

Univerzita Karlova v Praze

Přírodovědecká fakulta

Studijní program: Kartografie, geoinformatika a dálkový průzkum Země



Mgr. Petr Hofman

Modelování budov z dat leteckého laserového
skenování se zaměřením na bodová mračka nízké
hustoty

Building modeling from airborne laser scanning point
clouds of low density

Rigorózní práce

Vedoucí práce: Ing. Markéta Potůčková, Ph.D.

Praha 2018

PROHLÁŠENÍ

Prohlašuji, že jsem rigorózní práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného akademického titulu. Souhlasím se zapůjčováním této práce pro studijní účely a souhlasím s tím, aby byla řádně vedena v evidenci vypůjčovatelů.

Petr Hofman

Praha, 24. 5. 2018

PODĚKOVÁNÍ

Rád bych na tomto místě poděkoval své školitelce Ing. Markétě Potůčkové, Ph.D. za cenné rady a pomoc během psaní této práce i celého doktorského studia. Dále bych chtěl poděkovat Českému úřadu zeměměřickému a katastrálnímu, jmenovitě Ing. Karlu Brázdilovi, CSc., za pomoc s výběrem tématu a poskytnutí dat k praktické části práce.

Největší poděkování ale patří mé manželce a rodičům za trpělivost a obrovskou podporu během celého studia.

ABSTRAKT

Laserové skenování je relativně mladá metoda dálkového průzkumu Země, která si ale rychle získala významné postavení zejména v oblasti detekce a modelování budov a dalších výškových objektů.

Metody pro detekování a 3D modelování budov zpočátku využívaly zejména přístupů “řízených modelem” (*model-driven*), které porovnávají rozložení mračna laserových bodů se sadou předdefinovaných modelů. Metoda určující typ střešního pláště pomocí takového přístupu byla představena v článku Hofman, Potůčková (2012). Velikou výhodou přístupu řízeného modelem je relativní odolnost vůči nedostatkům dat, zejména nízké hustotě bodového mračna, polohové nepřesnosti bodů atd. Naopak nedostatkem těchto metod je omezení výstupu na přednastavenou sadu modelů, která nemůže obsáhnout rozmanitost reálných budov.

Z tohoto důvodu se v současnosti téměř výhradně používá přístupů “řízených daty” (*data-driven*). Tyto metody hledají v datech pouze sadu primitiv, nejčastěji střešních rovin, ze kterých se výsledný model dodatečně skládá. Zásadním přínosem je mnohem vyšší univerzálnost výsledných modelů. Naopak nevýhodou jsou obecně vyšší nároky na kvalitu dat, zejména hustotu bodového mračna. Ve studii Hofman, Potůčková (2017) byla představena metoda, která ačkoliv využívá přístupů řízeného daty, dokáže spolehlivě detekovat budovy i ve velmi řídkém bodovém mračnu. Při hustotě cca 1,5 bodů/m² dosahuje spolehlivosti 97 % a úplnosti 87 % detekovaných budov.

Významným nedostatkem současného výzkumu v oblasti modelování budov z dat leteckého laserového skenování je absence standardizovaného hodnocení kvality výsledků, která znemožňuje objektivní srovnání použitých metod. Studie Potůčková, Hofman (2016) analyzuje možné hodnotící přístupy a navrhuje používání metriky hodnocení založené na porovnání ploch (*area-based*), která je jasně definovaná, robustní a má vysokou vypovídací hodnotu o kvalitě detekovaných budov.

ABSTRACT

Laser scanning is a relatively recent remote sensing method which nevertheless quickly gained a prominent position, especially in the area of building detection and 3D modeling.

Methods for building detection and 3D modeling initially used model-driven approaches which compare a laser scanning point cloud to a set of predefined building models. A method for determining building roof types using such approaches was presented in the article of Hofman, Potůčková (2012). An important advantage of model-driven approaches is their relative robustness to various data deficiencies such as low point density or low spatial accuracy. However, output of such methods is limited to a predefined set of building models and does not allow for diversity of actual buildings.

For this reason, approaches used almost exclusively nowadays are data-driven. These methods search in datasets for a set of primitives (mostly roof planes) that are subsequently used to form the final model. This approach benefits from universality of resulting models but requires generally high data quality, especially in respect to input point cloud densities. The study of Hofman, Potůčková (2017) presented a data-driven method that can reliably detect buildings even in a very sparse point cloud in spite of using data-driven approach. At a density of about 1.5 points per m², the reliability of buildings detection reaches 97% and its completeness reaches 87%.

A major challenge of current research on building modeling from laser scanning data is absence of a standardized quality evaluation metric that prevents objective relative comparison of the methods applied. Potuckova, Hofman (2016) analyze possible assessment approaches and propose the use of area-based assessment metric that is clearly defined, robust, and highly accurate.

OBSAH

Úvod	6
Vývoj modelování budov z dat LLS	7
Historie leteckého laserového skenování	7
Modelování budov z dat LLS	7
Přístup řízený modelem	9
Přístup řízený daty	9
Nové typy informací v datech LLS	11
Full-wave laserová data	11
Multispektrální laserová data	11
Význam řídkého bodového mračna LLS	12
Určení střešního pláště a detekce budov v bodovém mračnu s nízkou hustotou bodů	14
Určení typu střešního pláště z řídkého bodového mračna	14
Komplexní přístup extrahování obrysů budov z řídkého bodového mračna	15
Postup zpracování	15
Výsledky	15
Hlavní přínosy	16
Hodnocení kvality detekce budov	19
Srovnání hodnotících metrik detekce budov	19
Plošně založená hodnotící metrika	20
Závěr	21
Zdroje	22
Seznam publikací zařazených do rigorózní práce	27

1. Úvod

Data leteckého laserového skenování (LLS) patří dnes již neodmyslitelně k běžným prostředkům dálkového průzkumu Země a množství aplikací, jako je zejména klasifikace povrchu a 3D modelování objektů v městském prostředí, bychom si bez nich už ani nedokázali představit a jen těžko lze uvěřit, že ještě před relativně nedávnou dobou nebyla technologie plošného sběru laserových dat vůbec možná.

Tato práce je rozdělena na dvě hlavní části. Teoretická část v kapitole 2 popisuje vývoj a vlastnosti leteckého laserového skenování a jeho využití pro detekci a 3D modelování budov. Praktická část v kapitole 3 představuje dvě nové metody využívající data LLS pro určení typu střešního pláště a detekci obrysů budov. Kromě metod na samotnou detekci budov je v kapitole 4 představena i analýza hodnotících metrik detekovaných obrysů a navržena metrika pro objektivní srovnání výsledků detekčních algoritmů.

2. VÝVOJ MODELOVÁNÍ BUDOV Z DAT LLS

2.1. HISTORIE LETECKÉHO LASEROVÉHO SKENOVÁNÍ

Technologie laserového skenování patří v současné době mezi nejvýznamnější metody získávání prostorových dat. Laserové skenery umístěné na pozemním nebo vzdušném nosiči sbírají prostorová data s nebývale vysokou rychlostí a přesností. Díky metodám přímého georeferencování je navíc náročnost jejich zpracování relativně nízká, což dále přispělo k prosazení tohoto typu dat pro nespočetné množství aplikací.

