

UNIVERZITA PAVLA JOZEFA ŠAFÁRIKA
PRÍRODOVEDECKÁ FAKULTA

**MAPOVANIE STROMOVEJ ZELENÉ V KOŠICIACH POMOCOU
LETECKÉHO LASEROVÉHO SKENOVANIA A
FOTOGRAMETRIE**

UNIVERZITA PAVLA JOZEFA ŠAFÁRIKA
PRÍRODOVEDECKÁ FAKULTA

**MAPOVANIE STROMOVEJ ZELENÉ V KOŠICIACH
POMOCOU LETECKÉHO LASEROVÉHO SKENOVANIA A
FOTOGRAMETRIE**

DIPLOMOVÁ PRÁCA

Študijný program:	Geografia a geoinformatika
Pracovisko:	Ústav geografie
Vedúci diplomovej práce:	doc. Mgr. Michal GALLAY, PhD.
Konzultant diplomovej práce:	Mgr. Ján Šašak

Košice 2018

Bc. Pavol TITKO



Univerzita P. J. Šafárika v Košiciach
Prírodovedecká fakulta

ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta: Bc. Pavol Titko
Študijný program: Geografia a geoinformatika (Jednoodborové štúdium, magisterský II. st., denná forma)
Študijný odbor: 4.1.35. geografia
Typ záverečnej práce: Diplomová práca
Jazyk záverečnej práce: slovenský
Sekundárny jazyk: anglický

Názov: MAPOVANIE STROMOVEJ ZELENÉ V KOŠICIACH POMOCOU LETECKÉHO LASEROVÉHO SKENOVANIA A FOTOGRAMETRIE
Názov EN: Mapping tree vegetation in Košice with airborne laser scanning and photogrammetry
Cieľ: Cieľom práce je navrhnúť vhodný postup identifikácie prvkov stromovej mestskej zelene z dát získaných jednorazovým leteckým laserovým skenovaním centrálnej časti mesta Košice. Riešenie úlohy predpokladá testovanie viacerých existujúcich postupov klasifikácie lidarového mračna bodov ako aj ich prispôbenie či navrhnutie vlastných postupov. Súčasťou úlohy je parametrizácia mestskej zelene ako napr. výška porastu, percento pokrytia, druhové zloženie a iné.
Literatúra: Xu, S., Vosselman, G., Oude Elberink, S.
Multiple-entity based classification of airborne laser scanning data in urban areas
(2014) ISPRS Journal of Photogrammetry and Remote Sensing, 88, pp. 1-15.

Vedúci: doc. Mgr. Michal Gallay, PhD.
Ústav : ÚGE - Ústav geografie
Riaditeľ ústavu: prof. Mgr. Jaroslav Hofierka, PhD.
Dátum schválenia: 27.04.2018

Pod'akovanie

Vyslovujem pod'akovanie všetkým, ktorí mi pomohli pri tvorbe tejto práce. Moja vďaka patrí hlavne vedúcemu diplomovej práce docentovi Michalovi Gallayovi a konzultantovi diplomovej práce magistrovi Jánovi Šašakovi.

Abstrakt

Objektom diplomovej práce bolo klasifikovať stromovú zeleň nachádzajúcu sa v meste Košice pomocou vybraných softvérov a určiť ich presnosť vzhľadom na referenčné dáta. Na klasifikáciu boli vybrané tri softvéry: LasTools, Cloud Compare - Canupo a eCognition. V nich boli využívané dva typy priestorových dát získané leteckým laserovým skenovaním a leteckou fotogrametriou. Porovnávanie presnosti klasifikácie sa uskutočňovalo s vopred vytvorenými referenčnými dátami a následne sme referenčnými bodmi určili presnosť klasifikácií a referenčných dát, ktoré boli využité pri porovnávaní. Poslednou časťou práce bola vizualizácia vybraných metrík na stanovených územiach. Klasifikácia pomocou Cloud Compare – Canupo a následné porovnávanie neprebehlo na celom území, kvôli zdĺhavému procesu klasifikácie a výpočtovej kapacite. Spomedzi testovaných softvérov najlepšie zvládol klasifikáciu softvér eCognition, ktorého výsledky sa najviac zhodovali s referenčnými dátami a môžu byť využité na automatizovanú klasifikáciu stromovej zelene. Porovnávaním klasifikácií s referenčnými bodmi bola dokázaná najlepšia klasifikácia referenčnými dátami a vysoká úspešnosť klasifikácie pomocou softvéru eCognition. Vizualizáciou úrovni výšok stromov bolo poukázané na prínos metrík pri mapovaní mestskej zelene.

Kľúčové slová: klasifikácia mestskej zelene, letecké laserové skenovanie, letecká fotogrametria, eCognition, Cloud Compare – Canupo, LasTools

Abstract

The object of the thesis was to classify the tree greenery located in Košice using selected software and to determine their accuracy with reference data. Three softwares were selected for classification: LasTools, Cloud Compare - Canupo and eCognition. They used two types of spatial data obtained by aerial laser scanning and aerial photogrammetry. Comparison of classification accuracy was performed with pre-established reference data, and then we determined the accuracy of the classifications and reference data used in the comparison. The last part of the thesis was the visualization of selected metrics in the defined areas. Classification by Cloud Compare - Canupo and subsequent comparison has not taken place across the whole territory due to the lengthy classification process and computational capacity. Among the tested software, the eCognition software was best suited to the classification, the results of which most matched the reference data and can be used for automated tree greenery classification. By comparing classifications with reference points, the best classification with reference data and the high success rate of classification have been proven with the eCognition software. By the tree height elevation visualization, benefits of metrics for mapping urban greenery were pointed out.

Keywords: classification of urban greenery, aerial laser scanning, aerial photogrammetry, eCognition, Cloud Compare - Canupo, LasTools

Obsah

Úvod	7
1 Prehľad problematiky	9
1.1 Význam vegetácie v meste	9
1.2 Mapovanie mestskej zelene	11
1.2.1 Letecká fotogrametria	13
1.2.2 Letecké laserové skenovanie.....	18
1.2.3 Družicová fotogrametria	22
1.3 Metódy identifikácie zelene	23
1.3.1 Popis nástroja lasclassify v softvéri LasTools	23
1.3.2 OBIA a funkcionality vybraných prvkov v eCognition	24
1.3.3 Princípy klasifikácie v Cloud Compare – CANUPO.....	33
2 Záujmové územie	35
3 Údaje a metodika.....	36
3.1 Údaje.....	36
3.2 Spracovanie údajov	37
3.2.1 Príprava a klasifikácia lidarových dát v Lastools	37
3.2.2 Klasifikácia pomocou eCognition.....	46
3.2.3 Klasifikácia pomocou modulu CANUPO.....	52
3.2.4 Výpočet a vizualizácia metrík.....	53
4 Výsledky mapovania mestskej zelene.....	55
4.1 Porovnanie výsledkom klasifikácie z LasTools a referenčných dát.....	55
4.2 Porovnanie výsledkom klasifikácie z eCognition a referenčných dát.....	58
4.3 Výsledky klasifikácie modulu CANUPO.....	62
4.4 Porovnávanie s referenčnými bodmi	62
4.5 Aplikovanie metrík.....	64
5 Diskusia	67
Záver	69
Zoznam literatúry	71

Úvod

Každým rokom sa miera urbanizácie zvyšuje, čo je podmienené lepšími podmienkami pre život, prácou, väčšou možnosťou seberealizácie. Mestá sa rozrastajú do šírky, ale aj do výšky a sú čoraz viac prepracovanejšie. Vyspelé mestá sa predbiehajú v aplikovaní moderných technológií riadenia miest, čím sa zvyšuje efektívnosť ich spravovania a vznikajú tzv. „chytré mestá“ (Smart Cities). Vyvíjajú sa aj rôzne technológie na mapovanie súčasného stavu miest, pre ich lepšie spravovanie, lokalizovania a odstránenia možných rizík, vybudovania lepšej infraštruktúry, ekologickejšieho prostredia a pod.

Jednou z možností mapovania miest je za pomoci využitia letecký laserových skenerov a fotogrametrie. Tieto metódy dokážu veľmi rýchlo, efektívne zachytiť zmeny v krajine a následným spracovaním týchto dát, je možné lokalizovať problémové oblasti a navrhnúť zmeny, ktoré by prispeli k lepšej kvalite života. Na kvalitu života vo veľkej miere vplýva vegetácia, ktorá má v mestách nezastupiteľné miesto. Jej primerané množstvo dokáže zlepšiť ovzdušie, zdravotný stav ľudí, či celkovú pohodu. V konečnom dôsledku dotvára akúsi mikroklimu v istých častiach miest.

Aj tieto fakty prispeli k vytváraniu rôznych medzinárodných projektov, vzniku organizácií, či agentúr, ktoré sa zaoberajú touto problematikou. Príkladom môže byť Európska vesmírna agentúra (ESA), ktorá všeobecne podporuje rôzne projekty, týkajúce sa prieskumu Zeme pomocou špičkových technológií, pričom sa snaží upovedomiť ľudí na nepriaznivé vplyvy vznikajúce v dnešnej dobe. Jedným z projektov, ktoré ESA podporuje je projekt s názvom Simulating the cooling effect of urban greenery (SURGE), ktorého hlavným cieľom bolo zistiť účinky zelene na mikroklimu v meste, konkrétne v centrálnej časti Košíc. Hlavným riešiteľom tohto projektu je Ústav geografie, ktorý využíva niekoľko typov dát, ako sú multispektrálne družicové snímky zo senzora Sentinel 2, dáta z pozemného laserového skenovania, GNSS, dáta z leteckého laserového skenovania (LLS), leteckej fotogrametrie.

Jednou z úloh SURGE bolo zistiť spôsob ako efektívne zmapovať mestskú zeleň. To bolo podnetom pre vznik tejto diplomovej práce, ktorej hlavným cieľom bolo navrhnúť postup automatizovaného mapovania stromovej vegetácie (ďalej využívané aj výrazy ako vegetácia/ stromová zeleň/ zeleň, ktoré sú v rámci práce myslené ako synonymá) v mestskej krajine na základe dát z leteckého laserového skenovania

a fotogrametrie a analyzovať presnosť mapovania. Riešenie úlohy si vyžadovalo zhodnotiť využitie softvérov LasTools, Cloud Compare (Canupo), eCognition a porovnať výsledky klasifikácie jednotlivých softvérov s referenčnými dátami. Čiastkovým cieľom bolo vypočítanie metrík na zvolených lokalitách z klasifikovaných LAS dát.

