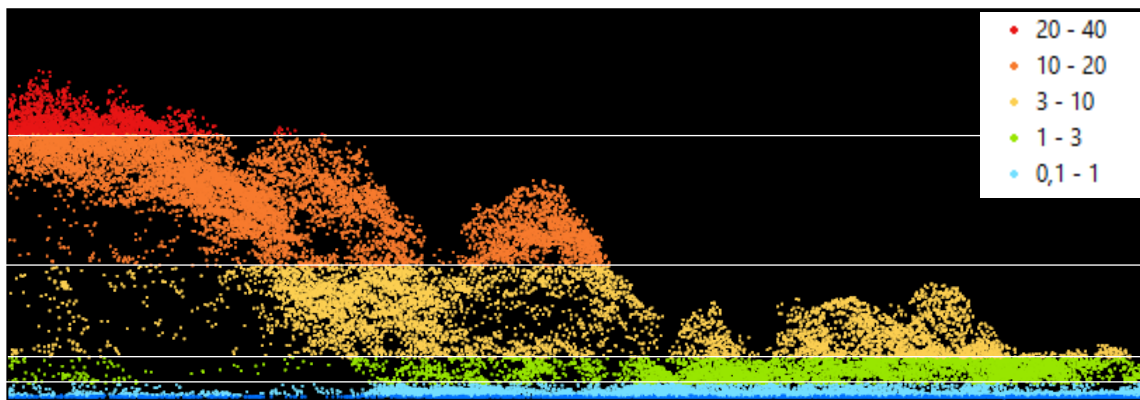
Výška a variabilita výšky vegetace (*vegetation*)

Výška a variabilita byla nejprve vypočtena ze všech vegetačních odrazů, resp. v intervalu výšek 0,1 – 40 m. Z nabízených proměnných bylo zvoleno maximum (zejména pro srovnání s maximem získaným z CHM), průměr, směrodatná odchylka a medián (50 % percentil) příkazy *-max -avg -std -p 50*. Důležitým parametrem je nastavení výškové hranice (*height cutoff*), nad kterou má být proveden výpočet. Protože defaultně je nastaveno 1,37 m, pro zahrnutí všech odrazů bylo potřeba hranici změnit příkazem *-height_cutoff 0.1*. Obdobně byla výška a variabilita vypočtena pouze pro stromové patro. V tomto případě již postačil pouze výpočet průměru, směrodatné odchylky a mediánu a nastavení výškové hranice na 3 m příkazem *-height_cutoff 3*. Nakonec byl vypočten průměr výšek pouze pro vegetaci do výšky 3 m (Huber et al. 2016). Zde bylo potřeba nastavit hranici *height_cutoff 0.1* a *drop_z_above 3*.

Vertikální stratifikace

Vertikální stratifikace popisuje charakter rozložení vegetace v jednotlivých patrech, který byl vyjádřen pomocí relativní hustoty vegetace, tzv. density. Výpočet spočívá ve zjištění počtu vegetačních odrazů spadajícího do určitého intervalu výšek a jeho následném vydělení celkovým počtem vegetačních odrazů, čímž je získán procentuální

podíl odrazů zastoupených v daném patře (Evans et al. 2009). Celkem bylo zvoleno následujících 5 intervalů vymežujících jednotlivá patra, a to 0,1–1 m pro bylinné patro, 1–3 m pro keřové patro, 3–10 m pro nižší stromové patro, 10–20 m pro vyšší stromové patro a 20–40 m odpovídající nejvyššímu stromovému patru (obr. 14). Tyto intervaly pro výpočet density byly zadány příkazem `-d 0.1 1 3 10 20 40`.



Obr. 14: Znáornění použitého rozdělení vegetace do výškových pater (m) pro výpočet density na příkladu výřezu z bodového mračna.

3.5.2 Charakteristiky terénu

Odvození topografických charakteristik bylo provedeno v prostředí ArcGIS. Z DTM v rozlišení 1 m byly nejprve připraveny rastry představující základ pro výpočet daných charakteristik. Z odpovídajících rastrů byly následně pomocí *Zonal Statistics* vytvořeny konečné rastry s hodnotami jednotlivých proměnných v zónách. Pro rychlé vytvoření souhrnné tabulky byla využita funkce *Extract Multiple Values to Points*.

Směrodatná odchylka nadmořské výšky

Rastr s hodnotami proměnné byl vytvořen přímo z DTM pomocí *Zonal Statistics* s nastavením atributu *STD*.

Průměrná svažítost

Základem pro výpočet je rastr svažítosti (*slope*) ve stupních vytvořený z DTM funkcí *Slope*. Rastr s hodnotami proměnné byl vytvořen pomocí *Zonal Statistics* s nastavením atributu *MEAN*.

Směrodatná odchylka svažítosti

Základem pro výpočet je rovněž rastr svažítosti. V *Zonal Statistics* byl v tomto případě nastaven atribut *STD*.

Směrodatná odchylka křivosti profilu

Nejprve byl vytvořen rastr křivosti profilu (*profile curvature*) jako jeden ze dvou dílčích výstupů (*Output profile curve raster*) funkce *Curvature*. Tento rastr byl pak vstupem do funkce *Zonal statistics* s nastavením *STD*.

Převažující expozice

Prvním krokem při přípravě prediktoru bylo vytvoření rastru expozice (*aspect*) funkcí *Aspect*. Jejím výstupem je spojitá proměnná, která vyjadřuje orientaci svahu ke světové straně ve stupních (0 – 360), buňky s všesměrnou expozicí (rovina) mají hodnotu -1. Protože má tato proměnná takto specifický charakter, pro lepší interpretaci a zejména pro možnost vyjádření převažující expozice v jednotlivých zónách byla převedena na proměnnou kategoriální s 9 kategoriemi 0 – 8 pomocí funkce *Reclassify*. Hodnoty odpovídající severní expozici sloučeny do jedné kategorie (1), viz schéma v tab. 5. Takto upravený rastr byl vstupem do *Zonal statistics* s nastavením *MAJORITY*, čímž je do výsledného rastru zanesena převažující hodnota v zóně.

Tab. 5: Použité schéma reklasifikace hodnot expozice.

Původní hodnota	Nová hodnota	Expozice
-1	0	Všesměrná
0 - 22,5	1	Severní
22,5 - 67,5	2	Severovýchodní
67,5 - 112,5	3	Východní
112,5 - 157,5	4	Jihovýchodní
157,5 - 202,5	5	Jižní
202,5 - 247,5	6	Jihozápadní
247,5 - 292,5	7	Západní
292,5 - 337,5	8	Severozápadní
337,5 - 360	1	Severní

Tab. 6: Přehled vytvořených charakteristik vegetace (4 skupiny) a terénu (1 skupina).

1. POKRYVNOST (%)	
Pokryvnost celková	cc_01
Pokryvnost nad 1 m	cc_1
Pokryvnost nad 3 m	cc_3
Pokryvnost nad 10 m	cc_10
Pokryvnost nad 15 m	cc_15
Pokryvnost nad 20 m	cc_20
2. VÝŠKA A VARIABILITA VÝŠKY VEGETAČNÍHO KRYTU (m)	
Průměrná výška vegetačního krytu	ch01_mean
Průměrná výška vegetačního krytu nad 3 m	ch3_mean
Maximální výška vegetačního krytu	ch01_max
Směrodatná odchylka výšky vegetačního krytu	ch01_std
Směrodatná odchylka výšky vegetačního krytu nad 3 m	ch3_std
3. VÝŠKA A VARIABILITA VÝŠKY VEGETACE (m)	
Průměrná výška vegetace	vh01_mean
Průměrná výška vegetace do 3 m	vh01_3_mean
Průměrná výška vegetace nad 3 m	vh3_mean
Medián výšky vegetace	vh01_med
Medián výšky vegetace nad 3 m	vh3_med
Směrodatná odchylka výšky vegetace	vh01_std
Směrodatná odchylka výšky vegetace nad 3 m	vh3_std
4. VERTIKÁLNÍ STRATIFIKACE (%)	
Relativní densita vegetace do výšky 1 m (%)	d01_1
Relativní densita vegetace v intervalu 1 - 3 m (%)	d1_3
Relativní densita vegetace v intervalu 3 - 10 m (%)	d3_10
Relativní densita vegetace v intervalu 10 - 20 m (%)	d10_20
Relativní densita vegetace nad výškou 20 m (%)	d20_40
5. TERÉN	
Směrodatná odchylka nadmořské výšky	elev_std
Průměrná svažitost	slope_mean
Směrodatná odchylka svažitosti	slope_std
Směrodatná odchylka křivosti profilu	profil_std
Převažující expozice	asp_maj

3.6 Výběr prediktorů


Před vlastním modelováním je potřeba posoudit, které z připravených prediktorů budou v modelech ve skutečnosti použity. V tab. 7 jsou pro přehlednost uvedeny vybrané prediktory, metodika výběru popsána níže.

Tab. 7: Přehled charakteristik vybraných pro použití v modelech.