První pionýrské projekty leteckého laserového měření byly prováděny už v 60. letech minulého století, jen pár let po vynálezu laseru v roce 1960. Zásadním způsobem se o rozvoj této technologie zasloužila NASA během projektu Arktického topografického mapování. V této době stále šlo pouze o jednotlivá měření podél dráhy letu s velmi omezeným využitím v praxi. Proti již zavedeným a hojně využívaným fotogrammetrickým metodám neumožňovala laserová data analogové uložení a zpracování a nepřicházela u nich v úvahu ani zpětná rektifikace pomocí vlíčovacích bodů. K širokému využití laserového měření proto došlo až v 90. letech minulého století s rozvojem výpočetních technologií, skenovacích zařízení a přímé geolokace pomocí Globálních družicových polohových systémů (GNSS) a inerciálních měřících jednotek (IMU) (Shan, Toth, 2008).

2.2. MODELOVÁNÍ BUDOV Z DAT LLS

Nový datový zdroj se začal velmi rychle využívat v širokém množství aplikací, jako je tvorba digitálních modelů terénu a povrchu (Ma, 2005), určování druhové skladby lesů (Tittmann et al., 2011; Jakubowski et al., 2013) nebo dokonce hledání pozůstatků zaniklých civilizací (Ithaca College, 2018). Mezi nejvýznamnější aplikace pak patří detekce obrysů a 3D modelování budov, nebo jiných lidmi vytvořených objektů.

První pokus o využití dat LLS pro 3D modelování budov provedl Weidner a Förstner (1995) a množství dalších aplikací velmi brzy následovalo. Vývoj v této oblasti byl tak rychlý, že na počátku 21. století laserové skenery v detekci a modelování 3D objektů na dlouhou dobu předčily mnohem starší a rozvinutější fotogrammetrické metody (Remondino, et al., 2014).

Výhody mračna bodů v porovnání s obrazem, zejména v městském prostředí, vyzdvihovala řada autorů. Ma (2005) uvádí, že v porovnání s tradičními fotogrammetrickými metodami je měření povrchu pomocí lidarů při téže výšce letu přesnější, podrobnější a snadněji automaticky zpracovatelné. Maas a Vosselman (1999) zmiňují výhodu absence náročného geometrického vyrovnávání snímků

náchylného k chybám a rovněž aktivního zdroje záření nezávislého na Slunci. Kromě toho, že je tak možné snímat za libovolných světelných podmínek, není intenzita zachyceného záření zatížena stíny, způsobující problémy při analýze dat výškových objektů (Matikainen, 2017). Zhang (1999) zmiňuje, že klasické klasifikační metody multispektrálních snímků dávají špatné výsledky při detekci městských objektů zejména kvůli vysoké komplexnosti spektrálních a geometrických vlastností. Rovněž Khoshelham (2010) uvádí, že samostatné snímky bez stereoskopického efektu neobsahují dostatek informací pro detekci komplexních budov, nebo objektů zakrytých vegetací. Haala a Brenner (1997) doplňují, že analýza překrývajících se stereo snímků 3D modelování i složitých budov sice v zásadě umožňuje, nicméně vysoká komplexita obsažených informací činí úplnou automatizaci celého procesu prakticky nemožnou.

Nicméně, díky nedávnému pokroku v technologii fotogrammetrických kamer i novým algoritmům pro zpracování obrazu se z fotogrammetrie opět stala konkurenceschopná metoda pro automatické 3D modelování objektů. Takzvané high density image matching algoritmy z husté sady snímků pořízených v různých směrech produkují bodové mračno se srovnatelnými geometrickými vlastnostmi, jaké produkují laserové skenery, a je tedy možné jej pomocí již existujících technik zpracovat. Řešená problematika se přitom přesouvá z digitálního zpracování obrazu do geometrické analýzy (Remondino, et al., 2014).

Při srovnávání obou datových zdrojů Remondino et al. (2014) uvádí, že zatímco hustota bodů leteckých skenerů dosahuje, při jednom průletu, běžně hustoty od 1 do 25 bodů na m^2 , mračno bodů získané z leteckých snímků může dosahovat hustoty až 100 bodů na m^2 , což pochopitelně umožňuje modelování do větších detailů. Kromě toho je možné výsledné modely obohatit o fotorealistické textury obsažené přímo v původní datové sadě, nikoliv jako doplňkový datový zdroj. Naopak nevýhodou leteckých snímků zůstává nutnost určení vlíčovacích bodů pro přesné určení polohy. Kromě toho nemohou letecké snímky proniknout hustou vegetací, která může detekované objekty částečně zakrývat, a rovněž některé typy povrchů s vysokou odrazivostí, nebo velkými homogenními plochami mohou způsobit chybné určení polohy bodů v mračnu. Volba technologie proto v současnosti závisí na specifických požadavcích pro konkrétní projekt a na zkušenosti se zpracováním jednoho či druhého typu dat (Remondino, et al., 2014).

Mračna bodů získaná ať už z laserových skenerů, nebo pomocí technologie high density image matching jsou využívána v řadě aplikací, například pro určení sklonu a orientace střešních rovin pro potřeby umístění solárních panelů (Jochem et al., 2009), extrahování obrysů budovy pro tvorbu, kontrolu nebo aktualizaci prostorových databází (Matikainen et al., 2003; Matikainen et al., 2016), rekonstrukci fasády (Cavegn et al., 2014) nebo vytvoření kompletních 3D modelů budov se širokým polem využití v architektuře, územním plánování, modelování šíření znečištění a

dalších urbanistických analýzách (Haala a Brenner, 1997; Hofmann, 2005; Forlani et al., 2006; Teo, 2008; Huang, 2013).

2.3. PŘÍSTUP ŘÍZENÝ MODELEM

První metody pro detekci budov v datech LLS využívaly zejména přístupů řízeného modelem. Jeho základním principem je porovnávání rozložení bodů v datech (nebo odvozeného digitálního modelu povrchu) se sadou přednastavených modelů. Model, který nejlépe odpovídá datům je poté vybrán jako výsledný model budovy. Tento přístup využívá například Weidner a Förstner (1995), Haala et al. (1998) nebo Maas (1999).

Výhodou přístupu řízeného modelem je odolnost vůči nedostatkům dat, jako je zejména nízká hustota bodového mračka, relativní polohová nepřesnost bodů (například z důvodu nedokonale vyrovnaných letových pásů), vysoký podíl bodů ležících mimo střešní roviny (například na přilehlé vegetaci a střešních objektech) atd. Pokud sobě předpřipravený model a zdrojová data z větší části geometricky odpovídají, je možné jej použít, i když část budovy (např. zakrytá vegetací) v datech chybí, nebo je polohově nepřesná. Naopak nedostatkem tohoto postupu je právě omezení výstupu na přednastavenou sadu modelů.

Bohužel ani sebevětší databáze takovýchto šablon nedokáže obsáhnout veškeré tvary budov vyskytující se v reálném světě. Pro 3D modelování komplexů budov se proto často využívaly dostupné 2D prostorové databáze, na základě kterých byly složené budovy rozděleny do obdélníkových částí, ty modelovány samostatně a na závěr opět spojeny do výsledného modelu (Haala et al., 1998; Teo, 2008). Kromě segmentace komplexů budov na jednodušší tvary je možné využít 2D obrysů budov i během rekonstrukční fáze ke stanovení hypotéz o možných tvarech střešního pláště (Haala a Brenner, 1997).