1 Prehľad problematiky

V tejto kapitole zdôvodníme, prečo je mapovanie vegetácie v mestách dôležité a aké metódy sa využívajú pre mapovanie vegetácie. Charakterizujeme technológie a softvéry, ktoré boli použité pri mapovaní nášho územia a poukážeme na aktuálnosť tejto problematiky prehľadom výskumov.

1.1 Význam vegetácie v meste

Od roku 2011 žije v mestách viac než 50% všetkých ľudí (UN-Habitat, 2011), ak trend urbanizácie bude pokračovať v takom rozsahu ako je tomu dnes, stúpne miera urbanizácie za 30 rokov až na 70% (Cox et al., 2017). Preto je potrebné venovať zvýšenú pozornosť mestám a ich štruktúre.

Mestá zohrávajú mimoriadnu úlohu pri globálnych klimatických zmenách a zároveň sú na tieto zmeny veľmi náchylné. Mestská klíma trpí vyššími teplotami, horšou kvalitou ovzdušia a zhoršeným odtokom pri povodňových situáciách oproti vidieckemu prostrediu (Escobedo & Nowak, 2009). Urbanizácia je taktiež jedným z hlavných príčin chorôb v 21.st. Vzrastá výskyt chronických, neprenosných, duševných chorôb (Cox et al., 2017).

Optimálne usporiadaná vegetácia v mestskom prostredí môže znížiť teplotu, zlepšiť kvalitu vzduchu a zlepšiť odtok (Myint, 2010; Alonzo, 2015) znižuje výskyt škodlivých mikroorganizmov v ovzduší, tlmí zvuk, znižuje prašnosť, vhodným umiestnením usmerňuje prúdenie vzduchu alebo sa môže využívať ako vetrolam (Smreček, 2013). Mestská zeleň má taktiež potenciál pomôcť k zmierneniu rôznych zdravotných problémov. Je dokázané, že prítomnosť vegetácie v mestách znižuje úmrtnosť, riziko kardiovaskulárnych ochorení, zníženie prejavov alergií, všeobecne zlepšenie kondície, duševného zdravia a kognitívnych schopností (Cox et al., 2017). V mnohých prípadoch zvýšená interakcia s vegetáciou prospešne ovplyvňuje výkony študentov v mestách (Hodson and Sander, 2017).

Jedným z hlavných faktorov je zvýšená teplota v mestách. Teplota v mestskom prostredí je znateľne vyššia než v priľahlých prímestských oblastiach. Dôsledkom zvýšenej teploty je vznik prehriatych mestských častí (angl. urban heat Island - UHI). Tie vznikajú hlavne drastickou redukciou zelene v určitých mestských oblastiach a ich nahradením stavbami rôzneho typu. Takýto povrch má následne tendenciu

zhromažďovať teplo, ktoré je vyžiarené cez deň a počas noci dané teplo vyžarovať do ovzdušia, čo zvyšuje priemernú dennú teplotu aj o niekoľko stupňov. To sa odráža na horších tepelných podmienkach vonku ale aj dnu v budovách (Buyadi et al. 2015). Tento fakt potvrdzujú aj (Voogt & Oke, 2003; Gerçek et al., 2016) vo svojich výskumoch.

UHI predstavuje zvýšenie spotreby energie kolapsov a úmrtí detí či starších občanov (Výberčí et al., 2017). Onačillová and Gallay (2018) potvrdili svojim výskumom, že UHI sú v značnej miere viditeľné aj v mestách s menším počtom obyvateľov a netýka sa to iba veľkých metropol. Výskum bol aplikovaný na mesto Košice (240 000 obyv.), pričom na poukázanie UHI využili údaje zo snímok satelitov Landsat 7 a 8.

Je niekoľko možností ako znižovať tento efekt nechceného otepľovania mestského prostredia. Jednou z možností je využívanie svetlejších farieb na budovách či reflexný povrch. Lepšou stratégiou je však vysádzanie vegetácie v mestských oblastiach (Hall, Handley, & Ennos, 2012). Stromy poskytujú množstvo ekosystémových služieb, ktorých veľkosť vplyvu závisí od druhu stromu, štruktúry či lokalizácie (Escobedo & Nowak, 2009)

Vegetácia ochladzuje mesto odparovaním, zabraňuje slnečným lúčom dopadať na zem, pričom tak nedochádza k jej priamemu zohrievaniu povrchu. Rastliny všeobecne odrážajú viac slnečných lúčov než bežný povrch, zelené oblasti majú odrazivosť 25% oproti 15% pri budovách (AboElata, 2017). Je mnoho štúdií, ktoré potvrdzujú ochladzovací efekt vegetácie. Jedným z príkladov je výskum, ktorý sa uskutočnil v Manchestri a poukazuje na zníženie teploty povrchu o 2,3°C vplyvom vegetácie (Hall, Handley, & Ennos, 2012). Nezanedbateľným efektom je tienenie stromov a teda správne rozostavenie vegetácie, tak aby to malo čo najlepší efekt, napr. aby strom vrhal tieň čo najdlhšiu dobu na využívané komunikácie a tak chránil ľudí pred priamym slnečným žiarením (AboElata, 2017). Výskum z Malajzie z mesta Kuala, popisuje priaznivé ochladzujúce účinky už pri malých plochách zelene, napr. stromov pozdĺž cesty či pri skupine stromov v malých parkoch v obytných oblastiach. Rozdiel teplôt medzi takými to plochami a zastavanou plochou bolo v priemere 1,32 °C (Buyadi et al. 2015). Gkatsopoulos (2017) skúmal vplyv stromu na vnútornú teplotu v byte v oblasti okna. Kde zistil, že teplota bola vplyvom stromu znížená o 1,5 stupňa, z 30 na

28,5. A taktiež sa vplyvom odparovania zvýšila relatívna vlhkosť v blízkosti stromu z 55% až na 80%.

V súčasnosti sa v súvislosti s efektívnym mapovaním zelene mestského prostredia využíva model Mestského lesného efektu (Urban Forest Effects), ktorý sa využíva celosvetovo pri odhade mestskej štruktúry lesov, druhovej rozmanitosti či funkcie ekosystémov (Nowak et al., 2008). Pri tomto mapovaní nastáva problém na súkromných pozemkoch, kde je práca náročná. Aj z tohto dôvodu sa pri mapovaní zelene využíva množstvo metód. Využívajú letecké alebo satelitné snímky, ktoré majú určité obmedzenia, ako je napríklad informácia o druhu stromu, vekovej triede (McGee et al. 2012). Vhodnou metódou je aj letecké laserové skenovanie (Hofierka et al., 2017). Mapovanie v mestách je zložité, hlavne z dôvodu pestrej druhovej škály či priestorovej variácie (Alonzo et al., 2014). Ale s rozvíjajúcimi sa technológiami je takéto mapovanie čoraz dôveryhodnejšie a rýchlejšie.

1.2 Mapovanie mestskej zelene

Témou mapovania mestskej zelene sa zaoberá množstvo vedcov, čo dosvedčuje aj fakt, že pri zadaní kľúčových slov urban vegetation mapping zobrazilo viac než 12 000 článkov. Mnoho z nich vzniklo len za posledných 10 rokov. Pre mapovanie vegetácie je využitých množstvo metodík, s použitím rôznych dát. Najčastejšie využívané dáta pochádzajú z multispektrálnych satelitných snímok, ktoré sú zväčša voľne dostupné.

Aj na Slovensku sa vedci zaoberajú využívaním multispektrálnych snímok, ako príklad môžeme uviesť výskum vedcov z Bratislavy (Kopecká et al., 2017), ktorí sa zaoberali mapovaním územia slovenských miest s využitím snímok zo satelitu Sentinel-2A, snímky boli zložené z 13nástich pásiem, kde rozlíšenie RGB a NIR pásiem bolo 10 m a zvyšné pásma mali rozlíšenie 20 – 60 m. Výsledky klasifikácie mali zhodu s ich referenčnými dátami až 91%.

V Nemecku Tigges et al. (2013) využili pre mapovanie berlínskej zelene dáta zo satelitu RapidEye, ktorého snímky majú 6 pásiem s rozlíšením 6,5 metra. Pre klasifikáciu používali NDVI a nDSM. Potvrdili fakt, že multispektrálne snímky sú využiteľné na približné mapovanie územia, ale ich presnosť by sa určite zväčšila zapojením LIDARových dát.

Alonzo et al. (2014) využili spojenie hyperspektrálnej snímky s rozlíšením 3,7 metra a lidarových dát, ktorých hustota bola 22 bodov/m². Okrem klasifikovania vegetácie, využívali dáta aj na klasifikáciu jednotlivých stromov. Kde s 83% presnosťou zatriedili stromy k druhom a poukázali na potenciál spájania multispektrálnych a lidarových dát.

Okrem satelitných multispektrálnych snímok sa využívajú aj ortofotosnímky použitím leteckej fotogrametrie. Guo et al. (2011) využitím multispektrálnych snímok (25 cm) a lidar (2,5 bodov/ m²), v oblasti mesta Biberach (Nemecko) dosiahli 95% úspešnosť pri celkovej klasifikácii objektov. Horšie výsledky dosiahli v prehustených mestských častiach, kde pri klasifikácii vegetácie a prírodného podlažia bola presnosť okolo 70%. Výskum Huang et al., 2011 poukázal na lepšiu presnosť zložených dát, konkrétne dát z laserového skenovania a ortofotomáp v rozlíšení 40cm.

V niektorých prípadoch sa výskumy sústredia na mapovanie určitého druhu vegetácie. Napríklad Pontius et al. (2017) sa zamerali na lokalizovanie jaseňa (*Fraxinus L.*), tento druh je ohrozený istým škodcom a preto je potrebné lokalizovať jednotlivé stromy a následne zabrániť ich napadnutiu. Pri lokalizovaní stromov boli využité hyperspektrálne a termálne letecké snímky. Pričom úspešnosť identifikovania jaseňa bola až 81%.