1. POKRYVNOST (%)	
Pokryvnost celková	cc_01
Pokryvnost nad 1 m	cc_1
2. VÝŠKA A VARIABILITA VÝŠKY VEGETACE (m)	
Směrodatná odchylka výšky vegetace	vh01_std
3. VERTIKÁLNÍ STRATIFIKACE (%)	
Relativní densita vegetace v intervalu 1 - 3 m (%)	d1_3
Relativní densita vegetace v intervalu 3 - 10 m (%)	d3_10
Relativní densita vegetace v intervalu 10 - 20 m (%)	d10_20
Relativní densita vegetace nad výškou 20 m (%)	d20_40
4. TERÉN	
Směrodatná odchylka nadmořské výšky	elev_std
Směrodatná odchylka křivosti profilu	profil_std
Převažující expozice	asp_maj

Při modelování je důležité zamezit současné přítomnosti významně korelovaných prediktorů, což je jev zvaný multikolinearita (Franklin 2009). Jedním z kritérií výběru tak může být posouzení míry korelace s využitím výpočtu korelačního koeficientu.

Zhodnocení korelací prediktorů bylo provedeno v prostředí R pomocí Pearsonova korelačního koeficientu. Za účelem zjištění obecné míry korelace byla funkcí *cor* vytvořena souhrnná korelační matice a následně graficky zobrazena funkcí *corrplot* (obr. 15), kde tmavě modrá a tmavě červená barva značí vysoké hodnoty korelačního koeficientu. Vzhledem k vysokému počtu prediktorů a vesměs vysoké zjištěné míře korelace byla data rozdělena do 5 datových sad odpovídající původním skupinám (tab. 4) a korelace v dalším kroku nejprve detailněji posuzovány v rámci těchto skupin. Jako hranice příliš vysoké korelace byla zvolena hodnota 0,7 (resp. 0,75 dle relevance prediktorů) – prediktory s vyšší korelací tedy společně v modelu použity nebudou. Tab. 8 – 13 představují korelační matice pro dílčí skupiny proměnných. Tučně vyznačené hodnoty značí vysokou míru korelace (> 0,7).



Obr. 15: Souhrnné grafické znázornění korelací mezi všemi prediktory.

Nejmenší zjištěná míra korelace je v rámci skupiny 4 (tab. 9), kde jsou významněji korelované pouze proměnné *d01_1* a *d3_10*. Z této dvojice byla vyřazena proměnná *d01_1* vzhledem k jejím celkově výraznějším korelacím s proměnnými ostatních skupin (obr. 15) a také z důvodu zachování souvislého sledu proměnných vyjadřujících densitu. Druhou relativně nejméně korelovanou skupinou jsou topografické charakteristiky (tab. 12). Z této skupiny byla vyřazena proměnná *slope_mean* s předpokládaným minimálním vlivem na druhovou diverzitu a dále proměnná *slope_std*, která je výrazně korelovaná s proměnnou *profil_std*. Zvláště výrazné korelace jsou patrné mezi proměnnými ze skupin 2 a 3 (obr. 15). Vzhledem k tomu, že většina těchto proměnných patrně obsahuje podobnou informaci, byly tyto dvě skupiny sloučeny a korelace posouzeny mezi těmito proměnnými společně (tab. 13). Na základě posouzení bylo vybráno několik variant skupin proměnných, které lze společně použít. Jedná se o trojici proměnných *ch01_std*, *vh01_med* a *vh01_3_mean* a dále trojici *vh3_std*, *vh01_med* a *vh01_3_mean*. Jako

variantu *ch01_std* lze použít *vh01_std*. Proměnnou *vh01_3_mean* lze použít ve dvojici s jakoukoli proměnnou ze skupiny.

Poměrně problematické bylo rozhodování o výběru proměnných z první skupiny. Na základě dosavadního výběru byl proto zredukován počet proměnných z ostatních skupin a posouzeny korelace skupiny 1 s těmito zbylými proměnnými (tab. 14). Největší důraz byl kladen na korelace s proměnnými ze skupiny 4 tak, aby byly tyto proměnné v modelu zachovány. S těmito proměnnými není významně korelována pouze *cc_01* (celková pokryvnost), která zároveň, jak je patrné z druhého sloupce tab. 14, není nadměrně korelována s žádnou z ostatních proměnných. Druhou nejméně korelovanou s densitou je *cc_1*, tedy pokryvnost nad 1 m odpovídající přibližně pokryvnosti od úrovně keřového patra, s výjimkou *d10_20*, kde dosahuje korelační koeficient hodnoty 0,75. I přes tuto skutečnost bude proměnná do modelů zařazena, jako varianta *cc_01*, ne však společně s proměnnými *vh01_med* a *vh01_3_mean*.

Tab. 8: Korelace mezi proměnnými v rámci skupiny 1.

	cc_01	cc_1	cc_3	cc_10	cc_15	cc_20
cc_01	1	0.91	0.87	0.67	0.53	0.41
cc_1	0.91	1	0.98	0.78	0.64	0.49
cc_3	0.87	0.98	1	0.86	0.71	0.55
cc_10	0.67	0.78	0.86	1	0.93	0.76
cc_15	0.53	0.64	0.71	0.93	1	0.91
cc_20	0.41	0.49	0.55	0.76	0.91	1

Tab. 9: Korelace mezi proměnnými v rámci skupiny 2.

	ch01_mean	ch01_max	ch01_std	ch3_mean	ch3_std
ch01_mean	1	0.84	0.77	0.88	0.75
ch01_max	0.84	1	0.91	0.90	0.92
ch01_std	0.77	0.91	1	0.87	0.95
ch3_mean	0.88	0.90	0.87	1	0.88
ch3_std	0.75	0.92	0.95	0.88	1

Tab. 10: Korelace mezi proměnnými v rámci skupiny 3.

	vh01_mean	vh01_std	vh01_med	vh01_3_mean	vh3_mean	vh3_std	vh3_med
vh01_mean	1	0.83	0.97	0.60	0.87	0.77	0.87
vh01_std	0.83	1	0.71	0.58	0.89	0.96	0.86
vh01_med	0.97	0.71	1	0.57	0.79	0.65	0.80
vh01_3_mean	0.60	0.58	0.57	1	0.47	0.53	0.42
vh3_mean	0.87	0.89	0.79	0.47	1	0.88	0.99
vh3_std	0.77	0.96	0.65	0.53	0.88	1	0.85
vh3_med	0.87	0.86	0.80	0.42	0.99	0.85	1

Tab. 11: Korelace mezi proměnnými v rámci skupiny 4.

	d01_1	d1_3	d3_10	d10_20	d20_40
d01_1	1	-0.50	-0.80	-0.64	-0.36
d1_3	-0.50	1	0.52	-0.15	-0.16
d3_10	-0.80	0.52	1	0.17	-0.09
d10_20	-0.64	-0.15	0.17	1	0.56
d20_40	-0.36	-0.16	-0.09	0.56	1

Tab. 12: Korelace mezi proměnnými v rámci skupiny 5.


	elev_std	slope_mean	slope_std	profil_std	asp_maj
elev_std	1	0.90	0.60	0.59	-0.10
slope_mean	0.90	1	0.80	0.77	-0.06
slope_std	0.60	0.80	1	0.82	-0.01
profil_std	0.59	0.77	0.82	1	-0.01
asp_maj	-0.10	-0.06	-0.01	-0.01	1

Tab. 13: Korelace mezi proměnnými ze skupin 2 a 3.

	ch01_mean	ch01_max	ch01_std	ch3_mean	ch3_std	vh01_mean
ch01_mean	1	0.84	0.77	0.88	0.75	0.99
ch01_max	0.84	1	0.91	0.9	0.92	0.84
ch01_std	0.77	0.91	1	0.87	0.95	0.77
ch3_mean	0.88	0.90	0.87	1	0.88	0.88
ch3_std	0.75	0.92	0.95	0.88	1	0.75
vh01_mean	0.99	0.84	0.77	0.88	0.75	1
vh01_std	0.83	0.93	0.99	0.91	0.95	0.83
vh01_med	0.97	0.74	0.64	0.80	0.62	0.97
vh01_3_mean	0.61	0.63	0.58	0.49	0.56	0.60
vh3_mean	0.86	0.89	0.84	0.98	0.85	0.87
vh3_std	0.78	0.92	0.94	0.91	0.99	0.77
vh3_med	0.85	0.84	0.80	0.97	0.81	0.87
	vh01_std	vh01_med	vh01_3_mean	vh3_mean	vh3_std	vh3_med
ch01_mean	0.83	0.97	0.61	0.86	0.78	0.85
ch01_max	0.93	0.74	0.63	0.89	0.92	0.84
ch01_std	0.99	0.64	0.58	0.84	0.94	0.80
ch3_mean	0.91	0.80	0.49	0.98	0.91	0.97
ch3_std	0.95	0.62	0.56	0.85	0.99	0.81
vh01_mean	0.83	0.97	0.60	0.87	0.77	0.87
vh01_std	1	0.71	0.58	0.89	0.96	0.86
vh01_med	0.71	1	0.57	0.79	0.65	0.8
vh01_3_mean	0.58	0.57	1	0.47	0.53	0.42
vh3_mean	0.89	0.79	0.47	1	0.88	0.99
vh3_std	0.96	0.65	0.53	0.88	1	0.85
vh3_med	0.86	0.80	0.42	0.99	0.85	1

Tab. 14: Korelace první skupiny s vybranými proměnnými.

	cc_01	cc_1	cc_3	cc_10	cc_15	cc_20
cc_01	1	0.91	0.87	0.67	0.53	0.41
cc_1	0.91	1	0.98	0.78	0.64	0.49
cc_3	0.87	0.98	1	0.86	0.71	0.55
cc_10	0.67	0.78	0.86	1	0.93	0.76
cc_15	0.53	0.64	0.71	0.93	1	0.91
cc_20	0.41	0.49	0.55	0.76	0.91	1
ch01_std	0.59	0.64	0.66	0.60	0.49	0.40
vh01_std	0.63	0.69	0.72	0.67	0.57	0.47
vh01_med	0.68	0.82	0.88	0.92	0.89	0.76
vh01_3_mean	0.67	0.78	0.70	0.42	0.32	0.23
vh3_std	0.60	0.65	0.67	0.65	0.56	0.47
d1_3	0.28	0.27	0.10	-0.17	-0.19	-0.17
d3_10	0.46	0.56	0.51	0.10	-0.04	-0.09
d10_20	0.64	0.75	0.82	0.94	0.82	0.58
d20_40	0.38	0.46	0.51	0.71	0.87	0.98
elev_std	0.50	0.57	0.55	0.48	0.37	0.23
profil_std	0.52	0.50	0.49	0.39	0.27	0.13
asp_maj	-0.19	-0.15	-0.15	-0.18	-0.18	-0.20



Obr. 16: Grafické znázornění korelací mezi vybranými prediktory.