2.4. PŘÍSTUP ŘÍZENÝ DATY

Přístup řízený modelem, hojně využívaný v počátcích vývoje, přestal velmi rychle postačovat rostoucím nárokům detekce a modelování budov. 2D prostorové databáze pro rozložení komplexních tvarů budov do jednodušších segmentů nemají často požadovanou kvalitu, nebo nejsou dostupné vůbec, a segmentace komplexů budov do jednodušších tvarů představuje sama o sobě netriviální úlohu (Brenner, 2000). Navíc ani s jejich pomocí nemůže žádná přednastavená sada modelů zcela pokrýt různorodost reálných objektů. Rostoucí kvalita dostupných dat, zejména vyšší hustota bodového mračka, a zároveň zvyšující se požadavky na přesnost, úplnost a spolehlivost výsledných modelů vyústila v dominantní využívání přístupu řízeného daty.

Tyto metody neurčují parametry celého modelu naráz, ale hledají v datech pouze sadu primitiv, nejčastěji střešních rovin, ze kterých se výsledný model dodatečně skládá. Nevýhodou tohoto přístupu jsou obecně vyšší nároky na kvalitu dat a výpočetní kapacity. Naopak zásadním přínosem je mnohem vyšší univerzálnost výsledných modelů. Většina dostupných metod vychází pouze z omezujícího předpokladu, že budova se musí skládat z rovinných ploch (např. Maas a Vosselman, 1999; Vosselman a Dijkman, 2001; Nardinocchi et al., 2001; Hofmann, 2005; Sohn et al., 2008; Jochem et al., 2009; Huang, 2013). Ačkoliv vyloučení zaoblených střech může být pro řadu aplikací zásadním nedostatkem, Dorninger a Pfeifer (2008) uvádí, že libovolné zaoblené střešní plochy je možné aproximovat sadou rovinných ploch. Míra detailu modelovatelných objektů je pak už závislá pouze na hustotě a přesnosti dostupných dat.

Zajímavý přístup představují v první představované metodě Maas a Vosselman (1999), kteří využívají kombinaci přístupu řízeného modelem a daty. Základní tvar budovy je určen analýzou parametrů přednastavených modelů, které jsou poté doplněny o odchylky od základních tvarů, jako jsou například vikýře.

Rovněž v případě přístupů řízených daty jsou nedostatky laserových dat často kompenzovány dalším zdrojem, zejména leteckými a družicovými snímky (např. Demir, et al., 2008; Matikainen, et al., 2007; Rottensteiner et al., 2005; Tomljenovic et al., 2016) nebo dostupnými prostorovými databázemi (např. Haala a Brenner, 1997; Hofmann et al., 2002). Doplněním dalších typů informace je možné do určité míry snížit vysoké požadavky na rozlišení a kvalitu laserových dat (Haala a Brenner, 1997).

Letecké snímky je možné využít například pro určení přesného průběhu hran a okrajů střechy, které nejsou v laserových datech přímo zachyceny a musí se dopočítávat pomocí průniku střešních rovin, nebo odhadovat na základě rozmístění okrajových bodů. Kromě toho představují letecké a pozemní snímky jedinou možnost na získání fotorealistického vzhledu budov aplikováním obrazových textur na drátěný model (Forlani, 2003).

Spojování rozdílných dat pořízených v různý čas s sebou bohužel přináší i řadu problémů, zejména s ohledem na přesné propojení obou datových sad a dále kvůli změnám radiometrických podmínek, nebo dokonce snímaných objektů v období mezi pořízením obou měření. Řešením tohoto problému je pořízení obou datových sad naráz. Prvním systémem umožňujícím pořízení laserových i obrazových leteckých dat naráz byl CityMapper Airborne Hybrid Sensor společnosti Leica Geosystems (Leica Geosystems AG, 2018)

2.5. NOVÉ TYPY INFORMACÍ V DATECH LLS

Ani kombinace více datových zdrojů ale nepředstavuje ideální řešení. Jednak nemusí být vždy dostupné a především, jak již bylo řečeno, s sebou přináší vlastní problémy. Prostorové databáze bývají často neaktuální, neúplné a nepřesné, nebo obsahují kvalitativně jiný druh informace (běžně například zachycují obrys budovy, kde zeď protíná povrch země, kdežto letecká laserová a obrazová data z principu zachycují plochu střechy, která půdorys budovy většinou přesahuje). U obrazových dat je naopak zásadním problémem automatizace zpracování komplexních informací městského prostředí a často není možné pořídít obě datové sady naráz, aby zachycovaly zájmovou oblast v totožném stavu.

Trendem současnosti v analýze dat LLS je proto jednoznačně neustálé zvyšování hustoty bodů a rovněž využívání kvalitativně jiných informací z vyslaného světelného pulzu, než jen původně využívaných současníc místa odrazu. Jedná se především o zachycení průběhu celého zpětně odraženého signálu (tzv. Full-wave) a dále vysílání laserových paprsků v různých vlnových délkách.

2.5.1. FULL-WAVE LASEROVÁ DATA

Full-wave laserová data poskytují, proti běžným odděleným signálům, doplňující radiometrické i geometrické informace (Azadbakht et al., 2016). Ty neslouží primárně k samotnému 3D modelování, ale přispívají ke spolehlivější klasifikaci bodů v městském prostředí, která je klíčovým krokem celé rekonstrukce. Pevné plochy, jako je holá zem nebo plochá střecha vrací jeden krátký a intenzivní signál. Rozšíření signálu a zároveň snížení amplitudy značí hrubý nebo ukloněný povrch. Větší počet oddělených návratových signálů je typický pro vertikálně členěné pevné objekty, například okraj budovy, a konečně komplexně tvarovaný roztažený návratový signál je charakteristický pro vysokou vegetaci (Harding et al., 2001 in Shan, Toth, 2008). Full-wave informace tak může při rekonstrukci budov přispět například ke spolehlivějšímu odlišení přilehlé vegetace, nebo střešních objektů, jako jsou antény, komíny apod.

Guo (2011) provedl analýzu přínosu širokého spektra parametrů z obrazových a laserových dat pro klasifikaci povrchu z městského prostředí. Zatímco pro přesnost klasifikace všech kategorií se ukázala být nejlepší kombinace obou datových zdrojů, pro detekci kategorie budov poskytoval laser samotný stejně spolehlivé výsledky. Full-wave informace pro detekci budov v datech LLS využívá například Hug (1997), Guo et al. (2011), Niemeyer et al. (2014) nebo Azadbakht et al. (2016).

2.5.2. MULTISPEKTRÁLNÍ LASEROVÁ DATA

Jedním z hlavních důvodů kombinování laserových a obrazových dat byla až do nedávné doby absence multispektrální informace v datech LLS. Ta se poprvé

objevila a ve větší míře začala využívat až v relativně nedávné době - první komerčně dostupný multispektrální LiDAR vyrobila společnost Optech Inc. v roce 2014 (Wichmann et al., 2015). Podobně jako již běžně dostupná multispektrální obrazová data využívá odlišného spektrálního chování (odrazivosti světla v různých vlnových délkách) měřených objektů. Stejně jako full-wave forma se i přínos multispektrálních laserových dat zkoumá především v oblasti klasifikace povrchu země, než ve specializovaném modelování budov, ale i zde může významně přispět zejména pro odfiltrování přilehlé vegetace.