V Kanade bol výskum (Liu et al., 2017) zameraný taktiež na identifikáciu druhov stromov. Kde sa podarilo dosiahnuť presnosť identifikovania aj 90%, pri niektorých druhoch, použitím kombinovaných dát lidar a hyperspektrálnych dát.

Okrem dát zo satelitov a lietadiel, sa často využívajú menšie nosiče UAV (bezpilotné zariadenia). Problémom takýchto zariadení je legislatíva. Vo väčšine krajín je zakázané lietať s takýmito zariadeniami nad súkromnými pozemkami a obývanými oblasťami. Tento fakt zužuje využitie týchto nosičov. Často sa využívajú pri mapovaní lesov (Sankey et al., 2017; Coomes et al., 2017; Lehmann et al., 2015). V niektorých krajinách je ale pravdepodobne využívanie UAV v mestách dovolené. Dokazuje to aj výskum (Gaitani et al., 2017), ktorý využil termálny senzor na mapovanie Atén a poukázal na zlepšenie klasifikácie objektov, využitím termálnych snímok.

Novinkou pri mapovaní územia je využívanie multispektrálnych leteckých skenerov. Tieto skenery v podstate nahrádzajú spájanie dát z leteckej fotogrametrie

a bežného leteckého skenovania. Multispektrálny skener, vysiela lúče vo viacerých spektrách a tým zlepšuje objektovo orientovanú klasifikáciu až na 96%. Je to v podstate najpresnejšia metóda pre mapovanie, ktorá vznikla v roku 2014 (Wichmann et al., 2015). Príkladom pre využitie multispektrálneho skeneru je napr. výskum (Leighand and Magruder, 2016; Bakula, 2015; Bakula et al., 2016). Zou et al. (2016) aplikovali objektovo orientovanú klasifikáciu. Kde klasifikovali 9 tried s použitím multispektrálneho skenera s presnosťou 91%.

Výsledky z rôznych typov mapovaní vegetácie sú následne prospešné pre mestá. Dáta môžu byť spracované podľa vlastného uváženia a využité pre zefektívnenie údržby, výsadby či informatizácie občanov pomocou mapových portálov ako je napr. gis.esluzbykosice.sk pre mesto Košice.

V nasledujúcich podkapitolách priblížime princípy zberu dát technológiami, ktoré boli spomenuté vyššie, popíšeme ich hlavné komponenty, výhody a nevýhody aplikovania pre mapovanie mestskej zelene.

1.2.1 Letecká fotogrametria

Všeobecne je fotogrametria vedecko-technickou disciplínou, ktorá pomocou fotografického záznamu uskutočňuje priestorové merania a geometrickú analýzu. Radíme ju k pasívnej metóde DPZ z hľadiska zdroja EMG žiarenia. Bola to jedna z prvých metód diaľkového prieskumu Zeme. Jej vznik bol v 19.st, kedy došlo k vynájdeniu princípu fotografickej komory, záznamu na svetlocitlivý papier a úspechy v letectve (Hofierka et al., 2014).

Základné rozdelenie fotogrametrie

Súčasnú fotogrametriu môžeme z hľadiska hardvérových a softvérových riešení rozdeliť do týchto hlavných oblastí (Fraštia, 2017):

- družicová fotogrametria
- letecká fotogrametria
- RPAS (Diaľkovo pilované letecké systémy)/ UAV fotogrametria
- blízka (pozemná) fotogrametria

Využitie leteckej fotogrametrie

Letecká fotogrametria slúži najčastejšie na mapovanie území v rôznych mierkach, a je využívaná v rôznych odvetviach, napr. pre projektovanie líniových a plošných stavieb, v lesníctve, vojenskom prieskume, pri prieskume územia za zámerom ochrany životného prostredia (Bitterer, 2005).

Pri mapovaní zelene je veľmi dôležité blízke infračervené pásmo, ktoré je podmienkou pre vypočítanie NDVI hodnôt. Tie slúžia k pomerne presnej klasifikácii zelene. Najväčšou nevýhodou je, že z týchto dát nevieme vytvoriť model výšky objektov nad povrchom a preto sa v mnohých prípadoch kombinuje s LAS dátami (Huang et al., 2011, Guo et al., 2011). Pre mapovanie mestskej zelene v Košiciach boli údaje z leteckej fotogrametrie, taktiež skombinované s dátami z laserového skenovanie.

Hlavné princípy v leteckej fotogrametrii

Letecká fotogrametria sa zo všetkých druhov vyznačuje najvyššou efektivitou a produkciou výsledkov, na druhej strane jej mínusom sú vysoké obstarávacie náklady (státisíce až milióny eur). Môžeme sem zahrnúť lietadlo /vrtuľník a jeho prevádzka, digitálna kamera, stabilizačný systém, navigačný systém, spracovateľský systém s príslušným softvérom, personál a iné (Fraštia, 2017).

Letecká fotogrametria analyzuje snímky vyhotovených z leteckých nosičov a vychádza z rekonštrukcie skutočných objektov na báze stereoskopického videnia, kde jej základným produktom sú letecké meračské snímky, získavané pomocou digitálnych fotografických kamier (Fraštia, 2017).

Snímky môžeme definovať ako fotografie, ktoré majú presné rozmery a na okrajoch majú rámové značky na určenie geometrického stredu snímky. Každá snímka obsahuje tiež údaje o lete, dátum, čas, poradie snímky, nadmorskú výšku letu, náklon, ohniskovú vzdialenosť kamery a iné údaje o kamere (Hofierka et al., 2014).

Základné komponenty pre leteckú fotogrametriu

V poslednom období zaznamenávame veľký pokrok v digitálnej fotogrametrii, kde nastalo veľa technologických zmien. Vývoj veľkoformátových digitálnych kamier, strednoformátových kamier, modulárnych systémov a taktiež rozmach diaľkovo pilotovaných leteckých systémov. Významný pokrok zaznamenávame aj v globálnych

navігаčných satelitných systémoch, či inerciálne meracích systémoch (IMS), ktoré sú doplnkovými senzormi pre fotogrametriu (Fraštia, 2017).

Hlavnou súčasťou pri fotogrametrii sú kamery, ktoré rozlišujeme na veľkoformátové digitálne letecké kamery, strednoformátové kamery a modulárne viackamerové systémy (Fraštia, 2017).


Veľkoformátové digitálne letecké kamery sa vyznačujú vysokým geometrickým rozlíšením (250 – 750 megapixelov), multispektrálnym rozlíšením (Panchro + RGB + NIR), priestorovým geometrickým rozlíšením od 0,01 m, rýchlosťou snímkovania 1,5 s/snímka a iné. Patria k nim kamery ako sú napr. UltraCam (Vexcel Imaging) DMC (Z/I Imaging/Hexagon), ADS (Leica Geosystems/Hexagon), A3 Digital Camera (VisionMap) zobrazené na Obr. 1 (Fraštia, 2017).



Obr. 1 Veľkoformátové digitálne letecké kamery. Zľava: UltraCam, DMC III, ADS100, A3; Zdroj: Fraštia, 2017

Rozlíšenie strednoformátových kamier je nižšie než pri veľkoformátových, kvôli tomu dochádza k spájaniu strednoformátových kamier a vznikajú modulárne viackamerové systémy, ktoré nemajú exaktnú centrálnu projekciu, s čím je potrebné pri spracovaní počítať. Zvyšné parametre sú podobné veľkoformátovým, výhodou sú prijateľnejšie ceny. Príkladmi takýchto kamier môžu byť PhaseONE, DigiCAM a IrisOne zobrazené na Obr. 2 (Fraštia, 2017).

Pre snímkovanie sú väčšinou používané jedno alebo dvojmotorové malé lietadlá. Súčasná technika umožňuje minimálnu posádku pilot + operátor alebo iba pilot. Sú vybavené väčšinou jednou kamerou a základnou vlastnosťou lietadla, je výdrž 5-6 hodín. Sú používané napr. jednomotorové hornoplošníky Cessna 206G, dvojmotorové dolnoplošníky Cessna 402B (Obr. 3) a iné (Hanzl, 2006).



Obr. 2 Strednoformátové (PhaseOne, DigiCAM) a modulárne kamery (IrisOne); Zdroj: Fraštia, 2017




Obr. 3 Cessna 402B; Zdroj: Hanzl, 2006

Vyhotovenie leteckých snímok, spracovanie a ortoretifikácia snímok

Skôr než uskutočníme snímkový let zvolíme si snímkovú mierku (čím väčšia tým väčšia presnosť), náletový plán, fotogrametrickú signalizáciu, vlicovací bod, následne je možné previesť snímkový let, uskutočniť kontrolu, spracovanie a ortoretifikáciu snímok (Katalinová, 2015).

Snímkovací let

Letecké meračské snímky sú vytvárané pri horizontálnom lete za sebou a spolu vytvárajú snímkový rad. Pozdĺžny prekryt snímok je okolo 60% a priečny prekryt je 20 – 40% (Obr. 4). Pre hospodárne vykonávanie snímkového letu je potrebný letový plán. Pre zostavenie tohto plánu sú dôležité požiadavky ako mierkové číslo snímok, výstroj (typ komory, lietadlo a iné). Úlohou posádky je dodržiavať dané parametre letu (výšku letu, smer, dráhu, interval medzi expozíciami a pod. (Bitterer, 2005).



Obr. 4 Pozdĺžny a priečny prekryt leteckých snímok; Zdroj: Hofierka et al., 2014

Spracovanie

Po vyhotovení snímok je potrebné snímky spracovať a vytvoriť z nich ortofotomapy. Tento úkon sa vykonáva na digitálnych fotogrametrických staniciach. Prvotným krokom je vnútorná orientácia snímky (individuálna orientácia) a následne sa snímky na základe niekoľkých identických bodov zorientujú vzájomne. Snímky sa potom zorientujú vzhľadom na kartografický systém (vonkajšia orientácia), na tento úkon sú potrebné referenčné (vlicovacie) body, ktoré sú viditeľné na snímke a vopred zamerané GNSS. V súčasnej dobe prijímače GNSS a merače náklonu fotogrametrickej snímky kontinuálne zaznamenávajú polohu kamery pri každej snímke. Tieto údaje a parametre kamery sa ďalej dajú využiť pre automatickú orientáciu snímok (Hofierka et al., 2014).