Pro kontrolu bylo provedeno grafické znázornění korelací mezi vybranými prediktory (obr. 16). Na základě výsledku byla ještě vyřazena proměnná *vh3_std*, která je výrazně korelovaná jak s *ch01_std* tak *vh01_std*, a dále proměnná *vh01_med* významně korelovaná s proměnnou *d10_20*. Nakonec byla vyřazena i proměnná *vh01_3_mean* s vyšší korelací s *d3_10* a *cc_1*. Z dvojice *ch01_std* a *vh01_std* byla vybrána pouze proměnná *vh01_std*, vzhledem k předpokládanému významnějšímu vlivu variability podrostu na druhovou diverzitu ptáků (Davies et Asner 2014). Dvojice *cc_01* a *cc_1* byla ponechána, přičemž každá z proměnných bude použita v jedné ze dvou variant skupin proměnných vstupujících do modelu.

3.7 Tvorba modelu

Protože vysvětlovaná proměnná *diverzita* vyjadřuje počet druhů a nabývá celých nezáporných hodnot, předpokládáme, že se jedná o Poissonovo rozdělení (Šmilauer 2007). Byly proto použity zobecněné lineární modely s Poissonovou distribucí, k jejichž fitování slouží funkce *glm* s parametrem *family = poisson*, který udává zvolený typ distribuce. Ještě před procesem výběru prediktorů a validací modelu je vždy potřeba ověřit, zda se v modelu neobjevuje tzv. nadměrná variabilita (*overdispersion*) (Zuur et al. 2009). K tomu slouží odhad disperzního parametru Φ , jehož hodnota odpovídá poměru residuální deviance (*residual deviance*) a residuálního počtu stupňů volnosti (*residual df*). V případě Poissonova rozdělení by měla být residuální deviance přibližně rovna residuálnímu počtu stupňů volnosti a disperzní parametr by se tedy měl přibližovat hodnotě 1 (Šmilauer 2007). V případě, že by hodnota disperzního parametru byla výrazně vyšší než 1, hovoříme již o nadměrné variabilitě. Závěry vyvozené z testů a kritérií, které předpokládají hodnotu $\Phi = 1$ pro Poissonovo rozdělení (*dispersion parameter for poisson family taken to be 1*) by proto mohly být zkreslené a bylo by třeba model fitovat s odlišnými parametry (Šmilauer 2007, Zuur et al. 2009). Byly vytvořeny dva základní modely (M1 a M2) s 9 proměnnými, ze kterých byly na základě výběru prediktorů získány konečné modely a následně všechny varianty porovnány na základě kritéria AIC (*Akaike information criterion*) pomocí stejnojmenné funkce.

Pro výběr optimálního modelu byla využita jedna z variant *backward selection*, kdy jsou z modelu postupně vyřazovány prediktory s nesignifikantním vlivem na základě analýzy deviance. Zásadním pojmem je tzv. residuální deviance, kterou lze chápat jako zbývající nevysvětlenou variabilitu v modelu. Čím nižší hodnoty residuální deviance ve srovnání s celkovou deviancí (pro nulový model) je tedy v daném modelu dosaženo, tím více variability bylo zpravidla použitými prediktory vysvětleno.

Zvolenou metodou je postup, kdy je z modelu vyřazen vždy jeden prediktor, model fitován bez tohoto prediktoru a následně srovnán s plným modelem se všemi prediktory na základě testu analýzy deviance. Tímto způsobem je analýza provedena postupně pro všechny použité prediktory. Z modelu je pak ručně vyřazen jeden prediktor, který nejméně přispěl ke snížení hodnoty residuální deviance a model fitovaný bez tohoto prediktoru se tedy průkazně neliší od modelu plného (hladina významnosti 0.05). Poté je tento postup opakován s novým modelem bez tohoto prediktoru a vyřazeny případné další nesignifikantní proměnné. Použitým testem signifikance je χ^2 test. Popsaná metoda byla provedena funkcí *drop1* s parametrem *test = „Chi“* (Zuur et al. 2009).

V rámci této metody jsou pro jednotlivé modely počítány také hodnoty kritéria AIC, které představuje další z možných variant výběru modelu. V tomto případě je vypočtena hodnota pro plný model a hodnoty AIC pro modely po vyřazení jednotlivých prediktorů. Čím nižší hodnoty je u určitého prediktoru dosaženo, tím je model dle tohoto kritéria lepší a je tedy vhodnější prediktor vyřadit (Zuur et al. 2009).

Po vyřazení nesignifikantních proměnných byl zobrazen souhrn výsledného modelu funkcí *summary* a zjištěny hodnoty *Null deviance* a *Residual deviance*, ze kterých byla vztahem

$$100 \times \frac{\text{null deviance} - \text{residual deviance}}{\text{null deviance}}$$

získána vysvětlená deviance (Zuur et al. 2009) v procentech vyjadřující míru vysvětlené variability daným modelem. Součástí výstupu funkce *summary* je také hodnota AIC. Výhodou tohoto kritéria je možnost porovnání modelů bez ohledu na to, zda je jeden z modelů podsouborem druhého (tzv. *nested*).

4. VÝSLEDKY

4.1 Analýza deviance a výběr prediktorů

Na základě analýzy deviance pro první variantu modelu byla jako první vyřazena proměnná *elev_std*, která ze všech proměnných nejméně přispívá k vysvětlené devianci. V následujících krocích byly postupně vyřazeny proměnné *d10_20*, *d20_40* a *asp_maj* (tab. 15). Jak je dále patrné z tab. 15, po vyřazení uvedených proměnných zároveň došlo ke snížení hodnoty kritéria AIC, což značí zlepšení kvality modelu. Výsledkem tohoto výběru je model 1.4. Po další analýze tohoto modelu bylo zjištěno, že po vyřazení proměnné *asp_maj* došlo ke snížení signifikance také u proměnné *d3_10*. Přestože je tato proměnná pod hranicí signifikance, po jejím vyřazení by došlo k mírnému zvýšení hodnoty kritéria AIC (tab. 15 – model 1.4). Protože jde o minimální rozdíl, byla tato proměnná také vyřazena a vytvořen dále model 1.5 obsahující 4 vysvětlující proměnné.

Tab. 15: Upravené výstupy funkce *drop1* znázorňující analýzu deviance a postup vyřazování proměnných v první variantě modelu. Červeně vyznačena residuální deviance, AIC a proměnné vyřazované v jednotlivých krocích analýzy.

Model 1:
diverzita ~ cc_01 + vh01_std + d1_3 + d3_10 + d10_20 + d20_40 +
elev_std + profil_std + asp_maj

	Df	Deviance	AIC	LRT	Pr(>Chi)	
<none>		215.13	1118.1			
cc_01	1	220.70	1121.7	5.5630	0.01834	*
vh01_std	1	237.39	1138.4	22.2605	2.381e-06	***
d1_3	1	245.30	1146.3	30.1645	3.969e-08	***
d3_10	1	219.93	1120.9	4.7942	0.02856	*
d10_20	1	215.67	1116.7	0.5324	0.46561	
d20_40	1	216.24	1117.2	1.1055	0.29307	
elev_std	1	215.53	1116.5	0.3909	0.53183	
profil_std	1	219.19	1120.2	4.0518	0.04412	*
asp_maj	1	216.57	1117.6	1.4385	0.23038	

Model 1.1:
diverzita ~ cc_01 + vh01_std + d1_3 + d3_10 + d10_20 + d20_40 +
profil_std + asp_maj

	Df	Deviance	AIC	LRT	Pr(>Chi)	
<none>		215.53	1116.5			
cc_01	1	220.96	1120.0	5.4382	0.0197	*
vh01_std	1	238.77	1137.8	23.2465	1.425e-06	***
d1_3	1	245.37	1144.4	29.8446	4.681e-08	***
d3_10	1	220.01	1119.0	4.4846	0.0342	*
d10_20	1	215.86	1114.9	0.3324	0.5643	
d20_40	1	216.56	1115.6	1.0408	0.3076	
profil_std	1	219.27	1118.3	3.7440	0.0530	.
asp_maj	1	216.86	1115.9	1.3326	0.2483	

Model 1.2:

diverzita ~ cc_01 + vh01_std + d1_3 + d3_10 + d20_40 + profil_std + asp_maj

	Df	Deviance	AIC	LRT	Pr(>Chi)	
<none>		215.86	1114.9			
cc_01	1	224.94	1122.0	9.084	0.002578	**
vh01_std	1	251.34	1148.3	35.484	2.571e-09	***
d1_3	1	247.78	1144.8	31.927	1.601e-08	***
d3_10	1	220.01	1117.0	4.153	0.041559	*
d20_40	1	216.92	1113.9	1.065	0.302123	
profil_std	1	219.99	1117.0	4.137	0.041963	*
asp_maj	1	217.02	1114.0	1.165	0.280347	