Velkou výhodou obsažení více spektrálních pásem přímo v laserových datech je především nulová časová prodleva (Wichmann et al., 2015) a rovněž absence chyby zanesené pozorováním bodu z různých míst, které jsou s kombinováním více datových sad spojené. Při automatické klasifikaci městského prostředí je významnou výhodou rovněž nepřítomnost jakýchkoliv stínů při použití výhradně laserových dat (Matikainen et al., 2016) a velmi přesné zaměření výšky objektů, která dále přispívá k větší přesnosti klasifikace (Bakula et al., 2016).

Multispektrálních laserových dat pro klasifikaci zemského povrchu využívá například Wichmann et al. (2015), Bakula et al. (2016) nebo Matikainen et al. (2016).

2.6. VÝZNAM ŘÍDKÉHO BODOVÉHO MRAČNA LLS

Přes jednoznačné trendy zahušťování mračna bodů LLS a obohacování dat o další popisné informace se stále využívají a mají vysoký význam i datové sady s nízkou hustotou bodů nesoucí pouze prostorové souřadnice. Jedním z příkladů je Celoplošné snímkování území České republiky Zeměměřickým úřadem (Dušánek, 2014). Důvodem pro využití méně kvalitní datové sady může být zejména vysoká cena pořízení, skladování a manipulování s obrovským objemem dat. Důležitým faktorem může být i doba zpracování dat a rychlost samotného modelování střech budov.

Vysoká výpočetní náročnost nepravidelného bodového mračna je často řešená převodem do pravidelné mřížky, na kterou lze aplikovat klasické metody zpracování obrazu. Rasterizaci mračna laserových bodů pro detekci budov využívá například Hofmann et al. (2002), Alharthy a Bethel (2002), Forlani et al. (2003), Forlani et al. (2006), Rottensteiner a Briese (2002), nebo Matikainen et al. (2007). Tímto zjednodušením je ale nutně velká část informace ztracena (Filin a Pfeifer, 2005). K největším ztrátám přitom dochází v místech s náhlými výškovými změnami, jako jsou okraje budov, hrany mezi střešními rovinami nebo v plochy s přesahující vegetací, které jsou pro získání přesných modelů budov kritické.

Z uvedených důvodů je tedy stále aktuální a žádoucí získat maximální možné množství informací s maximální přesností a spolehlivostí i z méně kvalitních dat LLS. Cílem těchto snah je spojit výhody přístupů řízených modelem i daty a

modelovat s vysokou přesností a spolehlivostí libovolné tvary střech i v řídkém mračnu bodů nesoucích pouze prostorovou informaci.

3. URČENÍ STŘEŠNÍHO PLÁŠTĚ A DETEKCE BUDOV V BODOVÉM MRAČNU S NÍZKOU HUSTOTOU BODŮ

Kapitola shrnuje metodické postupy a výsledky vytvořené autorem a publikované v recenzovaných periodikách, viz Hofman a Potůčková (2012) a Hofman a Potůčková (2016).

3.1. URČENÍ TYPU STŘEŠNÍHO PLÁŠTĚ Z ŘÍDKÉHO BODOVÉHO MRAČNA

V článku Hofman a Potůčková (2012) byla představena metoda automaticky detekující typ střešního pláště i ve velmi řídkém mračnu laserových bodů. Cílem aplikace bylo doplnění 2D prostorové databáze budov o doplňkové údaje o typu střešního pláště a výšce budov. Pro tento účel bylo tedy nejen možné, ale i žádoucí využít dostupné obrysy budov.

S ohledem na účel představené metody a dostupná data byl zvolen přístup řízený modelem. Jednak, jak už bylo řečeno, je tento přístup velmi odolný vůči nedostatkům dat, jako je především nízká hustota bodového mračna. Kromě toho bylo cílem metody doplnění databáze o množinu předem daných typů střešního pláště. Proto nebyl na škodu nedostatek přístupu řízeného modelem, kterým je omezení výstupu na sadu předem nastavených modelů. Cílem studie byla pouze samotná rekonstrukce střechy prokládáním základních tvarů. Proto byly brány v potaz pouze budovy s obdélníkovými půdorysy. Pro segmentaci budov s komplexními půdorysy do základních tvarů by bylo možné použít některou z dostupných metod (Haala et al., 1998; Vosselman a Dijkman, 2001; Teo, 2008).

Na základě známých půdorysů budov a předem zvolených testovaných typů střech (rovinná, štítová, valbová a stanová) bylo mračno bodů rozděleno do shluků odpovídajících testovaným střešním rovinám. Těmito shluky byla pomocí metody nejmenších čtverců iterativně prokládána rovina s postupným odstraňováním odlehlých bodů. Na základě podílu ponechaných bodů u jednotlivých sad střešních rovin byl zvolen nejpravděpodobnější typ střešního pláště.

Postup byl testován celkově na 460 budovách z obcí Brno, Pardubice-Polabiny a Sobotka představujících většinu běžně se vyskytujících druhů zástavby v České republice. Převládající štítové střechy urbanisticky vyspělých měst s množstvím vikýřů a dalších střešních objektů, rovinné střechy panelových domů a průmyslových budov, vilová zástavba s rozdrobenými střešními plášti a konečně vesnické budovy většinou se štítovými střechami, mnohdy částečně zakrytými přilehlou vegetací. Navzdory velmi nízké hustotě bodového mračna (1,5 a 0,25 bodů/m²) dává metoda velmi dobré výsledky. Podíl správně určených typů střešního pláště dosahuje 91 % při hustotě 1,5 bodů/m² a 80 % při hustotě 0,25 bodů/m².

Při aplikaci uvedené metody je nutné mít na zřeteli její úzce zaměřený způsob využití na určení přednastavených typů střešního pláště při známém půdorysu budov. Naopak zásadním přínosem je možnost využití i při extrémně nízké hustotě bodů LLS a plně automatické zpracování.

3.2. KOMPLEXNÍ PŘÍSTUP EXTRAHOVÁNÍ OBRYŠŮ BUDOV Z ŘÍDKÉHO BODOVÉHO MRAČNA

Ve studii Hofman a Potůčková (2017) byla představena automatická metoda extrakce obrysů budov z dat LLS. Přestože se jedná o metodu využívající přístup řízený daty, dosahuje vysoké přesnosti i spolehlivosti detekovaných obrysů budov i v extrémně řídkém bodovém mračnu obsahujícím pouze souřadnice polohy bodů s nízkou relativní výškovou přesností a vysokým podílem odlehlých bodů.

3.2.1. POSTUP ZPRACOVÁNÍ

V první fázi zpracování jsou odfiltrovány body ležící nízko u země, tak aby v datasetu zůstaly pouze body odražené od vysoké vegetace, budov a dalších výškových objektů. Blízkým sousedstvím každého bodu je pomocí metody random sample consensus (RANSAC, Fischer, Bolles, 1981) proložena rovina, z níž je odvozena hodnota sklonu a orientace hledané střešní roviny v místě zkoumaného bodu. Blízko ležící body s podobnými hodnotami sklonu a orientace jsou následně spojovány do klastrů reprezentujících střešní segmenty pomocí růstového algoritmu. Klastry obsahující příliš malé množství bodů (reprezentující s vysokou pravděpodobností vegetaci, nebo jiné výškové objekty neobsahující větší plochy) jsou z následného zpracování odstraněny. Kolem zbývajících bodů je pomocí α -shape algoritmu (Lach a Kerekes, 2008) vytvořen konkávní polygon, reprezentující obrys budovy. Nepravidelný obrys obsahující zbytečné množství bodů je dále zjednodušen pomocí sleeve-fitting algoritmu a upraven do pravidelného pravoúhlého tvaru. Oba algoritmy byly rovněž převzaty z článku Lach a Kerekes (2008).