Ortofotosnímka

Môžeme ju definovať ako ortogonálne prekreslenú snímku, pri ktorej dochádza k odstráneniu perspektívneho skreslenia. To vzniká kvôli nezávislej osi záberu snímky a výškovým rozdielom terénu. Výsledkom procesu ortorektifikácie je digitálne transformovaná snímka s ortogonálnym – pravouhlým priemetom, so stredom

premietania v nekonečne. Digitálna ortofotosnímka je vytváraná pre každý obrazový element (pixel) postupne (Bitterer, 2005).

1.2.2 Letecké laserové skenovanie

V tejto kapitole sa budeme venovať leteckému laserovému skenovaniu (LLS), ktorého dáta sme využívali pri klasifikovaní vegetácie na skúmanom území. LLS spolu s pozemným laserovým skenovaním, patria všeobecne pod laserové skenovanie, teda LIDAR (z ang. Light Detection And Ranging), ktorý patrí pod aktívnu metódu diaľkového prieskumu zeme (DPZ). Hlavný princíp fungovania je vyslanie a odraz laserového lúča od objektu pričom sa meria čas za aký sa odrazený lúč vráti späť do prístroja (Tencer, 2012).

Vývoj leteckých laserových skenerov (LLS)

V posledných 50-tich rokoch nastal veľký pokrok vo vývoji v oblasti elektroniky, fotoniky, počítačovej techniky a grafiky. To všetko umožnilo vytvoriť spoľahlivé, presné, pozemné a letecké laserové skenery s vysokým rozlíšením, ktoré dokážu efektívne spracovať husté mračná bodov pre topografické, environmentálne, priemyselné účely, či oblasť kultúrneho dedičstva (Beraldin et al., 2010).

Na začiatku sedemdesiatych rokov letecké laserové systémy dokázali merať vzdialenosť medzi lietadlom a pozemnými cieľmi s presnosťou menšou než 1 meter, pretože ešte neboli dostatočne presné technológie na určovanie vertikálnej a horizontálnej polohy. Až na konci osemdesiatych rokov s dostupnosťou GNSS sa vyvinula metóda, ktorá umožňovala presnú registráciu polohy a orientácie na väčších územiach. So zavedením diferenciálnej GPS (DGPS) sa pozícia skenera dala určiť s decimetrovou presnosťou, spolu s použitím inerciálnej meracej jednotky (IMU), poskytovali dostatočnú presnosť už od začiatku 90.rokov. Štandardná presnosť údajov o výške bola asi 10cm, pričom odchýlka pri určovaní pozície bola 50cm. Až začiatkom 90tych rokov sa začali využívať aj skenovacie zariadenia, ktoré dokázali vygenerovať 5000 až 10000 laserových pulzov za sekundu. Dnes sa frekvencia pulzov pohybuje okolo 300kHz a letecké laserové skenery majú široké uplatnenie pri 3D prezentácií krajiny (Beraldin et al., 2010).

V polovici 90. rokov sa začínajú komerčne využívať LLS so schopnosťou prenikania laserových lúčov cez pokrývku vegetácie a necitlivosťou na svetelné

podmienky. Ich dáta sa využívali k efektívnemu generovaniu modelu digitálneho terénu, v topografickom mapovaní, konštrukcii 3D modelu miest, či v oblasti vyhodnocovania prírodných rizík (Yan et al., 2015).

V článku od Ackermann (1999) bolo poukázané na budúci rast technológií LLS, ktorý sa po desaťročí potvrdil a to hlavne v oblasti rozšírení aplikácií, konsolidácií, rozšírení metód spracovania údajov LiDAR a získavaní dodatočných informácií o povrchových charakteristikách analyzovaných z vráteného signálu.

V priemyselnom prieskume (Cary and Associates, 2009) bolo poukázané na zvýšenie počtu využívania Lidarových systémov o 75%, pri prevádzkovateľoch o 53% a pri konečných spotrebiteľoch bolo zvýšenie až o 100% za roky 2005 až 2008. V takomto podobnom trende sa zvyšoval dopyt a ponuka aj v nasledujúcich rokoch. Čo malo za následok nárast vedeckých článkov, ktoré mali súvis s LLS napr. v oblasti lesného hospodárstva, ekológie biotopov, zosuve pôdy, 3D modelovaní budov, meraní hĺbky snehu a pod. (Yan et al., 2015).

Princíp fungovania LLS


Laserové skenery pracujú na princípe vysielania a prijímania vln. Najčastejšie sú to vlny s vlnovou dĺžkou od 1064 do 1540 nm, teda vlny nachádzajúce sa v blízkom infračervenom pásme (angl. NIR- Near Infrared). Keďže sa využíva pomerne malá vlnová dĺžka, tieto skenery sú vhodné na presné meranie, čo je plusom oproti radaru (Tencer, 2012).

Laserové skenery môžeme rozdeliť teda na pozemné a letecké. A z pohľadu druhu použitého laseru poznáme „klasické“, jedná sa prevažne o červený laser a „podvodné“- Bathymetrické skenery, ktoré využívajú zelený laser. Ten dokáže prechádzať cez vodu, čo sa využíva na meranie hĺbky dna. Ďalej sa budeme zaoberať len červeným laserom (Tencer, 2012).

Laserový skener má široké uplatnenie v rôznych odvetviach ako je archeológia, astronómia, bezpečnosť, biológia, doprava, ekológia, geodézia, geológia, meteorológia, poľnohospodárstvo a v neposlednom rade diaľkový prieskum zeme (Tencer, 2012).

Všeobecne LiDAR technológia kombinuje veľmi presné meranie laserovým lúčom, ako aj presné určovanie polohy pomocou navigačných technológií (Obr. 5).

Z platformy umiestnenej na lietadle sa vysiela lúč k meranému objektu a zároveň s ním sa spúšťa časomiera, ktorá meria dobu, za akú sa odrazený lúč vráti späť. Keďže vieme aká je rýchlosť lúču (približne 300 mil. m/s) a čas, vzdialenosť vieme vypočítať podľa rovnice: $(\text{Rýchlosť} \cdot \text{čas})/2$ (Tencer, 2012).




Obr. 5 Zobrazenie navigačných technológií využívaných pri LLS; Zdroj: (Beraldin et al., 2010)

Na určenie presnej polohy zameraného bodu sa využíva globálny navigačný systém/GPS a prístroj IMU na určujúci presnú polohu a rýchlosť lietadla. Kombináciou týchto dvoch informácií vieme presne určiť polohu lietadla v momente vysielania a prijatia laserového lúča a z toho vypočítať polohu meraného bodu s presnosťou okolo 15 cm. Skenovanie prebieha veľmi rýchlo a behom sekundy je skener schopný zamerať až 200 tisíc bodov. Letadlo sa zvyčajne pohybuje vo výške približne 300 – 5000 m. Jednotlivé lúče sa rozširujú a pri dopade vytvárajú akýsi odtlačok (footprint), ktorého veľkosť závisí od výšky letu a pohybuje sa od 0,2 až 2m. Lúč, odrazený od povrchu sa vracia späť do prístroja a v daný moment je časomiera vypnutá. Väčšinou sa jeden lúč neodrazí iba raz. Odráža sa pri prechode atmosférou, v korunách stromov, budov a samotnej zemi. Tieto odrazy nazývané echá, slúžia aj k tvorbe DMR (digitálny model reliéfu, angl. DTM – Digital Terrain Model) v zalesnených oblastiach.(obr. urban land cover) (Tencer, 2012).

V súčasnosti dokážu skenery zaznamenať všetky odrazy a množstvo iných informácií, nazývajú sa fullwave LiDAR (Obr. 6). Staršie modely boli schopné zaznamenať len prvý a posledný odraz (Tencer, 2012).

Okrem polohopisných súradníc vieme získať aj informácie o intenzite odrazu. Z čoho je možné vypočítať odrazivosť materiálu, čo napomáha k lepšej interpretácii dát z merania. Vieme tak identifikovať typ materiálu (betón, vegetácia, zem a iné) (Tencer, 2012).



Obr. 6 Ilustrácia odrazu laserového lúču a zaznamenanie sily signálu; Zdroj: Yan et al., 2015

Spracovanie

Skenovaním terénu získame obrovské množstvo dát, ktoré je potrebné spracovať pre koncového užívateľa. Väčšinou je pre každý skenovací systém vytvorený softvér, v ktorom sa dáta upravujú, pospájajú a vyrovnávajú. Následne sa tieto dajú ďalej upravovať, klasifikovať, vytvárať z nich 3D modely, DTM či DSM (Hofierka et al., 2014)

Základné komponenty

Zostava skeneru (obsahujúcu laser, snímacu mechaniku a optiku), letecká anténa GPS, jednotka inerciálnej meracej jednotky (IMU), jednotka riadenia a

zaznamenávania údajov, operátorsky prenosný počítač, systém riadenia letu (Beraldin et al., 2010).

Výhody a obmedzenia vzdušného laserového skenovania

Pri skenovaní potrebuje mať LLS jasné ovzdušie bez mrakov a hmiel. Pri skenovaní povrchu zeme nemá problém s listnatými stromami, hlavne v zimnom období, keď sú stromy bez listia. Väčší problém má s hustými, ihličnatými stromami alebo v dažďových pralesoch, kde lúče nedokážu dopadnúť na zem. Chyba v dátach nastáva aj z dôvodu celkovej odrazivosti objektov, jedná sa o vodný povrch, mokrý povrch napr. ulíc, striech domov (Beraldin et al., 2010).

Napriek menším obmedzeniam je LLS využívaný k vytváraniu vysoko kvalitných modelov terénu. Je to zabezpečené hlavne týmito prvkami: vysoká hustota merania a vysoká hustota údajov, rýchly zber údajov, prenikanie vegetačným krytom, minimálne množstvo referenčných bodov (Beraldin et al., 2010).