Model 1.3:

diverzita ~ cc_01 + vh01_std + d1_3 + d3_10 + profil_std + asp_maj

	Df	Deviance	AIC	LRT	Pr(>Chi)	
<none>		216.92	1113.9			
cc_01	1	228.13	1123.2	11.213	0.0008124	***
vh01_std	1	275.17	1170.2	58.251	2.307e-14	***
d1_3	1	248.24	1143.2	31.318	2.190e-08	***
d3_10	1	220.05	1115.1	3.125	0.0770913	.
profil_std	1	220.50	1115.5	3.584	0.0583544	.
asp_maj	1	218.20	1113.2	1.281	0.2576664	

Model 1.4:

diverzita ~ cc_01 + vh01_std + d1_3 + d3_10 + profil_std

	Df	Deviance	AIC	LRT	Pr(>Chi)	
<none>		218.20	1113.2			
cc_01	1	231.48	1124.5	13.276	0.0002689	***
vh01_std	1	280.54	1173.5	62.341	2.889e-15	***
d1_3	1	250.48	1143.5	32.277	1.337e-08	***
d3_10	1	220.57	1113.6	2.372	0.1235343	
profil_std	1	221.34	1114.3	3.141	0.0763676	.

Model 1.5:

diverzita ~ cc_01 + vh01_std + d1_3 + profil_std

	Df	Deviance	AIC	LRT	Pr(>Chi)	
<none>		220.57	1113.6			
cc_01	1	235.25	1126.3	14.670	0.0001281	***
vh01_std	1	294.36	1185.4	73.781	< 2.2e-16	***
d1_3	1	270.99	1162.0	50.418	1.242e-12	***
profil_std	1	224.38	1115.4	3.808	0.0510034	.

Na základě analýzy deviance pro druhou variantu modelu byla jako první vyřazena proměnná *cc_1*. Dále byly postupně vyřazeny proměnné *elev_std*, *d20_40* a *asp_maj*. (tab. 16). Poslední model (2.3) tedy obsahuje 6 proměnných signifikantně přispívajících k devianci, včetně proměnných, které byly z prvního modelu vyřazeny (*d3_10*, *d10_20* a *asp_maj*). Tato skutečnost je pravděpodobně způsobena tím, že většinu informace obsažené v těchto proměnných nese patrně prediktor *cc_01*, který v této variantě nebyl zařazen. Stejně jako v prvním případě došlo po vyřazení poslední nesignifikantní proměnné k nepatrnému zvýšení AIC.

Tab. 16: Upravené výstupy funkce *drop1* znázorňující analýzu deviance a postup při vyřazování proměnných ve druhé variantě modelu. Červeně vyznačena residuální deviance, AIC a proměnné vyřazované v jednotlivých krocích analýzy.

Model 2:

diverzita ~ cc_1 + vh01_std + d1_3 + d3_10 + d10_20 + d20_40 +
elev_std + profil_std + asp_maj

	Df	Deviance	AIC	LRT	Pr(>Chi)	
<none>		220.66	1123.7			
cc_1	1	220.70	1121.7	0.037	0.84670	
vh01_std	1	240.05	1141.1	19.390	1.065e-05	***
d1_3	1	256.26	1157.3	35.605	2.417e-09	***
d3_10	1	226.04	1127.0	5.381	0.02036	*
d10_20	1	222.45	1123.5	1.794	0.18046	
d20_40	1	222.38	1123.4	1.716	0.19021	
elev_std	1	220.94	1122.0	0.286	0.59279	
profil_std	1	226.53	1127.5	5.871	0.01539	*
asp_maj	1	223.51	1124.5	2.855	0.09109	.

Model 2.1:

diverzita ~ vh01_std + d1_3 + d3_10 + d10_20 + d20_40 + elev_std +
profil_std + asp_maj

	Df	Deviance	AIC	LRT	Pr(>Chi)	
<none>		220.70	1121.7			
vh01_std	1	241.37	1140.4	20.675	5.441e-06	***
d1_3	1	260.84	1159.8	40.139	2.365e-10	***
d3_10	1	230.06	1129.1	9.360	0.002218	**
d10_20	1	224.91	1123.9	4.210	0.040197	*
d20_40	1	223.05	1122.1	2.356	0.124791	
elev_std	1	220.96	1120.0	0.266	0.605977	
profil_std	1	226.70	1125.7	6.000	0.014304	*
asp_maj	1	223.81	1122.8	3.118	0.077428	.

Model 2.2:

diverzita ~ vh01_std + d1_3 + d3_10 + d10_20 + d20_40 + profil_std +
asp_maj

	Df	Deviance	AIC	LRT	Pr(>Chi)	
<none>		220.96	1120.0			
vh01_std	1	242.47	1139.5	21.510	3.520e-06	***
d1_3	1	261.20	1158.2	40.240	2.246e-10	***
d3_10	1	230.06	1127.1	9.094	0.002564	**
d10_20	1	224.94	1122.0	3.978	0.046089	*
d20_40	1	223.24	1120.2	2.273	0.131649	
profil_std	1	227.10	1124.1	6.139	0.013225	*
asp_maj	1	223.95	1121.0	2.985	0.084034	.

Model 2.3:

diverzita ~ vh01_std + d1_3 + d3_10 + d10_20 + profil_std + asp_maj

	Df	Deviance	AIC	LRT	Pr(>Chi)	
<none>		223.24	1120.2			
vh01_std	1	257.07	1152.1	33.834	6.002e-09	***
d1_3	1	263.53	1158.5	40.297	2.182e-10	***
d3_10	1	230.24	1125.2	7.004	0.008131	**
d10_20	1	228.13	1123.2	4.899	0.026879	*
profil_std	1	228.60	1123.6	5.365	0.020543	*
asp_maj	1	226.81	1121.8	3.579	0.058526	.

4.2 Výběr modelu

Srovnáme-li všechny varianty modelů na základě kritéria AIC a vysvětlené míry deviance (tab. 17), jako nejlepší model z hlediska dosažené hodnoty AIC se jeví model 1.4, který zároveň vysvětluje více variability vysvětlované proměnné (59 %, tj. $((531,99 - 218,20)/531,99)*100$), viz tab. 16) než model 1.5 (58,5 %). V tomto smyslu jde však o rozdíl minimální.

Tab. 17: Dosažené hodnoty kritéria AIC a míra vysvětlené deviance pro všechny varianty modelů.

	AIC	vysvětlená deviance (%)
Model 1	1118.145	59.6
Model 1.1	1116.536	59.5
Model 1.2	1114.868	59.4
Model 1.3	1113.933	59.2
Model 1.4	1113.214	59.0
Model 1.5	1113.586	58.5
Model 2	1123.670	58.5
Model 2.1	1121.708	58.5
Model 2.2	1119.974	58.5
Model 2.3	1120.247	58.0

Tab. 18: Výstup funkce *summary* pro model 1.4.

```
Call:
glm(formula = diverzita ~ cc_01 + vh01_std + d1_3 + d3_10 + profil_std,
     family = poisson, data = var1)

Deviance Residuals:
    Min       1Q   Median       3Q      Max
-2.9665  -0.6791  -0.1129   0.5919   2.4044

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept)  1.2975700  0.0624454  20.779 < 2e-16 ***
cc_01         0.0034734  0.0009533   3.643 0.000269 ***
vh01_std     0.1109869  0.0136329   8.141 3.92e-16 ***
d1_3         0.0136268  0.0023471   5.806 6.41e-09 ***
d3_10        0.0021485  0.0013910   1.545 0.122448
profil_std   0.0080529  0.0044276   1.819 0.068941 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for poisson family taken to be 1)

    Null deviance: 531.99  on 230  degrees of freedom
Residual deviance: 218.20  on 225  degrees of freedom
AIC: 1113.2

Number of Fisher Scoring iterations: 4
```


4.3 Významnost prediktorů

Jak je patrné ze souhrnu výsledného modelu (tab. 18), nejvyšší míry signifikance z použitých prediktorů ($p = 3,92e-16$) dosahuje směrodatná odchylka výšky vegetace (*vh01_std*). Je-li vytvořen samostatný model pouze s touto proměnnou, vysvětluje více než 40 % variability, tj. $((531,99 - 315,30)/531,99) \cdot 100$ (viz tab. 17). Vyneseme-li hodnoty druhové diverzity a této proměnné do bodového grafu, je patrný jasný trend, který naznačuje, že se zvyšující se variabilitou ve výšce vegetace roste také druhová diverzita.

Tab. 19: Výstup funkce *summary* pro model s proměnnou *vh01_std*.


```
glm(formula = diverzita ~ vh01_std, family = poisson, data = var2)

Deviance Residuals:
    Min       1Q   Median       3Q      Max
-3.3453  -1.0149  -0.1495   0.6803   3.2830

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept)  1.66053    0.04153   39.98  <2e-16 ***
vh01_std     0.15012    0.01001   15.00  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for poisson family taken to be 1)

    Null deviance: 531.99  on 230  degrees of freedom
Residual deviance: 315.30  on 229  degrees of freedom
AIC: 1202.3
```



Obř. 17: Bodový graf znázorňující závislost druhové diverzity na směrodatné odchylce výšky vegetace (*vh01_std*).