3.2.2. VÝSLEDKY

Uvedený postup byl testován na 1400 budovách z obcí Pardubice-Polabiny a Ctiněves, pokrývající všechny běžně se vyskytující typy zástavby (a střešních pláštů) v České republice. Navzdory tomu, že metoda využívá pouze prostorové souřadnice bodů, pracuje plně automaticky a nepotřebuje žádný doplňující dataset, dává i při velmi nízké hustotě bodů (v průměru 1,5 bodů/m²) velmi dobré výsledky spolehlivosti (97 %) i úplnosti (87 %) detekovaných budov.

Kvalita detekce budov byla testována i v závislosti na kvantitativních i kvalitativních parametrech bodového mračna i hledaných budov. Analýza ukázala velmi silnou závislost úspěšnosti detekce na relativním počtu bodů na střešní segment. Tento závěr není překvapující s ohledem na využití přístupu řízeného daty

detekujícího střešní plochy podle relativní polohy bodů v prostoru. V případě, že není k dispozici jiná popisná informace umožňující odlišení budovy od ostatních objektů a počet bodů ležící na střešní ploše neumožňuje její spolehlivé rozpoznání v prostoru, nezbyvá už žádný jiný způsob na její automatickou detekci. Kromě počtu bodů na střešní segment byla kvalita určení budov závislá ještě na velikosti šumu (přesnosti vzájemné polohy bodů klíčové pro správné lokální proložení roviny sousedstvím každého bodu). Žádné další faktory - množství přilehlé nebo přesahující vegetace, typ nebo komplexnost střešních pláštů - nevykazovaly žádný vliv na úspěšnost detekce.

Přestože primárním výstupem představené metody je pravidelný 2D obrys budov, uvedený postup detekce jednotlivých střešních rovin lze velmi snadno použít pro vytvoření 3D modelu celé budovy. Omezení na 2D půdorys bylo použito zejména proto, aby bylo možné kvalitu detekce objektivně porovnat s výsledky dalších dostupných metod a aplikací. Problematikou objektivního srovnávání kvality detekovaných budov se podrobně zabývá studie (Potůčková, Hofman, 2016) a je představena v kapitole Srovnávání kvality detekce budov.

3.2.3. Hlavní přínosy

Představená metoda uvádí 2 hlavní přínosy v detekci střešních rovin, které nejsou, v tomto kontextu, použity jinde v dostupných zdrojích. Jedná se o proložení roviny sousedstvím bodu pomocí metody RANSAC a sloučení bodů náležících jedné střešní ploše pomocí růstového algoritmu.

Určení rovinných parametrů pomocí RANSAC

Ransac je iterativní metoda určování parametrů modelu z dostupných dat - v tomto případě určování lokální orientace a sklonu střechy z bodového mračka ležícího v blízkém sousedství zkoumaného bodu. Běžné techniky výpočtu parametrů (například metoda nejmenších čtverců), jejichž cílem je přizpůsobit model všem datům, nemají žádný zabudovaný mechanismus pro odfiltrování hrubých chyb. Tyto průměrující metody fungují dobře za předpokladu, že dataset obsahuje dostatek správných hodnot, které vyváží několik odlehlých měření. Bohužel tento předpoklad v mnoha praktických aplikacích neplatí (Fischler a Bolles, 1981).

Častý výskyt a velká vzdálenost odlehlých bodů platí bohužel i v případě dat LLS. Nejedná se přitom nutně o chyby měření, ale ve většině případů o pulzy odražené od sousedních objektů. V případě modelování střešních pláštů jde nejčastěji o střešní objekty (komíny, antény apod.), fasádu a přilehlou vegetaci. Zásadní výhodou metody RANSAC je schopnost interpretovat data obsahující významný podíl odlehlých měření a to i v případě, že jejich počet převyšuje měření správná. Díky využití RANSAC je představená metoda, proti jiným podobným

přístupům (např. Forlani et al., 2006; Jochem et al., 2009), schopná velmi přesně určit rovinné parametry i na okrajích a vnitřních hranách budov.

RANSAC s sebou nese i některé nedostatky, které je nutné mít při použití na paměti. V první řadě jde o metodu založenou na pravděpodobnosti, takže není zaručen správný výsledek a opakovaná spuštění mohou dát rozdílný výstup. Nicméně lze výpočetně určit a zvolit takový počet iterací, aby pravděpodobnost nenalezení n správných bodů nepřekročila akceptovatelnou úroveň (Fischer, Bolles, 1981).

Mimoto, ačkoliv rovina proložená pomocí RANSAC mračnem bodů hledané **rovině** (s vysokou pravděpodobností) odpovídá, nejedná se o nejlepší možnou zjištěnou polohu roviny. Její parametry totiž byly vypočítány pouze z náhodně vybrané podmnožiny bodů a ostatní správné body byly z výpočtu vyjmuty. Tento nedostatek je v prezentované metodě kompenzován v dalším kroku zpřesněním polohy roviny pomocí metody nejmenších čtverců. Důležité však je, že před jejím použitím byly metodou RANSAC odfiltrovány všechny odlehlé body a rovina je prokládána pouze body ležícími na střeše hledané budovy.

Metodu RANSAC využívají pro detekci budov i další autoři, ale nikoliv ve stejném kontextu. Například Nardinocchi et al. (2001) používají RANSAC pro detekci rovin v laserových datech, ale aplikují ji na celé bodové mračno, nikoliv jen na lokální sousedství. V důsledku toho dokáže metoda detekovat pouze rovinné střešní plochy.

Shlukování bodů střešní plochy růstovým algoritmem

Druhým přínosem představené metody je využití růstového algoritmu pro sloučení bodů náležících jedné střešní ploše na základě parametrů sklonu a orientace získaných z roviny proložené metodou RANSAC. Z mračna bodů s přiřazenými rovinnými parametry se náhodně vybere jeden bod a postupně se prochází body v jeho blízkém sousedství. Pokud se hodnoty sklonu a orientace příliš neliší, sloučí se body do jedné skupiny (reprezentující střešní plochu) a na nově přidaný bod se iterativně aplikuje stejný postup. V případě, že už nelze přidat žádný další bod (a skupina je dostatečně velká), jsou detekovány všechny body náležící jedné střešní ploše. Osamocené body nebo příliš malé shluky reprezentují vegetaci, nebo jiné objekty tvořící souvislé plochy.

Klíčovou výhodou této metody proti jiným shlukovacím algoritmům je pozvolná změna parametrů, na základě kterých se přidávají do množiny nové body. V případě zaoblených střech je tak možné do jednoho shluku zahrnout body se zcela jinými hodnotami sklonu a orientace, pod podmínkou, že přechod mezi nimi je pozvolný.

Huang (2013) uvádí, že nejsou dostupné rovnice popisující obecnou zakřivenou plochu. I metody, které jsou schopny rozpoznat zakřivené střechy si proto dokáží poradit jen s omezenou množinou tvarů (například Teo, 2008). Adaptace parametrů

postupně přidávaných bodů však žádnou rovnicí popisující plochu jako celek nevyžaduje.

Růstový algoritmus je velmi dobře známý a hojně využíván v řadě aplikací, včetně detekce a modelování budov, ale opět nikoliv v tomto kontextu. Forlani et al. (2006) například aplikuje růstový algoritmus na rastrový digitální model povrchu vypočtený z dat LLS, aby určil pixely náležící jedné budově.