1.2.3 Družicová fotogrametria

Ako už bolo spomenuté v podkapitole 2.2.1 Letecká fotogrametria, je družicová fotogrametria súčasťou fotogrametrie. Dáta, ktoré družicová fotogrametria poskytuje sú vo väčšine multispektrálne a aj voľne stiahnuteľné. Ich rozlíšenie je oveľa horšie než pri leteckej fotogrametrii, ale pre určitý mapovania sú postačujúce, čo dokazuje aj množstvo výskumov. V jednom z nich (Kopecká et al., 2017), využívajú snímky zo satelitu Sentinel 2-A (rozlíšenie 10 – 60m), pre mapovanie berlínskej zelene využívali Tigges et al. (2013) dáta zo satelitu RapidEye (6,5 m). Chengqi et al. (2003) využili satelit IKONOS, ktorého snímky majú rozlíšenie 1m. Viac takýchto príkladov spomenieme v podkapitole 2.2.4 Metódy klasifikácie zelene.

Princíp fungovania družicovej fotogrametrie

Družice/satelity vo väčšine prípadov fungujú na princípe multispektrálneho skenovania. Skener, ktorý je umiestnený na satelite sníma odrazené slnečné žiarenie vo viacerých spektrách súčasne, takže ide o pasívnu metódu DPZ. Rozlišujeme multispektrálne a hyperspektrálne skenovanie, podľa počtu pásiem. Princíp skenerov je analogický ako pri stolných riadkových skeneroch, kde obrazový záznam vzniká postupne po jednotlivých obrazových elementoch, napr. pixlov alebo riadkov pixlov, či

ich súborom. Dáta sú ukladané v rastrovom formáte, pričom každému z pixlov dokážeme priradiť parametre ako priestor, vlnovú dĺžku, čas a intenzitu EMG žiarenia.

Výhodou satelitných dát je, že zachytávajú veľké priestory, ktoré sú v mnohých prípadoch ťažko prístupné a poskytujú dáta periodicky (niekoľko hodín či dní). Nevýhodou je to, že je potrebné slnečné žiarenia ako aj vhodné počasie bez oblakov či oparu (Hofierka et al., 2014).

Príklady družíc a skenerov

Je známych množstvo skenerov, jedným z najznámejších družíc, ktoré sú nositeľom multispektrálnych skenerov je LANDSAT (MSS- Multi Spectral Scanner, TM – Thematic Mapper, ETM+ - Enhanced Thematic Mapper Plus), Terra, SPOT, IKONOS, RESURS, GeoEye. Nositeľom hyperspektrálneho skeneru je napr. EO-1(Hyperion) (Hofierka et al., 2014).

1.3 Metódy identifikácie zelene

V práci sme využili viacero metód na identifikáciu zelene použitím troch softvérov. Pri klasifikácii sme potrebovali len niektoré z ich funkcií, preto sme sa rozhodli čiastočne popísať tieto funkcie, teda metódy, ktoré sú využívané pri daných softvéroch.

1.3.1 Popis nástroja lasclassify v softvéri LasTools

Lasclassify má viacero parametrov, kde najviac pracuje s parametrami *planar* (plochosť) a *rugged*(nepravidelnosť). Pri základnom nastavení *planar* = 0,1, sa zisťuje štandardná odchýlka v rozpätí 10cm a dochádza k hľadaniu susedných bodov, ktoré spolu vytvárajú plochý tvar. Čím je väčšie rozpätie tým viac plochých regiónov nájdeme. Čo v praxi znamená, že pri selektovaní dosiahneme väčší počet bodov, ktoré budú priradené k budovám a menej k vegetácii. Pri nastavení parametra *rugged* sa mení vyhľadávacia plocha pre nepravidelné objekty.

Problém s určovaním plochých plôch môže nastať pri veľkom šume, kde softvér nedokáže rozpoznať čo je ploché. Vtedy sa je potrebné viac zaoberať s nastaveniami plochosti (*planar*). V predvolených nastaveniach sa počíta s tým, že už máme určené horizontálne a vertikálne jednotky v metroch a teda nastavený súradnicový systém. Takže možnosti ako *feet a elevation_feet* ostanú nezaškrtnuté.

Ďalšími možnosťami sú:

small_buildings – využíva sa na území, kde sú malé budovy a je potrebné ich klasifikovať ako budovy

no_gutters – slúži na klasifikovanie okrajov budov

wide_gutters – pre klasifikovanie okrajov striech

keep_overhang - neodstraňuje vegetáciu, ktorá je nad budovami alebo v ich blízkosti

Ako už bolo spomínané, pri využívaní *lasclassify* bez licencie dochádza k vynulovaniu intenzity, *gps_času*, užívateľským dátam a zdroju bodu. Taktiež sa zmení poradie bodov a pridá sa biely šum k súradniciam bodov.

1.3.2 OBIA a funkcionálna vybraných prvkov v eCognition

V posledných rokoch sú čoraz viac dostupné dáta s vysokým rozlíšením, nastal pokrok v technológiách získavania údajov z diaľkového snímania a zvýšený dopyt po aplikáciách diaľkového snímania (Belward and Skoien, 2015). Patria sem dáta zo satelitných zdrojov (WorldView, Gaofen, SuperView) a leteckých zariadení (UAV, lietadlá). Aj kvôli týmto podnetom vznikla výzva, klasifikovať jednotlivé objekty na zemi pomocou týchto údajov. Jednou z techník klasifikovania objektov bola objektovo orientovaná analýza snímok (OBIA), ktorá nahradila štandardnú metódu založenú na pixloch (Blaschke et al., 2014), ktorá uľahčí klasifikovanie objektov.

Analýza snímok založená na objektoch (OBIA), je technika používaná na analýzu digitálnych snímok, vyvinutá relatívne nedávno v porovnaní s tradičnou obrazovou analýzou založenou na pixloch (Burnett and Blaschke, 2003). Pixlovo orientovaná analýza je založená na informáciách na úrovni pixlov, pričom objektovo orientovaná analýza je založená na informáciách skupiny pixlov, nazývaných objektov alebo obrazových objektov. Konkrétnejšie obrazový objekt je skupina pixlov, ktorá si je podobná v určitom spektre, veľkosti, tvare, textúre ako aj kontexte so susediacimi pixlami (Blaschke, 2010).

Dôležitým krokom pre vznik OBIA bola medzinárodná konferencia v Rakúsku v roku 2006. A následne vzniknutie množstva publikácií, ktoré túto metódu

presadzovali (Hay and Blaschke, 2010). Čo viedlo k tomu že od roku je táto metóda rovnocennou časťou diaľkového mapovania pôdneho krytu (ang. land cover).

Všeobecne mapovanie zemského povrchu je komplikovaný proces s veľkým množstvom faktorov, ktoré ovplyvňujú kvalitu konečného produktu (Khatami et al., 2016). Pri klasifikačných procesoch založených na objektoch sa musí zväžiť veľa možností, vrátane typu snímok, metódy segmentácie, presnosti, klasifikačného algoritmu, skúšobnej vzorky, vstupných funkcií a cieľových tried (Ma et al., 2017). Ma et al. (2017) opisujú okrem iného, výhody a nevýhody objektovo orientovanej analýzy. Potvrdzujú, že snímky s vysokým rozlíšením sú najbežnejšie využívané pre mapovanie využitia zeme a existuje korelácia medzi rozlíšením snímok a veľkosti skúmaného územia. Neprekvapivým zistením bolo, že čím vyššie rozlíšenie tým je klasifikácia presnejšia, avšak v niektorých prípadoch, ktoré sú zamerané na mestské prostredie, nie je celková presnosť vysoká, vzhľadom veľkému množstvu rozličných objektov. Z čoho vyplýva, čím viac tried chceme klasifikovať, tým celková presnosť klesá. Preto je objektovo orientovaná klasifikácia vhodnejšia na poľnohospodárske plochy, ale jej využitie má miesto aj v mestskom prostredí.

Niektoré výskumy poukazujú aj na zlé stránky objektovo orientovanej analýzy a tvrdia, že nemá výhody pred inými metódami (pixlovo orientovaná), ako napr. Gavazzi et al. (2016) tvrdia, že táto metóda je najhoršia oproti ich najlepšej klasifikácii.

Opis vybraných prvkov eCognition

Na princípe objektovej analýze (OBIA) funguje aj softvér eCognition, ktorý sme sa rozhodli využiť pre mapovanie mestského prostredia.

Softvér eCognition Developer 9.0, ktorý vytvorila spoločnosť Trimble sídliaca v Nemecku. Je založený na výkonnej objektovej analýze snímok. Využíva sa vo vedách o Zemi, kde pomocou určitých súborov pravidiel vie automaticky analyzovať údaje z diaľkového prieskumu Zeme.


Na Ústave geografie nie je tento produkt veľmi rozšírený a preto sme sa rozhodli opísať určité funkcie tohto programu, ktoré sme využívali a testovali pre naše skúmané územie. Konkrétny postup a využité parametre sú popísané bližšie v Metodike práce. Pre popis a pochopenie jednotlivých prvkov sme využili príručku pre používateľa (eCognition Developer, 2014), ktorá obsahuje kompletný popis softvéru eCognition.

Keďže softvér pracuje so snímkami a rastrami, mohli sme využiť dáta, ktoré vznikli za pomoci programu ESA. Ortofotosnímky aj laserové dáta, z ktorých sme vyvodili výšku povrchu nad terénom (nDSM). Tieto údaje sa načítajú do programu a môže sa pristúpiť k prvému kroku a to je segmentácia snímok na základe určitých parametrov.

Softvér ponúka viacero možností segmentácie a cieľom bolo zistiť, aká segmentácia sa hodí k naším dátam najlepšie. Môžeme ju rozdeliť na segmentáciu zhora nadol a naopak zdola nahor.


Segmentácia zhora nadol

Segmentácia zhora nadol rozdelí objekt/ snímku na veľké množstvo malých častí, zhluky pixlov, podľa určitého algoritmu. Na výber je viacero možností (Obr. 7): *chessboard segmentation* (šachovnicová segmentácia), *quadtree based segmentation*, *contrast split segmentation* (segmentácia rozdeľujúca podľa kontrastu).




Obr. 7 Možnosti segmentácie.

Ako prvú sme vylúčili *chessboard segmentation* (Obr. 8). Z názvu vyplýva, že sa územie rozdelí na množstvo pravidelných úsekov, pripomínajúcich políčka na šachovnici. Takáto segmentácia by nám neprispela k vyselektovaniu vegetácie.




Obr. 8 Princíp fungovania *chessboard segmentation*.