Výsledky modelu naznačují, že druhým nejvýznamnějším prediktorem diverzity ptačích druhů ($p = 6.41e-09$) je densita vegetace v keřovém patře ($d1_3$). Tato proměnná samostatně vysvětluje 14,6 % variability, tj. $((531,99 - 454,34)/531,99)*100$ (viz tab. 18). Ze závislosti obou proměnných (obr. 18) lze vyvodit, že při nízkém zastoupení vegetace v keřovém patře je přítomen spíše nižší počet druhů, zatímco při vyšším zastoupení diverzita spíše roste. Trend však není zcela jednoznačný a může souviset s odlišnými biotopovými nároky, neboť některé druhy mohou naopak vyžadovat vyšší zastoupení vegetace ve vyšších patrech nebo naopak přízemní vegetaci.

Tab. 20: Výstup funkce *summary* pro model s proměnnou $d1_3$.

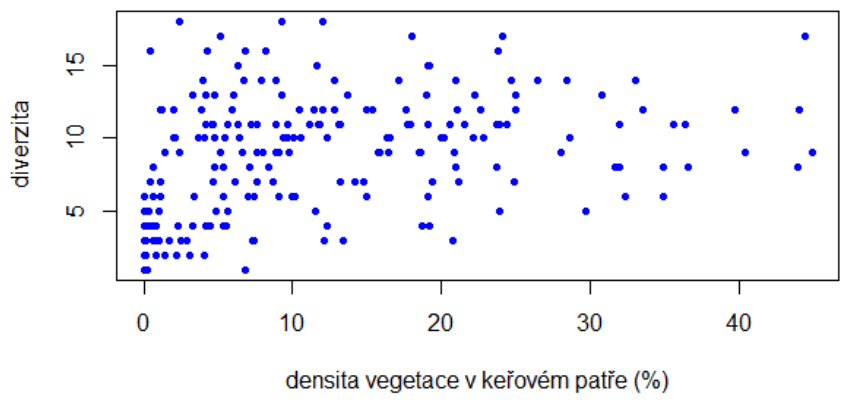
```
glm(formula = diverzita ~ d1_3, family = poisson, data = var2)

Deviance Residuals:
    Min       1Q   Median       3Q      Max
-3.0352 -1.2454 -0.1152  0.9178  3.4278

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept)  1.915921   0.034037  56.289  <2e-16 ***
d1_3          0.017268   0.001902   9.081  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for poisson family taken to be 1)

    Null deviance: 531.99  on 230  degrees of freedom
Residual deviance: 454.34  on 229  degrees of freedom
AIC: 1341.3
```



Obr. 18: Bodový graf znázorňující závislost druhové diverzity na densitě vegetace v keřovém patře ($d1_3$).

Jako třetí nejvýznamnější proměnná byla vyhodnocena celková pokryvnost vegetací (*cc_01*). Přestože na základě dosažené hladiny signifikance ve výsledném modelu (tab. 18) se prediktor může jevit méně významným, při jeho samostatném použití je vysvětleno necelých 37 % variability, tj. $((531,99 - 337,20)/531,99) \cdot 100$ (viz tab. 21), což je srovnatelné s hodnotou dosaženou v případě prediktoru *vh01_std*. Vyneseme-li závislost diverzity na celkové pokryvnosti do bodového grafu, je dobře patrný trend rostoucí diverzity s rostoucí pokryvností (obr. 19). Možné vysvětlení spočívá v tom, že při celkové vyšší pokryvnosti území vegetací může být zastoupeno více vegetačních pater, která nabízí habitat pro širší spektrum druhů.

Tab. 21: Výstup funkce *summary* pro model s proměnnou *cc_01*.

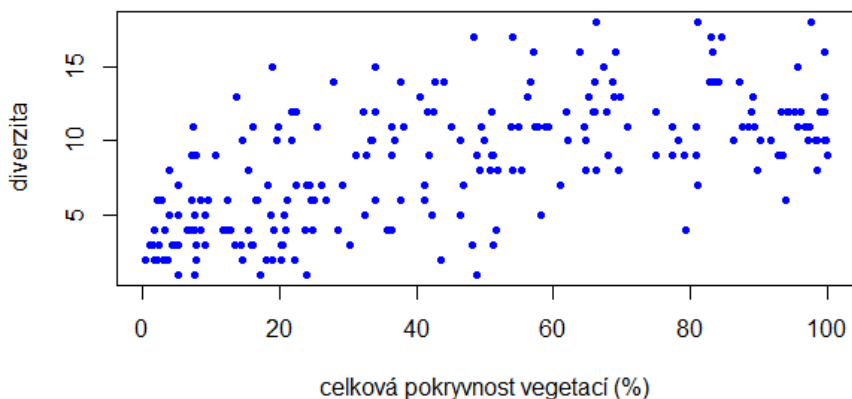
```
glm(formula = diverzita ~ cc_01, family = poisson, data = var1)

Deviance Residuals:
    Min       1Q   Median       3Q      Max
-3.2291 -1.0323 -0.2258  0.7062  2.9767

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept) 1.6378429  0.0447729  36.58  <2e-16 ***
cc_01        0.0099069  0.0007098  13.96  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for poisson family taken to be 1)

Null deviance: 531.99  on 230  degrees of freedom
Residual deviance: 337.20  on 229  degrees of freedom
AIC: 1224.2
```



Obr. 19: Bodový graf znázorňující závislost diverzity na celkové pokryvnosti (*cc_01*).

Na hranici významnosti je také jedna z topografických charakteristik – směrodatná odchylka křivosti profilu (*profil_std*). Tato proměnná samostatně vysvětluje 16,3 % variability, tj. $((531,99 - 445,49)/531,99) \cdot 100$ (tab. 22). Závilost diverzity na hodnotách této proměnné (obr. 20) vykazuje rostoucí tendenci a skutečnost, že na plochách s vyšší směrodatnou odchylkou křivosti profilu, a tedy členitějším terénem, nachází habitat více ptačích druhů.

Tab. 22: Výstup funkce *summary* pro model s proměnnou *profil_std*.


```
glm(formula = diverzita ~ profil_std, family = poisson, data = var2)

Deviance Residuals:
    Min       1Q   Median       3Q      Max
-4.5910 -1.2254 -0.0161  0.9154  3.0647

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept)  1.774829   0.042192  42.06  <2e-16 ***
profil_std    0.033150   0.003155  10.51  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for poisson family taken to be 1)

    Null deviance: 531.99  on 230  degrees of freedom
Residual deviance: 445.49  on 229  degrees of freedom
AIC: 1332.5
```



Obr. 20: Bodový graf znázorňující závislost diverzity na směrodatné odchylce křivosti profilu (*profil_std*).

5. DISKUZE

Variabilita ve výšce porostu vyjádřená jako směrodatná odchylka výšky vegetace se ukázala jako jedna z nejvýznamnějších proměnných vysvětlující počet zaznamenaných ptačích druhů. Toto zjištění potvrzuje obecný předpoklad, že ve strukturovaném porostu, který se vyznačuje bohatým podrostem, nachází vhodné prostředí pro hnízdění zpravidla širší spektrum druhů. Jsou však známy i studie ukazující trend opačný (Davies et Asner 2014). Záleží mimo jiné na tom, jaká skupina druhů je v dané studii zahrnuta, zda se nevyznačuje specifickými nároky a zda se tedy vztah její diverzity k variabilitě výšky neliší od obecného předpokladu. To může být případ některých specializovaných skupin, které nachází vhodná stanoviště na plochách v raných stádiích sukcese s otevřeným a nízkým porostem. Příkladem takového druhu je linduška úhorní (*Anthus campestris*) nebo bělořit šedý (*Oenanthe oenanthe*) (Šálek 2012), patřící mezi silně ohrožené druhy České republiky, pro které je vyšší a strukturovaný porost spíše nežádoucí. Pro tyto druhy by nízké hodnoty směrodatné odchylky výšky mohly naopak značit vhodný habitat. Užitečnou proměnnou by mohla představovat také maximální výška vegetace, která nebyla z důvodu korelací do modelu zařazena.

Densita vegetace v intervalu 1 – 3 m popisující procentuální zastoupení vegetace v keřovém patře se ukázala jako druhá významná proměnná odvozená přímo z bodového mračna. Navíc se vyznačuje velice nízkou mírou korelace s ostatními proměnnými a lze tedy předpokládat, že poskytuje informaci, které ostatní proměnné neobsahují. Výsledky naznačují, že vyšší diverzita je spojena spíše s vyšším zastoupením vegetace v keřovém patře, nicméně, jak již bylo zmíněno, tento trend není zdaleka jednoznačný. Je důležité si uvědomit, že nízké hodnoty density v keřovém patře mohou značit několik skutečností – zbývající odrazy jsou např. rovnoměrně rozmístěny ve více patrech, jsou soustředěny pouze v bylinném patře, případně stromovém patře apod. Nižší zastoupení vegetace v keřovém patře tak nutně nemusí značit habitat s nízkou diverzitou. Zde je vhodné zmínit, že celkové výsledky mohou být ovlivněny také volbou intervalů, ve kterých byly proměnné popisující densitu počítány a nabízí se otázka, zda byly tyto intervaly zvoleny správně.