Jochem et al. (2009) v první fázi využívá růstový algoritmus přímo pro slučování laserových bodů náležících jedné střešní ploše. Jakmile však množina dosáhne určité velikosti, je jí proložena rovina a další body jsou do množiny přidávány už na základě podobnosti s parametry této roviny. Tímto postupem se sice minimalizuje riziko nežádoucího rozšíření střešní plochy například na přilehlou vegetaci, nebo sousední budovu. Zároveň se tím ale omezují detekovatelné plochy pouze na rovinné segmenty.

4. HODNOCENÍ KVALITY DETEKCE BUDOV

Přestože dálkový průzkum Země pomocí technologie laserového skenování už nelze považovat (alespoň z pohledu rychle se rozvíjejícího oboru geoinformatiky) k novým metodám, metody hodnocení kvality zpracování těchto dat ještě stále nejsou všeobecně ustáleny a používány, což prakticky znemožňuje jakékoliv objektivní srovnání.

Tohoto nedostatku si je vědom například Rutzinger et al. (2009), který soudí, že “Zatímco důležitost nezávislého hodnocení je nesporná a navzdory skutečnosti, že jsou k určení úspěšnosti detekce běžně využívány velmi podobné metriky, jejich standardizace stále chybí.” Nutnost standardizace hodnotících metrik dokládá pro představu na příkladu, kde dosahovala úplnost detekovaných budov 44 % pomocí jedné a 92 % pomocí druhé hodnotící metriky (Rutzinger et al., 2009). Za této situace, kdy každý autor používá jiný způsob hodnocení, je jakékoliv srovnání detekčních metod nemožné. Srovnání hodnotících přístupů s cílem napravit tuto situaci prezentuje například Song a Haithcoat (2005), Rutzinger et al. (2009). Na jejich práci navazují Potůčková a Hofman (2016), když porovnávají stávající metody v teoretické rovině i zpracováním datové sady čítající na 1400 budov. Ve své studii zdůrazňují univerzálnost plošně zaměřené metriky (viz část 4.2).

4.1. SROVNÁNÍ HODNOTÍCÍCH METRIK DETEKCE BUDOV

Rutzinger et al. (2009) navrhuje kombinaci objektově založené (*object-based*) a pixelově založené (*pixel-based*) metriky, ačkoliv úvodu uvádí jejich nedostatky. Konkrétně v případě *pixel-based* metriky se jedná o zkreslení plochy na okrajích budov, které hraje významnou roli zejména u malých objektů. V případě *object-based* přístupu je nezbytné jasně definovat a standardizovat, co je považováno za úspěšně detekovanou budovu. Navíc zcela zanedbává geometrickou nepřesnost detekovaných budov, a naopak nedostatečně detekované budovy ignoruje zcela. Vzhledem k tomu, že každá z metrik zanedbává/zkresluje jiný aspekt detekovaných budov, podávají společně relativně dobrý obraz úspěšnosti detekce.

Kromě porovnávání detekovaných objektů a ploch se pro hodnocení úspěšnosti často využívají ještě metriky popisující geometrickou přesnost detekovaných budov, nejčastěji rozptyl (střední kvadratická odchylka) aplikovaný na souřadnice rohů budov. Bohužel tyto přístupy porovnávající tvar detekovaných a vzorových budov hodnotí pouze geometrickou přesnost detekovaných budov (Rutzinger et al., 2009) a neberou v potaz zcela nedetekované budovy, nebo naopak jiné objekty nesprávně označené za budovu. Vypočtená hodnota rozptylu není navíc příliš vypovídající, neboť členitější budovy (či jejich části) s vyšším počtem rohů se podílí na výsledné hodnotě vyšší měrou. Kromě toho není možné je jednoduše aplikovat na surová data.

Zejména složitější tvary budov vyžadují často netriviální předzpracování dat, vnášející do výsledků další chyby a rozdílné přístupy, dále znemožňující objektivní srovnání (Potůčková, Hofman, 2016).

Ve snaze odstranit subjektivní přístup při hodnocení geometrické přesnosti detekovaných budov, navrhuje Avbelj et al. (2015) novou metriku nazvanou PoLis (Polygon and Line Segments), která jasně definuje výpočet rozptylu i v případě nepředzpracovaných obrysů budov. Vypočtená hodnota však v případě odlišné komplexnosti budov stále není příliš vypovídající. Stejně tak hodnotí geometrickou přesnost pouze u správně detekovaných budov a proto není možné ji použít jako samostatnou hodnotící metriku.

Song a Haithcoat (2005) navrhují použití kombinace až deseti různých metrik pro komplexní hodnocení výsledků. S rostoucím množstvím hodnot se ale může celkový obraz snadno ztratit a objektivní srovnání je problematické (Potůčková, Hofman, 2016).

4.2. PLOŠNĚ ZALOŽENÁ HODNOTÍCÍ METRIKA

Rutzinger et al. (2009) soudí, že volba optimální hodnotící metody závisí na účelu, pro který jsou budovy detekovány. Přestože řada detekčních metod má specifické zaměření a některému z aspektů extrahovaných budov přikládá větší důležitost, hodnoty úplnosti a geometrické přesnosti detekovaných budov jsou žádoucí za všech okolností. Volba specifických hodnotících metod podle účelu detekce navíc prakticky znemožňuje jakékoliv srovnání.

Potůčková a Hofman (2016) soudí, že by měla být na všechny detekční metody aplikována jedna jasně definovaná, robustní a vypovídající hodnotící metoda, která by umožňovala rychlé a objektivní srovnání napříč spektrem detekčních přístupů. Všechny podmínky jasné definice, robustnosti a vysoké vypovídací hodnoty splňuje hodnota kvality určená z vzájemně se překrývajících ploch detekovaných a vzorových budov (*Area-based accuracy assessment*).

Tento hodnotící přístup je velmi dobře známý, ale přestože netrpí nedostatky ostatních postupů, autoři srovnání jej doporučují jen jako podpůrnou metodu (Song a Haithcoat, 2005), nebo jej nezmiňují vůbec (Rutzinger et al., 2009). Důvodem je pravděpodobně to, že není tolik intuitivní, jako jiné přístupy připomínající ruční hodnocení prováděné člověkem. Kromě toho není z jedné hodnoty popisující celkovou kvalitu zřejmé, jakého druhu jsou chyby detekovaných budov. To však není pro celkové objektivní srovnání detekčních metod na škodu. Kromě toho, pokud chtějí autoři vyzdvihnout určitý aspekt úspěšnosti detekce, nebo podrobněji analyzovat její nedostatky, může být tato hodnotící metrika dle potřeby doplněna libovolným jiným kritériem podle požadovaného účelu (Potůčková, Hofman, 2016).

5. ZÁVĚR

Data leteckého laserového skenování a jejich aplikace v oblasti detekce a modelování budov prodělala během své krátké dosavadní existence bouřlivý vývoj. Detekční metody přešly postupem času od přístupu řízeného modelem, který nedokázal postihnout všechny typy zástavby, k univerzálnějšímu přístupu řízeného daty.