Podobne segmentáciou je aj *quadtree based segmentation* (Obr. 9). Ktorá segmentuje objekt na vopred zvolené veľké segmenty a na základe váhy vrstiev.



Obr. 9 Princíp fungovania *quadtree based segmentation*.

Jednou z využiteľných segmentácií bola *contrast split segmentation*, ktorá pomocou kontrastu rozdelí objekt na svetlé a tmavé časti. Tu sme sa snažili aplikovať nDSM vrstvu, ktorá je zložená z farieb od bielej po čiernu na základe výšky objektov nad terénom. Nedokázali sme nastaviť také parametre, ktoré by nám scénu rozdelilo na dostatočne množstvo objektov, pretože kontrast medzi povrchom a daným objektom (malým stromom) nebol dostatočne veľký (Obr. 10). Aj pri výbere tých najdetailnejších parametrov boli malé stromy zanedbané a považované za časť terénu (Obr. 11). Tento typ delenia by sme mohli využiť, ak by sme využívali dáta, kde by bol kontrast zreteľnejší alebo by sme sledovali len vysokú vegetáciu.



Obr. 10 Vrstva nDSM (vľavo) rozdelená na základe parametrov (Obr. 11) a grafické znázornenie parametrov (v pravo).

Parameter	Value
Settings	
Chessboard Tile Size	100000
Level Name	New Level
Overwrite existing level	Yes
Minimum threshold	0
Maximum threshold	255
Step size	5
Stepping type	add
Image layer	Layer 5
Class for bright objects	Klasifikované
Class for dark objects	unclassify
Advanced Settings	
Contrast mode	edge ratio
Execute splitting	Yes
Variable for best threshold	
Variable for best contrast	
Minimum relative area dark	0.1
Minimum relative area bright	0.1
Minimum contrast	0
Minimum object size	1

Obr. 11 Parametre testované pri *contrast split segmentation*.


Segmentácia zdola nahor

Pri segmentácii zdola nahor dochádza k skladaniu pixlov, resp. menších častí do väčších segmentov. Pri tomto type je na výber týchto možností: *multiresolution segmentation* (segmentácia viacerých rozlíšení), *spectral difference segmentation* (segmentácia spektrálnych rozdielov) a The Multi-Threshold Segmentation (Segmentácia viacerých prahov).

Multiresolution segmentation vyhovovala najlepšie k našim dátam. Pri tomto algoritme dochádza k spájaniu jednotlivých pixlov alebo existujúcich obrazových objektov s ich susedmi, na základe kritérií relatívnej homogenity. Tieto kritéria homogenity sú kombináciou spektrálnych a tvarových kritérií.


Hlavným parametrom je voľba váhy, akou budú jednotlivé pásma (ang. bands) prispievať. Ideálnu kombináciu je ťažko určiť, je pre každé dáta rôzna a založená subjektívnym rozhodovaním. My sme disponovali s RGB, NIR vrstvami a nDSM vrstvou (vznikne odčítaním DTM a DSM).

Je potrebné si uvedomiť, že vrstva nDSM nesedí úplne s ostatnými vrstvami (Obr. 12), je to spôsobené iným rozlíšením (0,5 m) a iným zdrojom dát (z LAS dát). Aj keď boli dáta vytvárané približne v rovnakom čase, ortofoto snímky (0,1 m) majú isté skreslenie. Tento fakt spôsobil malé nepresnosti klasifikácie.




Obr. 12 Poukázanie na iné rozlíšenie nDSM vrstvy oproti ostatným vrstvám.

Na Obr. 13 sme uviedli za príklad tri možnosti aplikovania váhy vrstvy pri segmentácii. Kde 1.,2.,3. vrstva sú RGB, 4. je NIR a 5. je nDSM. Na ľavom príklade mali všetky vrstvy rovnakú váhu a preto sa územie rozdelilo na viacero častí ako pri zvyšných dvoch príkladoch. Je to kvôli tomu, lebo každá vrstva si môže vyčleniť rovnaký počet dielov a žiadna z nich nemá výhodu, kde pri strednom príklade môžeme vidieť, že vrstva nDSM má najväčšiu váhu a preto jej hodnoty sú najpodstatnejšie. Pri treťom príklade sme využili kombináciu troch vrstiev (Green, NIR, nDSM).




Obr. 13 Znáozornenie vplyvu váhy vrstiev pri segmentácii.

Dôležitým krokom je nastavenie veľkosti mierky (Obr. 14). Čím vyššie číslo tým vyššie segmenty, menšia presnosť. Čím menšie číslo tým je presnosť vyššia ale na druhej strane dlhší výpočet, potrebné lepšie vybavenie a nadbytočné dáta.



Obr. 14 Vplyv mierky a kritérií homogenity na segmentáciu.

Dôležitým prvkom je prispôbenie kritérií tvaru (shape) a kompaktnosti (compactness) (Obr. 14 a 15). Čím vyššie je hodnota tvaru, tým menší vplyv má farba na segmentačný proces. Pri určovaní kompaktnosti je tým väčšia kompaktnosť a hladšie polygóny, čím vyššie číslo. Takže aj pri týchto kritériách platí, čím menšia hodnota tým viac polygónov. Pri *multiresolution segmentation* sú celkovo vyššie nároky na procesor a pamäť, kvôli čomu to niekedy nemusí byť najlepšia voľba.



Obr. 15 Vplyv kritérií kompozície a homogenity pri *multiresolution segmentation*.


Doplňujúcou segmentáciou zdola nahor je *spectral difference segmentation* (segmentácia spektrálnych rozdielov), ktorá spája obrazové objekty s podobnými

spektrálnymi vlastnosťami. Nie je možné ju využiť na úrovni pixlov. Pre naše územie sme nenašli konkrétne využitie.

Poslednou možnosťou je *The Multi-Threshold Segmentation* (Segmentácia viacerých prahov), ktorá vytvára výsledné obrazové objekty založené na definovanej prahovej hodnote pixlov. Pre naše účely bola táto segmentácia komplikovaná.


Klasifikácia vegetácie

Naším cieľom bolo segmentovať naše územie, tak, aby bol každý strom samostatným segmentom. Tento cieľ sme nedokázali splniť, podarilo sa nám iba rozdiferencovať oblasť na také časti, ktoré kopírovali stromy. Následne sme na tieto segmenty aplikovali klasifikáciu, ktorú v tejto časti popíšeme.



Obr. 16 Základné a pokročilé algoritmy klasifikácie.

Pri klasifikácii je možné využiť viacero algoritmov (Obr. 16), ale v našom prípade stačila iba jednoduchá klasifikácia, konkrétne *assign class* (priradiť triedu)(Obr. 17).




Obr. 17 Možné nastavenia v *assign class*.

Zárukou dobrej klasifikácie je správna segmentácia na ktorú môžeme aplikovať klasifikačné parametre. Nastavenie kategórií je vhodné určiť vopred, aby sme si vedeli presne určiť klasifikačné kritéria.


Pri klasifikovaní zelene je potrebné mať dáta, ktoré obsahujú blízko infračervené spektrum. Práve pomocou neho a červeného spektra farieb si vieme vytvoriť NDVI. Pri členení vegetácie na trávnatý porast a stromy je potrebné mať vrstvu, ktorá bude aspoň čiastočne niesť údaje o nadmorskej výške. V lepšom prípade sú to LAS údaje, ktoré nesú informácie o intenzite, nadmorskej výške a poradí odrazu. Menej presným variantom je vytvorený nDSM, ktorý vyjadruje výšku objektu. Tento variant sme využili v práci my, pre ktorý konkrétne aplikovanie popíšeme.

V prvom rade je potrebné kategorizovať vegetáciu a ostatné objekty. Keďže k dispozícii máme NDVI, môžeme si v prahových podmienkach (threshold conditions) určiť čo budeme považovať za vegetáciu a čo za ostatné objekty (Obr. 18). V tejto časti procesu klasifikácie je vhodné vedieť čo NDVI predstavuje a skúšať jednotlivé rozpätie pre vlastné údaje. NDVI je možné využiť pri určovaní kondície rastlín, hustoty rastlín alebo v našom prípade je rozlišovať vegetáciu od iných objektov na základe hodnôt NDVI. Čím vyššia hodnota má daný segment je väčšia pravdepodobnosť, že daný objekt patrí k zeleni. Pre naše územie sme zistili, že hodnoty nad 0,2 prevažne patria k vegetácií. Preto je vhodné viacnásobné testovanie a porovnávanie s referenčnými dátami.




Obr. 18 Zobrazenie územia v CIR farbách (vľavo) a hodnotách NDVI(vpravo), kde svetlejšia farba znázorňuje vyššiu hodnotu NDVI.

Pri našich snímkach si môžeme všimnúť, že objekty vrhajú tieň, ktoré skresľujú hodnoty NDVI. V našom prípade to pre klasifikáciu nemalo veľký vplyv, väčší vplyv to má pri klasifikácii nižších objektov. Iba v niekoľkých prípadoch nastala výrazná zmena NDVI, kvôli tieneniu budovou (Obr. 19).



Obr. 19 Nesprávna klasifikácia stromov (v ľavo) a zobrazenie danej lokality v iných spektrách (v pravo).

Po oddelení vegetácie od ostatných objektov je potrebné pristúpiť ku kategorizovaniu podľa výšky objektov. Tento údaj získame z vrstvy nDSM (Obr. 20). Kde nižšie hodnoty budú patriť nižšej vegetácii (tmavá farba) a vyššie hodnoty stromom a kríkom (svetlejšia farba).



Obr. 20 Porovnanie CIR snímky s nDSM vrstvou.

Tento softvér má ďaleko viac možností využitia a sfér aplikovania. Táto podkapitola mala priniesť určitý prehľad, ktorý je potrebný k pochopeniu postupu využitého pre mapovanie vegetácie v podkapitole 4.2 Spracovanie údajov.

1.3.3 Princípy klasifikácie v Cloud Compare – CANUPO

Ďalšou možnosťou ako automaticky vyselektovať vegetáciu, bolo využiť program Cloud Compare, konkrétne jeho zásuvný modul CANUPO. Nie je veľmi zaužívaným nástrojom pre automatické extrahovanie vegetácie v meste, skôr je využívaný v prírodných prostrediach ako je koryto rieky, močiar, kde sa pohybujeme

v inej mierke než v mestskom prostredí (Brodu and Lague, 2012). Naším cieľom bolo aplikovať tento Canupo na skúmané územie a posúdiť jeho využiteľnosť pre klasifikáciu vegetácie v meste.