Co se týče pokryvnosti, signifikantní proměnnou se z vybrané dvojice ukázala pouze pokryvnost celková, na rozdíl od pokryvnosti nad 1 m, která byla z druhého modelu překvapivě vyřazena jako první nesignifikantní proměnná, přestože jsou obě výrazně korelované (0,91). Výsledky tedy naznačují, že významnějším prediktorem je celková pokryvnost zahrnující bylinné, keřové i stromové patro, ačkoliv Bergen et al. (2009)

uvádí, že pro diverzitu ptačích druhů je klíčová pokrývnost spíše nad jednotlivými úrovněmi výšky. Dle výsledků byl vyšší počet druhů obecně zaznamenán na plochách s vyšší pokrývností, což lze vysvětlit tak, že na těchto plochách můžeme očekávat porost v pozdější fázi vývoje, s výjimkou zemědělských kultur, kde je sice pokrývnost vysoká, nicméně jde zpravidla o nízký neheterogenní porost. Proto bychom mohli očekávat signifikanci spíše pro pokrývnost nad vyšší úrovní, tedy např. nad 1 m, případně nad 3 m, která nebyla do posuzovaných proměnných zařazena. Davies et Asner (2014) uvádí, že se zvyšující se pokrývností se diverzita naopak snižuje, což vysvětlují tak, že vysoká pokrývnost vede k rostoucímu zastínění a úbytku mezer v porostu, které přispívají k vyšší diverzitě živočichů i rostlin. Protože na Radovesické výsypkce je vegetační kryt zatím na počátku vývoje, nelze vyšší hodnoty pokrývnosti spojovat se zapojenými porosty v pozdější fázi sukcese.

Přestože směrodatná odchylka křivosti profilu je spíše na hranici signifikance, z použitých topografických charakteristik je patrně nejvýznamnější proměnnou. Zjištěný vztah lze dobře odůvodnit významem heterogenity terénu, kterou tato proměnná dobře vystihuje. Vyšší počet druhů lze na základě výsledků očekávat na plochách s členitějším reliéfem, kterým jsou typické plochy ponechané přirozené sukcesí. Tato proměnná může být užitečným ukazatelem, kterým lze odlišit plochy podle způsobu rekultivace, neboť technicky rekultivované plochy se vyznačují uměle zarovnaným terénem.

Vzhledem k velmi výrazným korelacím mezi řadou prediktorů vstupoval do modelu pouze zlomek ze všech připravených proměnných. Korelace proměnných, které jsou odvozeny z jedné datové sady, je běžným jevem, který je pro data odvozená z ALS typický (Müller et al. 2014). Směrodatná odchylka vegetace, jako signifikantní prediktor, byla například vysoce korelovaná se směrodatnou odchylkou výšky vegetačního krytu (0,99), která v modelu použita nebyla, ale logicky bychom u ní mohli očekávat obdobnou významnost. Vysoká míra korelace těchto proměnných však může být dána pouze specifickým charakterem porostu posttěžební lokality a nemusí být zdaleka pravidlem v jiných typech prostředí – v případě vysokého a zapojeného porostu se současně vyvinutými nižšími patry by se hodnoty směrodatné odchylky vegetace a směrodatné odchylky vegetačního krytu lišily. Podobná situace mohla nastat i u jiných dvojic prediktorů. Přestože tímto způsobem byly nejvýraznější korelace eliminovány, některé společně použité proměnné jsou mezi sebou stále poměrně korelované a jeden prediktor tedy nese část informace obsaženou v jiném z nich. Může pak dojít k tomu, že se některý z prediktorů jeví v modelu jako nevýznamný, ačkoliv samostatně nebo v kombinaci s jinými prediktory by měl vliv signifikantní. V případě výrazných korelací

a interakcí pak výsledky závisí také na tom, která kombinace prediktorů je v modelu nakonec použita a také pořadí, v jakém jsou do modelu přidány.

Protože diverzita ptačích druhů je kromě horizontální a vertikální struktury porostu a terénu patrně ovlivněna řadou dalších faktorů, které v této práci a vybraném modelu nejsou zahrnuty, lze míru vysvětlené variability výsledným modelem dosahující téměř 60 % považovat za vysokou hodnotu. Srovnáním může být studie, kterou provedli Goetz et al. (2007), kde bylo proměnnými odvozenými z ALS vysvětleno maximálně 45 % variability v diverzitě ptačích druhů. Lesak et al. (2011) vysvětlili pouze 15 – 20 % variability. Kromě jednoduchého vyjádření diverzity celkovým počtem zaznamenaných druhů použitým v této práci, lze diverzitu jako vysvětlovanou proměnnou vyjádřit komplexněji, např. formou různých indexů diverzity, které zahrnují informaci také o početnosti případně zastoupení jednotlivých druhů (např. Wallis et al. 2016). Důležité je také co nejvíce eliminovat záznamy, které mají např. pouze charakter přeletů a nevypovídají o vhodnosti habitatu pro daný druh v místě jeho záznamu.

Nakonec je třeba připomenout zmiňovanou časovou prodlevu mezi mapováním druhů a leteckým laserovým skenováním, která činí zhruba 5 let. Takový, případně výraznější, rozdíl je vzhledem k pořizovací ceně ALS dat běžný (např. Huber et al. 2016) a některé studie navíc ukázaly, že nemusí mít významný vliv (Vierling et al. 2014). Nabízí se otázka, zda je v tak dynamickém typu území jako je posttěžební lokalita tento rozdíl přijatelný a do jaké míry by se lišily výsledky získané při použití aktuálních nálezových dat. Použitá data dále nezahrnují pouze vlastní těleso výsypky, ale také jeho blízké okolí, které se charakterem vegetace a terénu může výrazně lišit a výsledky tak nemusí odrážet zákonitosti typické pouze pro posttěžební lokalitu. Zajímavé by mohlo být provedení analýzy pouze pro vlastní těleso výsypky a srovnání obou výsledných modelů. Dalším námětem pro výzkum může být srovnání výsledků získaných na základě jiné vhodné modelovací techniky, jako jsou např. zobecněné aditivní modely (GAM, *generalized additive models*). Nové poznatky by jistě přineslo také vytvoření modelů distribuce vybraných druhů ptáků na základě prezenčních a absenčních dat (Graf et al. 2009). Časté je také rozlišení potravních nebo hnízdních guild (např. Goetz et al. 2007). Tyto modely by mohly přispět k lepšímu porozumění biotopovým nárokům konkrétních zájmových druhů, neboť nároky jednotlivých druhů se mohou výrazně lišit.

6. ZÁVĚR

Výsledky této práce potvrzují, že data získaná z leteckého laserového skenování jsou dobře využitelná pro popis struktury prostředí posttěžební lokality a umožňují výpočet charakteristik, které mohou ovlivňovat zaznamenaný počet ptačích druhů v oblasti Radovesické výsypky a blízkého okolí. Ukázalo se, že mezi proměnné vysvětlující nejvíce variability v diverzitě patří ze skupiny vegetačních charakteristik směrodatná odchylka výšky vegetace, densita vegetace v keřovém patře a celková pokryvnost vegetací. Z topografických charakteristik odvozených z digitálního modelu terénu je patrně nejvýznamnější proměnnou směrodatná odchylka křivosti profilu, která dobře vystihuje členitost terénu. Výsledným vybraným modelem bylo vysvětleno 59 % variability, což lze považovat za vysokou hodnotu, neboť druhovou diverzitu ptáků jistě ovlivňuje řada dalších faktorů, které nebyly v této práci zahrnuty. Výsledky mohly být ovlivněny vysokou mírou korelace mezi prediktory a při výběru tedy mohlo potenciálně dojít k vyřazení jiných signifikantních proměnných. Při interpretaci výsledků je třeba vzít v úvahu také časovou prodlevu ve sběru obou typů vstupních dat. Námětem pro další výzkum může být srovnání výsledků získaných na základě jiné vhodné modelovací techniky, jako jsou např. zobecněné aditivní modely. Nové poznatky by přineslo také vytvoření modelů distribuce konkrétních vybraných druhů ptáků, které by mohlo přispět k lepšímu porozumění jejich biotopovým nárokům.

7. POUŽITÁ LITERATURA

- [1] Bergen K. M., Goetz S. J., Dubayah R. O., Henebry G. M., Hunsaker C. T., Imhoff M. L. et Radeloff V. C., 2009: Remote sensing of vegetation 3-D structure for biodiversity and habitat: review and implications for lidar and radar spaceborne missions. *Journal of Geophysical Research: Biogeosciences* 114.
- [2] Bradbury R. B., Hill R. A., Mason D. C., Hinsley S. A., Wilson J. D., Balzter H. et Bellamy P. E., 2005: Modelling relationships between birds and vegetation structure using airborne LiDAR data: a review with case studies from agricultural and woodland environments. *Ibis* 147(3): 443-452.
- [3] Cibulka T., Mikita M. et Klimánek M., 2013: Hodnocení metod interpolace dat leteckého laserového skenování pro detekci stromů a měření jejich výšek. *Zprávy lesnického výzkumu* 58(2): 99-106.
- [4] Davies A. B. et Asner G. P., 2014: Advances in animal ecology from 3D-LiDAR ecosystem mapping. *Trends in ecology & evolution* 29(12): 681-691.
- [5] Dolanský T., 2004: Lidary a letecké laserové skenování. Univerzita J. E. Purkyně, Ústí nad Labem.
- [6] Eldegard K., Dirksen J. W., Ørka H. O., Halvorsen R., Næsset E., Gobakken T. et Ohlson M., 2014: Modelling bird richness and bird species presence in a boreal forest reserve using airborne laser-scanning and aerial images. *Bird Study* 61(2): 204-219.
- [7] Elith J. et Leathwick J. R., 2009: Species distribution models: ecological explanation and prediction across space and time. *Annual Review of Ecology, Evolution, and Systematics* 40(1): 677-697.
- [8] Evans J. S., Hudak A. T., Faux R. et Smith A., 2009: Discrete return lidar in natural resources: Recommendations for project planning, data processing, and deliverables. *Remote Sensing* 1(4): 776-794.
- [9] Farrell S. L., Collier B. A., Skow K. L., Long A. M., Campomizzi A. J., Morrison M. L. et Wilkins R. N., 2013: Using LiDAR-derived vegetation metrics for high-resolution, species distribution models for conservation planning. *Ecosphere* 4(3): 1-18.