Tento přerod šel ruku v ruce se zvyšující se kvalitou pořizovaných dat, zejména hustotou bodového mračka, umožňující vytváření 3D modelů budov s vysokou přesností, spolehlivostí i mírou detailu. Navzdory tomuto trendu ale příklad Projektu tvorby nového výškopisu území České republiky od Českého úřadu zeměměřického a katastrálního ukazuje, že i v současnosti má řídké bodové mračko své využití. Bohužel tento aspekt je v publikovaných metodách na detekci budov většinou opomíjen.

V této práci byly představeny dvě metody s cílem tento nedostatek napravit. První metoda využívá přístupu řízeného modelem pro určení typu střešního pláště budov se známými obrysy. Nedostatek velmi specifického využití je vyvážen plně automatickým zpracováním a vysoké spolehlivosti i při extrémně nízké hustotě bodového mračka. Podíl správně určených typů střešního pláště dosahuje 91 % při hustotě 1,5 bodů/m² a 80 % při hustotě 0,25 bodů/m².

Druhá metoda využívá přístupu řízeného daty pro rekonstrukci střešního pláště a následně detekci obrysů budov. Díky využití algoritmu RANSAC na prokládání roviny blízkým sousedstvím laserových bodů dokáže metoda spolehlivě určit správný sklon a orientaci střešního pláště i na tradičně problematických místech, jako jsou vnitřní hrany a okraje střech, a to i při zpracování laserových dat s velmi nízkou hustotou bodů. Určení střešních ploch pomocí růstového algoritmu umožňuje metodě detekovat i budovy se zaoblenými střechami. Navzdory tomu, že metoda využívá pouze prostorové souřadnice bodů, pracuje plně automaticky a nepotřebuje žádný doplňující dataset, dává i při velmi nízké hustotě bodů (v průměru 1,5 bodů/m²) velmi dobré výsledky spolehlivosti (97 %) i úplnosti (87 %) detekovaných budov.

Kromě samotných metod modelování budov byla v této práci představena i studie analyzující standardizaci hodnotících metrik, která je v oblasti detekce budov z dat LLS stále nedostatečná. Aby bylo možné objektivně posoudit kvalitu detekčních metod musí být hodnotící metriky jasně definované, robustní a mít vysokou vypovídací hodnotu. Všechny tyto podmínky splňuje hodnota kvality určená z vzájemně se překrývajících ploch detekovaných a vzorových budov (Area-based accuracy assessment).

ZDROJE

ALHARTHY, A., BETHEL, J., 2002. Heuristic filtering and 3D feature extraction from lidar data. *IAPRS International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol.34, Part 3A: 23–28.

AZADBAKHT, M., FRASER, C. S., KHOSHELHAM, K., 2016. Improved Urban Scene Classification Using Full-Waveform Lidar. *Photogrammetric Engineering and Remote Sensing*, Volume 82, Issue 12: 973–980.

AVBELJ, J., MÜLLER, R., BAMLER, R., 2015. A metric for polygon comparison and building extraction evaluation. *IEEE Geoscience and Remote Sensing Letters*, 12(1): 170–174.

BAKUŁA, K., KUPIDURA, P., JELOWICKI Ł., 2016. Testing of land cover classification from multispectral airborne laser scanning data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B7: 161–169.

BRENNER, C., 2000. Towards fully automatic generation of city models. *IAPRS International Archives of Photogrammetry and Remote Sensing and Spatial Information Sciences*, Vol.34, Part 3A: 169–174.

CAVEGN, S., HAALA, N., NEBIKER, S., ROTHERMEL, M., TUTZAUER, P., 2014. Benchmarking high density image matching for oblique airborne imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XL-3.

DEMIR, N., POLI, D., BALTSAVIAS, E., 2008. Extraction of buildings and trees using images and LiDAR data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XXXVII. Part B4.

DORNINGER, P., PFEIFER, N., 2008. A comprehensive automated 3D approach for building extraction, reconstruction, and regularization from airborne laser scanning point clouds. *Sensors*, 8 (11): 7323–7343.

DUŠÁNEK, P., 2014. Projekt tvorby nového výškopisu území České republiky. *GIS Ostrava 2014*, Ostrava ČR.

FILIN, S., PFEIFER, N., 2005. Neighborhood systems for airborne laser data. *Photogrammetric Engineering and Remote Sensing*, 71(6): 743–755.

FISCHLER, M. A., BOLLES, R. C., 1981. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, 24.6: 381–395.

FORLANI, G., NARDINOCCHI, C., SCAIONI, M., ZINGARETTI, P., 2003. Building reconstruction and visualization from LiDAR data. *IAPRS International Archives of Photogrammetry and Remote Sensing and Spatial Information Sciences*, Vol. 34, Part 5/W12: 151–156.

FORLANI, G., NARDINOCCHI, C., SCAIONI, M., ZINGARETTI, P., 2006. Complete classification of raw LIDAR data and 3D reconstruction of buildings. *Pattern Analysis and Applications*, 8 (4): 357–374.

GUO, L., CHEHATA, N., MALLET, C., BOUKIR, S., 2011. Relevance of airborne lidar and multispectral image data for urban scene classification using Random Forests. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66: 56–66.

HAALA, N., BRENNER, C., 1997. Generation of 3D city models from airborne laser scanning data. Proc. *3rd EARSEL Workshop on LIDAR Remote Sensing on Land and Sea*, Tallinn, Estonia: 105–112.

HAALA, N., BRENNER, C., ANDERS, K.-H., 1998. 3D urban GIS from laser altimeter and 2D map data. *International Archives of Photogrammetry and Remote Sensing*, 32, Part 3: 339–346.

HOFMAN, P., POTŮČKOVÁ, M., 2012. Roof type determination from a sparse laser scanning point cloud. *AUC Geographica*, 47 (1): 35–39.

HOFMAN, P., POTŮČKOVÁ, M., 2017. Comprehensive approach for building outline extraction from LiDAR data with accent to a sparse laser scanning point cloud. *Geoinformatics FCE CTU*, 16 (1): 91–102.

HOFMANN, A. D., 2005. An approach to 3D building model reconstruction from airborne laser scanner data using parameter space analysis and fusion of primitives. *Technische Universität Dresden, Fakultät Forst-, Geo- und Hydrowissenschaften*, 109 s.

HOFMANN, A. D., MAAS, H-G., STREILEIN, A., 2002. Knowledge-based Building Detection Based on Laser Scanner Data and Topographic Map Information. *ISPRS Archives*, Volume XXXIV Part 3 A+B.

HUANG, X., 2013. Building reconstruction from airborne laser scanning data. *Geo-spatial Information Science*, 16:1: 35–44.

HUG, C., 1997. Extracting artificial surface objects from airborne laser scanner data. In: Gruen, A., Baltsavias, E.P., Henricsson, O. (Eds.), *Automatic Extraction of Man-Made Objects From Aerial and Space Images (II)*. *Birkhäuser Verlag*, Basel, Switzerland: 203–212.

ITHACA COLLEGE, 2018. Mapping the Maya: Laser technology reveals secrets of ancient civilization. *ScienceDaily*, www.sciencedaily.com/releases/2018/02/180205140111.htm [26. 4. 2018].

JAKUBOWSKI, M. K., LI, W., GUO, Q., AND KELLY, M., 2013. Delineating Individual Trees from Lidar Data: A Comparison of Vector- and Raster-based Segmentation Approaches. *Remote Sensing*, 5: 4163–4186.

JOCHEM, A., HÖFLE, B., RUTZINGER, M., PFEIFER, N., 2009. Automatic Roof Plane Detection and Analysis in Airborne Lidar Point Clouds for Solar Potential Assessment. *Sensors*, Volume 9, Issue 7.