Tento zásuvný modul pracuje priamo s bodovým poľom, do značnej miery nereaguje na tienenie ani na zmenu hustoty bodov. Najdôležitejšie je, že je variabilný a heterogénny pri charakteristike tried (Brodu and Lague, 2012).

Tento nástroj pracuje v určitom lokálnom rozmere, to znamená, že sa pozerá na mračno bodov z geometrického hľadiska, čiže ako geometricky vyzerá dané mračno bodov na určitom mieste v danej mierke. Hovoríme teda buď o línii (1D), rovinatej ploche (2D), alebo 3D objekte. Napríklad pri scéne, kde je povrch zložený zo skál, štrku, vegetácie. Sa nám pri niekoľko centimetrovej stupnici javí skalnatý povrch ako 2D, štrk ako 3D a vegetácia ako zmes línii (stonky) a 2D plôch(listy). Pri väčšej mierke (napr. 30cm), skalnatá podložka stále vyzerá ako 2D, štrk vyzerá už viac ako 2D než 3D a vegetácia má už 3D tvar. Ak skombinujeme tieto informácie o geometrii z rôznych mierok, vieme vytvoriť kategórie objektov, ktoré sú na skúmanom území (Brodu and Lague, 2012).


Táto klasifikácia prebieha počas tzv. tréningovej fázy automaticky. Základnou myšlienkou klasifikačného postupu je definovanie najlepšej kombinácie stupníc, pri ktorých sa meria rozmernosť, čo umožňuje maximálne vymedzenie dvoch alebo viacerých kategórií. Prakticky by mohol používateľ sám určiť rozsah stupníc, pri ktorých budú jednotlivé kategórie najviac geometricky odlišné, ale v mnohých prípadoch to kvôli veľkej variabilite tvarov a veľkostí predmetov, nie je jednoduché. Kvôli tomu sa využíva automatizovaný tréning, ktorý nájde tú najlepšiu kombináciu stupníc (čo znamená, že ku konečnej klasifikácii prispievajú všetky stupnice ale s rôznymi hmotnosťami), čo maximalizuje separovateľnosť dvoch kategórií, ktoré používateľ predtým ručne definoval (Brodu and Lague, 2012).

Tieto informácie z tréningového procesu sa potom využijú ako predloha pre kategorizovanie bodov na väčšom území. Tento proces prebieha pre odlíšenie dvoch kategórií, ak je na území viac kategórií, je potreba vytvorenia viacerých tréningov. Napríklad v mestskom prostredí chceme klasifikovať stromy, budovy, autá a cestu. V tomto prípade je potrebné prv vytvoriť predlohu pre vegetáciu a ostatné, následne budovy a zvyšok, nakoniec autá a cestu.

2 Záujmové územie

Záujmovou oblasťou bola centrálna časť mesta Košice, ktoré sa nachádzajú v centrálnej časti Európy, na východnom Slovensku. S počtom obyvateľov približne 240 000, sú Košice druhým najväčším mestom na Slovensku a zároveň metropolou východného Slovenska. Celková výmera mesta je 243,75 km² (ŠÚSR, 2011). Centrum mesta leží na nive rieky Hornád v nadmorskej výške 208 m n. m., smerom na západ územie stúpa o niekoľko desiatok metrov, kvôli terase rieky. Územie leží v teplej klimatickej oblasti, kde priemerná teplota vzduchu dosahuje okolo 9 °C.

Záujmové územie má približne 5,3 km², zahŕňa historické centrum mesta a jeho okolie. Centrum mesta je príznačné svojou hustou zástavbou a malou koncentráciou zelene, čoho dôsledkom vznikajú tepelné ostrovy - UHI (Onáčillová and Gallay, 2018). V okolí centra mesta je zvýšená koncentrácia vegetácie a to hlavne vo forme rozľahlých parkov, skupín stromov medzi blokmi panelových budov, stromov okolo ciest, či stromov na záhradách rodinných domov. Tieto rozľahlejšie plochy zelene pozitívne vplývajú na mikroklimu mesta (Hofierka et al., 2017).




Obr. 21 Záujmové územie lokalizované v rámci Európy (v ľavo hore), Slovenska (v ľavo dole) a v rámci Košíc (vpravo); Podklady: basemaps

3 Údaje a metodika

3.1 Údaje

V práci sme využívali dáta z leteckého laserového skenovania (Obr. 22) a fotogrametrické snímky (Obr. 23). LLS boli potrebné na zachytenie 3D geometrie a následné odlíšenie jednotlivých objektov v skúmanej oblasti. Multispektrálne snímky (R, G, B, NIR) k vypočítaniu NDVI a následnej separácii vegetácie od ostatných objektov. Obidve misie zberu dát boli vykonané v letných mesiacoch roku 2016, firmou Photomap s.r.o. sídliacou v Košiciach. Pre LLS bol využitý laserový skener Leica ALS70, ktorého parametre sú popísané v Tab. 1.




Obr. 22 Automaticky klasifikované dáta z laserového skenera Leica ALS70, poskytuté firmou Photomap.

Tab. 1 Parametre misie LLS nalietavané LIDARovým systémom Leica ALS70-CM.

Parametre	Hodnota
Výška letu nad zemským povrchom	1050 - 1087 m
Letová nadmorská výška nad priemernou hladinou mora	1333 m
Celkové množstvo bodov	365 mil.
Celková rozloha	4 km ²
Priemerná hustota bodov (celkovo/na zemi)	91/15 bodov na m ²
Absolútna celková presnosť v otvorených oblastiach	0.1 m @ 1 σ

Zdroj: Hofierka et al. (2017)

Fotogrametrické snímky v pravých a nepravých farbách blízko infračerveného spektra boli vytvorené digitálnym fotoaparátom Vexcel UltracamXp s priestorovým rozlíšením 10cm (Obr. 23).



Obr. 23 Ukážka ortofotosnímkov v pravých farbách (vľavo) a nepravých farbách – CIR (vpravo).

3.2 Spracovanie údajov


3.2.1 Príprava a klasifikácia lidarových dát v Lastools

Dáta, ktoré nám boli dodané firmou Photomap, neboli špeciálne upravované a preto bolo potrebné tieto dáta skontrolovať, upraviť a prispôbiť na konkrétnu klasifikáciu, ktorú sme uskutočnili softvérmi LasTools, eCognition a Cloud Compare.

Prípravu dát sme uskutočnili v softvéri LasTools. Pod tento softvér spadá niekoľko menších programov (nástrojov), ktoré sú špecializované na konkrétne úkony a vedia rýchlo a efektívne zobrazovať a spracovať obrovské množstvo bodov. Pri príprave dát sme sa prevažne riadili postupmi Isenburg a, b, c (2013). M. Isenburg vytvoril tento softvér a taktiež formát LAS/LAZ, ktorý je využívaný vo všetkých odvetviach, kde sa pracuje s bodovým mračnom.


Kontrola dát

Prvým krokom bola vizuálna kontrola mračna dát, s ktorým sme pracovali (Obr. 24). Na to nám poslužil *lasview*, kde je možné prezeranie dát, upravovanie dát, zafarbenie bodov podľa rôznych kritérií, vytvorenie jednoduchého 3D modelu a pod.



Obr. 24 Kontrola dát.

V našom prípade sme zistili, že dáta už boli klasifikované, ale s väčšími nepresnosťami a s bodmi identifikovanými ako šum (Obr. 25) Z tohto dôvodu bolo potrebné znovu klasifikovať mračno bodov presnejšie.



Obr. 25 Ukážka pôvodných dát, ktoré boli nesprávne klasifikované (autá ako vegetácia) a s nežiadaným šumom (ružové body).

Je potrebné podotknúť, že pri neplatenej verzii LasTools nie je možné vykonať určité úkony, resp. dajú sa vykonávať s istými obmedzeniami. Napríklad nie je možné rozložiť prácu na viacero jadier alebo pri s viac než 1,5 miliónoch bodov (v niektorých prípadoch 3 mil.) sa pri výstupoch vytvorí čierny pás cez celý výstup alebo sú dáta znehodnotené iným spôsobom. Táto skutočnosť zapríčinila spomalenie práce s .las dátami a bolo potrebné vytvoriť menšie úseky, aby bolo možné vytvárať výstupy bez poškodenia.

Lasoverlap bol použitý, na vytvorenie KML a png výstupu, kde KML nesie tú istú informáciu ako png formát, ale slúži na zobrazenie konkrétnych informácií v Google Earth (Obr. 26). Pre správne zobrazenie KML je potrebné určiť koordinačný systém. My sme využívali dáta, ktoré boli v súradnicovom systéme S-JTSK / Krovak East North. Tento súradnicový systém nie je na výber v LasTools a preto sme na ukážku použili dáta v UTM 34 NORTH. Pri KML vrstve vidíme určité posunutie, približne o 2 metre.



Obr. 26 KML výstup zobrazený v Google Earth, vytvorený v *lasoverlap*, poukazujúci na prekryt v dátach.

Pre presnú kontrolu laserových dát sa využíva nástroj *lascontrol* (Obr. 27). My sme tento nástroj nemohli využiť, kvôli chýbajúcim referenčným dátam, ktoré obsahujú presné súradnice, nadmorskú výšku a popis daného bodu čo sa v ňom nachádza. Výsledkom je textový súbor, ktorý porovnáva nadmorskú výšku referenčného bodu s bodom z laserového skenovania.

```
sampld TIN at 29 of 29 control points.  
avgabs/rms/stddev/avg of elevation errors are  
4.63438/9.61987/8.62324/4.55475 meter. skew is 1.47593.
```

Obr. 27 Ukážka výsledku hodnotenia chýb v *lascontrol*.