- [10] Franklin J., 2009: Mapping species distributions: spatial inference and prediction. Cambridge University Press.
- [11] Fraštia M. et Řehoř M., 2014: Zahlazování následků hornické činnosti – rekultivace Radovesické výsypky. Sympoziem Hornická Příbram ve vědě a technice 2014, dostupné z: <<http://slon.diamo.cz/hpvt/2014/Z/Z%2010.pdf>>
- [12] Frouz J., Mudrák O., Reitschmiedová E., Walmsley A., Vachová P., Šimáčková H., Albrechtová J., Moradi J. et Kučera J., 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* 205: 50-58.
- [13] García-Feced C., Tempel D. J. et Kelly M., 2011: LiDAR as a tool to characterize wildlife habitat: California spotted owl nesting habitat as an example. *Journal of Forestry* 109(8): 436-443.
- [14] Goetz S., Steinberg D., Dubayah R. et Blair B., 2007: Laser remote sensing of canopy habitat heterogeneity as a predictor of bird species richness in an eastern temperate forest, USA. *Remote Sensing of Environment* 108(3): 254-263.
- [15] Graf R. F., Mathys L. et Bollmann K., 2009: Habitat assessment for forest dwelling species using LiDAR remote sensing: Capercaillie in the Alps. *Forest Ecology and Management* 257(1): 160-167.
- [16] Grohmann C. H., Smith M. J. et Riccomini C., 2011: Multiscale analysis of topographic surface roughness in the Midland Valley, Scotland. *IEEE Transactions on Geoscience and Remote Sensing* 49(4): 1200-1213.
- [17] Guisan A. et Zimmermann N. E., 2000: Predictive habitat distribution models in ecology. *Ecological Modelling* 135(2): 147-186.
- [18] Hill R. A. et Hinsley S. A., 2015: Airborne lidar for woodland habitat quality monitoring: Exploring the significance of lidar data characteristics when modelling organism-habitat relationships. *Remote Sensing* 7(4): 3446-3466.
- [19] Huber N., Kienast F., Ginzler C. et Pasinelli G., 2016: Using remote-sensing data to assess habitat selection of a declining passerine at two spatial scales. *Landscape ecology* 31(9): 1919-1937.

- [20] Isenburg M., 2013: Tutorial: derivative production (online) [cit. 10. 4. 2018], dostupné z <<https://rapidlasso.com/2013/10/20/tutorial-derivative-production>>.
- [21] Isenburg M., 2014: Rasterizing Perfect Canopy Height Models from LiDAR (online) [cit. 6.3.2018], dostupné z <<https://rapidlasso.com/2014/11/04/rasterizing-perfect-canopy-height-models-from-lidar>>.
- [22] Isenburg M., 2017: Plots to Stands: Producing LiDAR Vegetation Metrics for Imputation Calculations (online) [cit. 8.3.2018], dostupné z <<https://rapidlasso.com/2017/03/27/plots-to-stands-producing-lidar-vegetation-metrics-for-imputation-calculations>>.
- [23] Isenburg M.: LAStools - efficient tools for LiDAR processing (version 171231, licensed). <http://rapidlasso.com/LAStools>
- [24] John J., 2011: Letecké laserové skenování (ALS/LIDAR) a možnosti jeho využití v archeologii – úvodní informace o projektu. Počítačová podpora v archeologii 3: 24-28.
- [25] Khosravipour A., Skidmore A. K., Isenburg M., Wang T. et Hussin Y. A., 2014: Generating pit-free canopy height models from airborne lidar. *Photogrammetric Engineering & Remote Sensing* 80(9): 863-872.
- [26] Lassueur T., Joost S. et Randin C. F., 2006: Very high resolution digital elevation models: Do they improve models of plant species distribution? *Ecological Modelling* 198(1): 139-153.
- [27] Lesak A. A., Radeloff V. C., Hawbaker T. J., Pidgeon A. M., Gobakken T. et Contrucci K., 2011: Modeling forest songbird species richness using LiDAR-derived measures of forest structure. *Remote Sensing of Environment* 115(11): 2823-2835.
- [28] Li X. et Wang Y., 2013: Applying various algorithms for species distribution modelling. *Integrative Zoology* 8(2): 124-135.
- [29] Miller J., 2010: Species distribution modeling. *Geography Compass* 4(6): 490-509.
- [30] Moudrý V. et Gdulová K., 2015: Lesson 12 – Light Detection and Ranging (LiDAR), učební text ke cvičení GIS II, Fakulta životního prostředí, ČZU, Praha.

- [31] Müller J., Stadler J. et Brandl R., 2010: Composition versus physiognomy of vegetation as predictors of bird assemblages: The role of lidar. *Remote Sensing of Environment* 114(3): 490-495.
- [32] Müller J., Bae S., Röder J., Chao A. et Didham R. K., 2014: Airborne LiDAR reveals context dependence in the effects of canopy architecture on arthropod diversity. *Forest ecology and management* 312: 129-137.
- [33] Pearson R. G., 2010: Species' distribution modeling for conservation educators and practitioners. *Lessons in Conservation* 3: 54-89.
- [34] Prach K., 2009: Ekologie obnovy narušených míst VI. Shrnutí a závěrečné poznámky. *Živa* 6/2009: 262 – 264.
- [35] Prach K., Frouz J, Karešová P., Konvalinková P., Koutecká V., Mudrák O., Novák J., Řehounek J., Řehounková K., Tichý L., Trnková R. et Tropek R., 2009: Ekologie obnovy narušených míst II. Místa narušená těžbou surovin. *Živa* 2/2009: 68 – 72.
- [36] R Core Team, 2017: R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>
- [37] Šálek M., 2012: Spontaneous succession on opencast mining sites: implications for bird biodiversity. *Journal of Applied Ecology* 49(6): 1417-1425.
- [38] Šmilauer P., 2007: Moderní regresní metody. Jihočeská univerzita, Biologická fakulta, České Budějovice.
- [39] Tian B., Wang L. et Koike K., 2011: Spatial statistics of surface roughness change derived from multi-scale digital elevation models. *Procedia Environmental Sciences* 7: 252-257.
- [40] Uhlířová K., 2010: Možnosti využití leteckého laserového skenování pro vodohospodářské účely. *Symposium GIS Ostrava*.
- [41] Vierling K. T., Swift C. E., Hudak A. T., Vogeler J. C. et Vierling L. A., 2014: How much does the time lag between wildlife field-data collection and LiDAR-data acquisition matter for studies of animal distributions? A case study using bird communities. *Remote Sensing Letters* 5(2): 185-193.

- [42] Vogeler J. C., Hudak A. T., Vierling L. A., Evans J., Green P. et Vierling K. T., 2014: Terrain and vegetation structural influences on local avian species richness in two mixed-conifer forests. *Remote sensing of environment* 147: 13-22.
- [43] Vojar J., Doležalová J. et Solský M., 2012: Hnědouhelné výsypky – nová příležitost nejen pro obojživelníky. *Ochrana přírody* 67(3): 8-11.
- [44] VÚGTK, 2018: Terminologický slovník zeměměřictví a katastru nemovitostí (online) [cit. 17. 3. 2018], dostupné z <<http://www.vugtk.cz/slovník>>.
- [45] Wallis C. I., Paulsch D., Zeilinger J., Silva B., Fernández G. F. C., Brandl R., Farwig N. et Bendix J., 2016: Contrasting performance of Lidar and optical texture models in predicting avian diversity in a tropical mountain forest. *Remote sensing of environment* 174: 223-232.
- [46] Zuur A. F., Ieno E. N., Walker N. J., Saveliev A. A. et Smith G. M., 2009: *Mixed Effects Models and Extensions in Ecology with R*. Springer, New York.