KHOSHELHAM, K., NARDINOCCHI, C., FRONTONI, E., MANCINI, A., ZINGARETTI, P., 2010. Performance evaluation of automated approaches to building detection in multi-source aerial data, *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 65, Issue 1: 123–133.

LACH, S. R., KEREEKES, J. P., 2008. Robust extraction of exterior building boundaries from topographic lidar data. *IEEE Proceedings*, IGARSS: 85-88.

LEICA GEOSYSTEMS AG, 2018. Leica CityMapper Airborne Hybrid Sensor. <https://leica-geosystems.com/en-in/products/airborne-systems/leica-citymapper> [26. 4. 2018].

MA, R., 2005. DEM Generation and Building Detection from Lidar Data. *Photogrammetric Engineering and Remote Sensing*, Vol. 71, No. 7: 847–854.

MAAS, H-G., 1999. Fast determination of parametric house models from dense airborne laserscanner data. *ISPRS Workshop on Mobile Mapping Technology*, Bangkok, Thailand.

MAAS, H-G., VOSSELMAN, G., 1999. Two algorithms for extracting building models from raw laser altimetry data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54: 153–163.

MATIKAINEN, L., HYYPPÄ, J., HYYPPÄ, H., 2003. Automatic detection of buildings from laser scanner data for map updating. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 34, 3/W13: 218–224.

MATIKAINEN, L., HYYPPÄ, J., LITKEY, P., 2016. Multispectral airborne laser scanning for automated map updating. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 41.

MATIKAINEN, L., KAARTINEN, H., HYYPPÄ, J., 2007. Classification tree based building detection from laser scanner and aerial image data. *International Archives of*

the Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol 36, Part 3, W52.

MATIKAINEN, L., KARLA, K., HYYPPÄ, J., LITKEY, P., PUTTONEN, E., AHOKAS, E., 2017. Object-based analysis of multispectral airborne laser scanner data for land cover classification and map updating. *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 128: 298–313.

MAYER, H., 1999. Automatic Object Extraction from Aerial Imagery - A Survey Focusing on Buildings. *Computer Vision and Image Understanding*, Vol. 74, No. 2: 138–149.

NARDINOCCHI, C., SCAIONI, M., FORLANI, G., 2001. Building extraction from LIDAR data. *Remote Sensing and Data Fusion over Urban Areas*, IEEE/ISPRS Joint Workshop.

POTŮČKOVÁ, M., HOFMAN, P., 2016. Comparison of Quality Measures for Building Outline Extraction. *The Photogrammetric Record*, 31 (154): 193–209.

REMONDINO, F., SPERA, M. G., NOCERINO, E., MENNA, F., NEX, F., 2014. State of the art in high density image matching. *The Photogrammetric Record*, 29(146): 144–166.

ROTTENSTEINER, F., BRIESE, CH., 2002. A new method for building extraction in urban areas from high-resolution lidar data. *IAPRS International Archives of Photogrammetry and Remote Sensing and Spatial Information Sciences*, Vol.34, Part 3A: 295–301.

ROTTENSTEINER, F., SOHN, G., GERKE, M., WEGNER, J. D., BREITKOPF, U., JUNG, J., 2014. Results of the ISPRS benchmark on urban object detection and 3D building reconstruction. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93: 256–271.

ROTTENSTEINER, F., SUMMER, G., TRINDER, J., CLODE, S., KUBIK, K. K. T., 2005. Evaluation of a method for fusing LIDAR data and multispectral images for building detection. *Joint workshop of ISPRS and DAGM-CMRT05*, vol. 36, no. Part 3/W24: 15–20.

RUTZINGER, M., ROTTENSTEINER, F. AND PFEIFER, N., 2009. A comparison of evaluation techniques for building extraction from airborne laser scanning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2(1): 11–20.

SCHMIDT, A., NIEMEYER, J., ROTTENSTEINER, F., SOERGEL, U., 2014. Contextual Classification of Full Waveform Lidar Data in the Wadden Sea. *IEEE Geoscience and Remote Sensing Letters*, Volume: 11, Issue: 9.

SHEN, W., 2008. Building boundary extraction based on LIDAR point clouds data. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37(B3b): 157–162.

SOHN, G., HUANG, X., TAO, V., 2008. Using a Binary Space Partitioning Tree for Reconstructing Polyhedral Building Models from Airborne Lidar Data. *Photogrammetric Engineering and Remote Sensing*, 74 (11): 1425–1440.

SONG, W. AND HAITHCOAT, T. L., 2005. Development of comprehensive accuracy assessment indexes for building footprint extraction. *IEEE Transactions on Geoscience and Remote Sensing*, 43(2): 402–404.

TEO, T., 2008. Parametric Reconstruction for Complex Building from Lidar and Vector Maps Using a Divide-and-Conquer Strategy. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37: 133–138.

TITTMANN, P., SHAFIL, S., HARTSOUGH, B. AND HAMANN, B., 2011. Tree detection and delineation from lidar point clouds using ransac. *Proceedings of SilviLaser 2011*.

TOMLIJENOVIC, I., TIEDE, D., BLASCHKE, T., 2016. A building extraction approach for Airborne Laser Scanner data utilizing the Object Based Image Analysis paradigm. *International Journal of Applied Earth Observation and Geoinformation*, 52: 137–148.

VOSELNAN, G., DIJKMAN, S., 2001. 3D building model reconstruction from point clouds and ground plans. *IAPRS International Archives of photogrammetry and Remote Sensing*, Vol. 34, Part 3-W4: 37–43.

WANG, O., LODHA, S. K., HELMBOLD, D. P., 2006. A Bayesian Approach to Building Footprint Extraction from Aerial LIDAR Data. *3rd International Symposium on 3D Data Processing, Visualization and Transmission (3DPVT 2006)*, Chapel Hill, North Carolina, USA.

WEIDNER, U., FÖRSTER, W., 1995. Towards automatic building extraction from high resolution digital elevation models. *ISPRS Journal of Photogrammetry and Remote Sensing*, 50: 38–49.

WICHMANN, V., BREMER, M., LINDENBERGER, J., RUTZINGER, M., GEORGES, C., PETRINI-MONTEFERRI, F., 2015. Evaluating the potential of multispectral airborne lidar for topographic mapping and land cover classification. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3/W5: 113–119.

SEZNAM PUBLIKACÍ ZAŘAZENÝCH DO RIGORÓZNÍ PRÁCE

Recenzované publikace na Web of Science

POTŮČKOVÁ, M., HOFMAN, P., 2016. Comparison of Quality Measures for Building Outline Extraction. *The Photogrammetric Record*, 31 (154): 193–209.

Recenzované publikace v databázi Scopus

HOFMAN, P., POTŮČKOVÁ, M., 2012. Roof type determination from a sparse laser scanning point cloud. *AUC Geographica*, 47 (1): 35–39.

Ostatní recenzované publikace

HOFMAN, P., POTŮČKOVÁ, M., 2017. Comprehensive approach for building outline extraction from LiDAR data with accent to a sparse laser scanning point cloud. *Geoinformatics FCE CTU*, 16 (1): 91–102.

ŠTYCH, P., HOFMAN, P., 2012. Dlouhodobé změny využití krajiny v říční nivě středního Polabí. *Geografické rozhledy*, 21 (5): 11–12.