Seznam odkazů:

URL 1: <<https://earthdatascience.org/courses/earth-analytics/lidar-raster-data-r/lidar-chm-dem-dsm/>> [cit. 10. 4. 2018]

URL 2: <<http://desktop.arcgis.com/en/arcmap/10.3/manage-data/raster-and-images/curvature-function.htm/>> [cit. 10. 4. 2018]

URL 3: <<http://znicenekostely.cz/?load=detail&id=13892>> [cit. 10. 4. 2018]

URL 4:

<https://www.lidovky.cz/foto.aspx?r=ln_domov&c=A171110_135930_ln_domov_rsa&foto=RSA6f3d11_48celkovypohlednaobecskostelem1967Re.jpg> [cit. 10. 4. 2018]

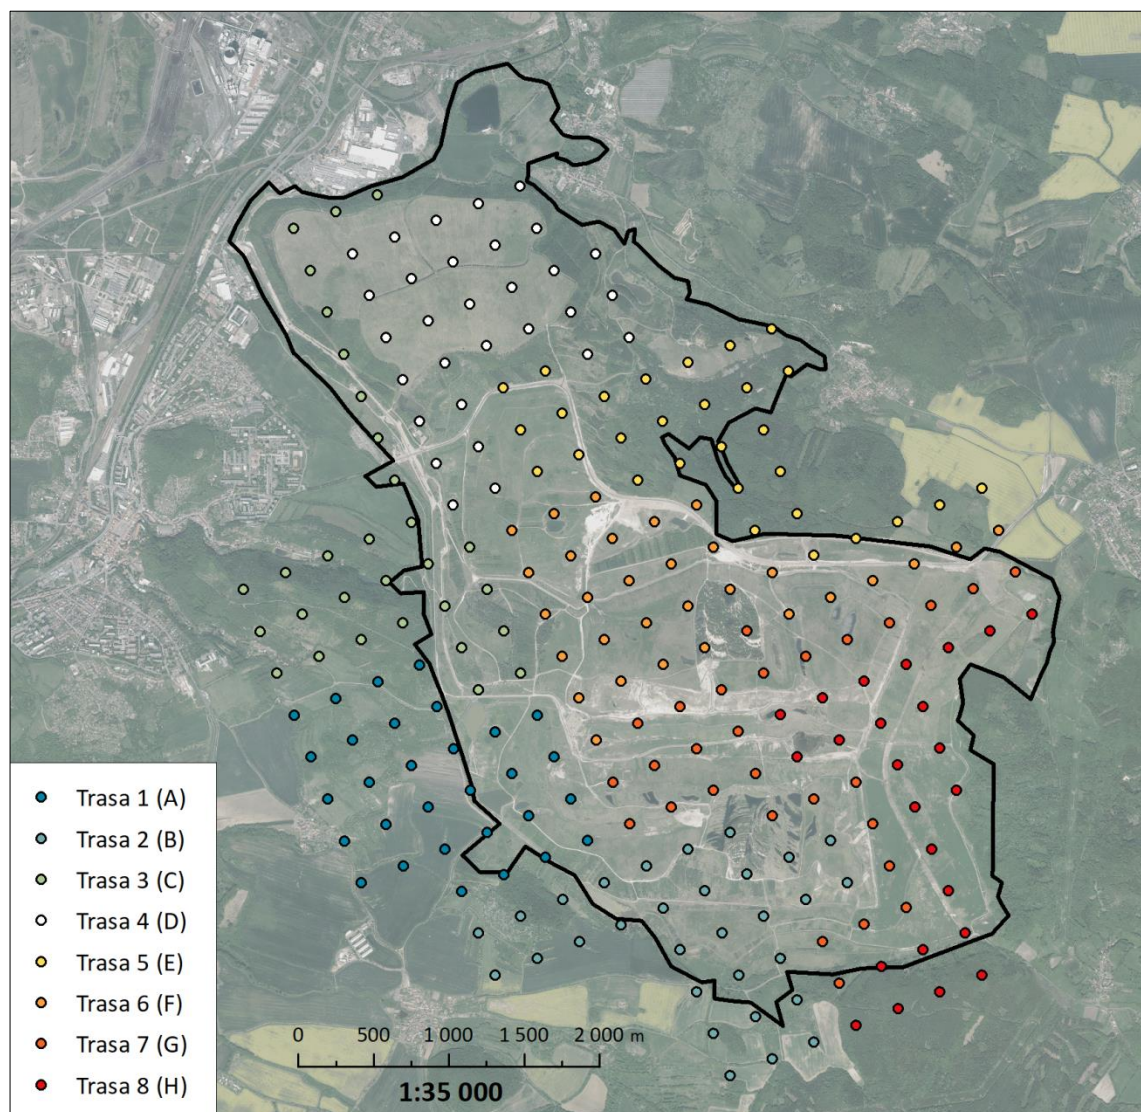
URL 5: <<http://www.hrobcice.cz/data/galerie/hrboviceimg08351.jpg>> [cit. 10. 4. 2018]

URL 6: <<https://www.uzsvm.cz/leden-2317-0-85/uzsvm-jiz-hospodari-s-pozemkem-puvodne-neznameho-vlastnika-na-vysypce-u-biliny-123364/>> [cit. 10. 4. 2018]

8. PŘÍLOHY


Příloha č. 1:

Orientační mapa zobrazující rozmístění mapovacích bodů a tras v oblasti Radovesické výsypky.



Příloha č. 2:

Orientační mapa zobrazující pokrytí území daty leteckého laserového skenování.



Příloha č. 3: Skript použitý pro úpravu nálezových dat (trasa A).

```
library(xlsx)
library(plyr)
library(foreign)
library(reshape2)
library(data.table)

setwd("F:/DP/data/BODOVKY/Sona_Mullerova/TRASA_A")

dfTab_all <- read.xlsx2("RADOVESICKA_2012_Vl_Bejcek_kontrola_1.xls",
sheetIndex = 1, encoding = "UTF-8", stringsAsFactors = F)
dfTab2_all <- read.xlsx2("RADOVESICKA_2012_Vl_Bejcek_kontrola_2.xls",
sheetIndex = 1, encoding = "UTF-8", stringsAsFactors = F)

dfTab <- subset(dfTab_all)
dfTab <- dfTab[colnames(dfTab) != "encoding"]
dfTab <- dfTab[4:(ncol(dfTab))]
dfTab[dfTab == ""] <- 0
dfTab[dfTab != 0] <- 1

dfTab2 <- subset(dfTab2_all)
dfTab2 <- dfTab2[colnames(dfTab2) != "encoding"]
dfTab2 <- dfTab2[4:(ncol(dfTab2))]
dfTab2[dfTab2 == ""] <- 0
dfTab2[dfTab2 != 0] <- 1

dfTab <- sapply(dfTab, as.numeric)
dfTab2 <- sapply(dfTab2, as.numeric)

x <- as.matrix(dfTab)
y <- as.matrix(dfTab2)

resultdf <- as.data.frame(x + y)
resultdf[resultdf != 0] <- 1
fname <- names(resultdf)
sumTab <- data.frame(matrix(, nrow=0, ncol=2))

for(tile in fname){
  ntable <- count(resultdf, tile)
  ntable <- subset(ntable, ntable[1] != 0)
  sum <- sum(ntable$freq)
  newRow <- data.frame(tile, sum)
  sumTab <- rbind(sumTab, newRow)
}

sumTab$tile <- gsub("X", "A", sumTab$tile)
write.dbf(sumTab, "diversity_trasa_A.dbf", factor2char = F)
```


Příloha č. 4: Skript použitý pro tvorbu pit-free CHM.

```
blast2dem -v -lof file_list.9440.txt -merged -drop_classification 6 -
drop_classification 7 -drop_classification 15 -drop_z_above 0.1 -
elevation -odir "F:\DP\CHM\tmp_chm" -o "chm_ground.bil"

lasthin -v -lof file_list.10292.txt -merged -drop_classification 6 -
drop_classification 7 -drop_classification 15 -subcircle 0.05 -step 0.5
-highest -odir "F:\DP\CHM" -o "temp.laz"

blast2dem -v -i "F:\DP\CHM\tmp.laz" -elevation -kill 3 -odir
"F:\DP\CHM\tmp_chm" -o "chm_00.bil"

blast2dem -v -i "F:\DP\CHM\tmp.laz" -drop_z_below 2 -elevation -kill 3
-odir "F:\DP\CHM\tmp_chm" -o "chm_02.bil"

blast2dem -v -i "F:\DP\CHM\tmp.laz" -drop_z_below 5 -elevation -kill 3
-odir "F:\DP\CHM\tmp_chm" -o "chm_05.bil"

blast2dem -v -i "F:\DP\CHM\tmp.laz" -drop_z_below 10 -elevation -kill
3 -odir "F:\DP\CHM\tmp_chm" -o "chm_10.bil"

blast2dem -v -i "F:\DP\CHM\tmp.laz" -drop_z_below 15 -elevation -kill
3 -odir "F:\DP\CHM\tmp_chm" -o "chm_15.bil"

blast2dem -v -i "F:\DP\CHM\tmp.laz" -drop_z_below 20 -elevation -kill
3 -odir "F:\DP\CHM\tmp_chm" -o "chm_20.bil"

blast2dem -v -i "F:\DP\CHM\tmp.laz" -drop_z_below 25 -elevation -kill
3 -odir "F:\DP\CHM\tmp_chm" -o "chm_25.bil"


blast2dem -v -i "F:\DP\CHM\tmp.laz" -drop_z_below 30 -elevation -kill
3 -odir "F:\DP\CHM\tmp_chm" -o "chm_30.bil"

blast2dem -v -i "F:\DP\CHM\tmp.laz" -drop_z_below 35 -elevation -kill
3 -odir "F:\DP\CHM\tmp_chm" -o "chm_35.bil"

lasgrid -v -i "F:\DP\CHM\tmp_chm\chm*.bil" -merged -elevation -highest
-odir "F:\DP\CHM" -o "chm1.bil"

lasgrid -v -i "F:\DP\CHM\tmp_chm\chm*.bil" -merged -elevation -highest
-false -set_min_max 0 35 -odir "F:\DP\CHM" -o "chm2.tif"
```

Příloha č. 5: Výřez z CHM pro jihovýchodní část Radovesické výsypky.



Příloha č. 6: Výřez ze stínovaného DTM pro jihovýchodní část Radovesické výsypky.