Pri kontrole dát pomôže aj *lasinfo*, ktoré vygeneruje metadáta (Obr. 28). Vieme z nich vyčítať množstvo informácií, ktoré sú dôležité pre užívateľa, napr. čas zberu dát, hustota dát, oznám chýbajúcich či nesprávnych údajov a iné. Konkrétne naše body majú hustotu 67,35 bodu na m² a vzdialenosť medzi jednotlivými bodmi je v priemere 12 cm.


```

gps_time 289096.938948 292738.931748
number of first returns: 14280722
number of intermediate returns: 376964
number of last returns: 14281383
number of single returns: 12409367
covered area in square units/kilounits: 245440/0.25
point density: all returns 67.35 last only 58.19 (per square units)
spacing: all returns 0.12 last only 0.13 (in units)
overview over number of returns of given pulse: 12409367 3045812 963450 106875 4
198 0 0
histogram of classification of points:
      4628 unclassified (1)
    2761544 ground (2)
    5284604 low vegetation (3)
    3811661 high vegetation (5)
    4635766 building (6)
     31499 noise (7)

```

Obr. 28 Ukážka metadát vytvorená pomocou *lasinfo*.

Príprava dát

Prípravu dát sme uskutočnili taktiež v rôznych nástrojoch LasTools, kde sme využili konkrétne parametre, ktoré sú uvedené v Tab. 2. Ako bolo spomenuté vyššie, je potrebné rozdeliť dané územie na menšie časti, ak pracujeme bez licencie. Na to sme využili funkciu *lastile*. V *lastile* sme otvorili pôvodné dáta, ktoré sme skontrolovali. Je vhodné nastaviť projekciu, napr. UTM zone 34 north a vertikálny údaj na NAVD88, pre naše dáta v S-JTSK sme nezadávali nič. Naše časti sme potrebovali mať s menej než 1,5 mil. bodov a keďže dáta nemajú milimetrovú presnosť zmenili sme aj rozlíšenie.

Tab. 2 Využíte parametre v jednotlivých nástrojoch LasTools.

Nástroj	Parametre
<i>lastile</i>	-rescale 0.01 0.01 -tile_size 100 -buffer 5
<i>lasnoise</i>	-step_xy4 -step_z 1 -remove_noise
<i>las2las</i>	-drop_classification 7
<i>lasground</i>	-city -ultra_fine
<i>lasheight</i>	-drop_below -0.5 -drop_above 85


Na začiatku kapitoly sme poukázali na šum v dátach (Obr. 25). Tento šum sme odstránili pomocou nástroja *lasnoise*. Po opätovnom prehliadnutí dát sme zistili, že niektoré body klasifikované ako šum ostali v dátach, preto sme využili *las2las*, kde sme odstránili body klasifikované ako šum.

Ďalším veľmi dôležitým krokom bola klasifikácia terénu. Pričom sme využili funkciu *lasground*. Selektovanie sme uskutočnili niekoľko krát, s rozdielnymi parametrami. Menili sme veľkosť krokov (step size). Ukázalo sa, že najlepšou alternatívou pre naše územie bolo stredne veľké mesto s veľkosťou krokov 25 metrov

a s prednastavenou detailnosťou(default) alebo s vysokou detailnosťou (ultra). Ostatné nastavenia sme nechali prednastavené, pretože po ich zmene sa zhoršila selekcia pozemných bodov. Pri klasifikácii došlo k menším chybám, kde niektoré body neboli správne priradené.

V ďalšom kroku sme využili funkciu *lasheight*. Vypočítali sme pomocou nej výšku každého bodu nad povrchom, ktorý sme v predchádzajúcom kroku vytvorili. Táto funkcia funguje tak, že z jednotlivých pozemných bodov vytvorí TIN, ktorý je vlastne 0 metrov nad povrchom. Výška ostatných bodov sa teda odvíja od vytvoreného TIN modelu. Taktiež sme sa zbavili prípadných bodov, ktoré sú nižšie než 0,5 metra pod povrchom a vyššie než 85 metrov nad povrchom (najvyššia budova 83m). Výšku bodov sme museli vypočítať hlavne kvôli klasifikovaní bodov na budovy, vegetáciu a ostatné prvky.

Kvôli lepšej prehľadnosti využitých nástrojov sme vytvorili schému prípravy dát (Obr. 29).



Obr. 29 Schéma prípravy dát.

Klasifikácia: vysvetlenie pojmov využívaných v *lasclassify*

Po kontrole a príprave našich dát, sme mohli uskutočniť klasifikáciu. Klasifikovali sme vegetáciu (trieda 5), človekom vytvorené objekty (6) a neklasifikované body (1) v nástroji *lasclassify*. Najviac sme sa sústredili na presné klasifikovanie zelene, kde je dôležité aby bola hustota viac než 2 body na m². V našom prípade bola priemerná hustota až okolo 60 b/m².


Klasifikácia: Výber optimálnej klasifikácie

Prvým krokom bolo klasifikovať naše územie podľa predvolených nastavení (Tab. 3). Kde sme zhodnotili klady a zápory a následne to porovnávali s výsledkami z ostatných klasifikácií.

Tab. 3 Testované parametre *lasclassify* a ich hodnotenie. Skratky: ✓ - Použitý parameter, ✗ - Nepoužitý p., HF - Horizontal feet, VF - Vertical feet, SAS - Search area size, BP - Building planarity, FR - Forest ruggedness, IG - Include gutters, WG - Wide gutters, NTB - No tiny buildings, NTO - No tree overhang.


Pokus	HF	VF	SAS	BP	FR	IG	WG	NTB	NTO	Poznámka
1.	✗	✗	2	0,1	0,4	✓	✗	✓	✓	Dobré
2.	✗	✗	3	0,1	0,4	✓	✗	✓	✓	Nevyhovujúce
3.	✗	✗	1	0,1	0,4	✓	✗	✓	✓	Nevyhovujúce
4.	✗	✗	1,5	0,1	0,4	✓	✗	✓	✓	Dobré
5.	✗	✗	1,8	0,1	0,4	✓	✗	✓	✓	Dobré
6.	✗	✗	2	0,2	0,4	✓	✗	✓	✓	Dobré
7.	✗	✗	2	0,2	0,5	✓	✗	✓	✓	Dobré
8.	✗	✗	2	0,1	0,5	✓	✗	✓	✓	Dobré
9.	✗	✗	2	0,2	0,6	✓	✗	✓	✓	Dobré
10.	✗	✗	2	0,1	0,6	✓	✗	✓	✓	Dobré
11.	✗	✗	2	0,1	0,3	✓	✗	✓	✓	Nevyhovujúce
12.	✗	✗	2	0,2	0,3	✓	✗	✓	✓	Dobré
13.	✗	✗	2	0,1	0,4	✓	✓	✓	✓	Veľmi zlé
14.	✗	✗	2	0,1	0,4	✗	✗	✓	✓	Veľmi zlé
15.	✗	✗	2	0,1	0,4	✗	✗	✗	✓	Veľmi zlé
16.	✗	✗	2	0,1	0,4	✓	✗	✓	✗	Veľmi zlé

Pri základnom nastavení (Pokus 1) je množstvo chýb pri klasifikácii vegetácie, ako aj budov. Najväčší problém môžeme vidieť pri klasifikovaní bodov, ktoré sú na komplexnejších budovách ako je Štátne divadlo, či kostoloch (Obr. 30). Ich špecifický, tvar viac pripomína tvar stromu ako budovy. Taktiež veľká nezhoda nastala pri naskenovaní stien budov, keďže strechy sú orientované viac horizontálne, steny budov boli priradené k stromom. Tie majú viac vertikálnych bodov, napr. peň.



Obr. 30 Aplikácia základných nastavení na výreze skúmanej oblasti. Kde oranžovou farbou sú zobrazené budovy, zelenou vegetácia, hnedou terén a sivou sú nešpecifikované body.

Pri zvýšenom parametri vyhľadávania bodov na tri metre došlo k zvýšenému počtu bodov priradených k vegetácii (Obr. 31). Väčšina týchto bodov v skutočnosti nepatrí k vegetácii, takže môžeme tieto nastavenia ohodnotiť ako nesprávne.




Obr. 31 Výsledok testovania parametrov pri 2. pokuse.

Pri treťom pokuse (Obr. 32), kde sme si zmenšili vyhľadávaciu oblasť na jeden meter, došlo k určitému zlepšeniu pri určení bodov budov, ale na druhej strane zhoršenému určení vegetácie pri okrajoch budov a menších stromov, čo sme určili za nežiaduce.

Pri ďalšom testovaní sme pokračovali podobne a môžeme zhodnotiť, že: 5., 8., 10., 11. pokus má podobný výsledok ako základnom nastavení. Pri 4., 6., 7., 9. pokuse sa zvýšil pomer bodov patriacich budovám v pozitívnom aj negatívnom ponímaní.


Nevhodné parametre boli pri pokusoch 13., 14., 15., 16., kde sa veľmi zvýšilo zastúpenie vegetácie.



Obr. 32 Výsledok testovania parametrov pri 3. pokuse.

Pri ďalšom testovaní sme pokračovali podobne a môžeme zhodnotiť, že: 5., 8., 10., 11. pokus má podobný výsledok ako základnom nastavení. Pri 4., 6., 7., 9. pokuse sa zvýšil pomer bodov patriacich budovám v pozitívnom aj negatívnom ponímaní. Nevhodné parametre boli pri pokusoch 13., 14., 15., 16., kde sa veľmi zvýšilo zastúpenie vegetácie.

Najväčším problémom pri hľadaní správnych parametrov bol fakt, že územie je veľmi členité a nie je možné vybrať vhodné parametre pre celú skúmanú oblasť. Parametre, ktoré sú vhodné pre istý úsek, nie sú vhodné pre iný. Ak zvýšime parameter *planarity* zvýši sa tým počet bodov, ktoré sú priradené k budovám. Pričom ak meníme *rughness* zmena je nepatrná. Pri nastavení veľkosti vyhľadávacej plochy, bola najvhodnejšia hodnota 2. Pretože pri nižších hodnotách boli stromy klasifikované ako budovy a naopak pri vyšších hodnotách boli budovy klasifikované ako stromy. Pri klasifikácii bol celkovo najväčší problém so stožiarimi, špecifickými budovami (divadlo, kostoly), fasádami väčších budov, okrajmi budov, komínmi a podobne (Obr. 33). Určenie najlepších parametrov je subjektívna záležitosť, my sme sa rozhodli pre pôvodné nastavenie, ktoré sme aplikovali v pokuse 1 (Tab. 3).



Obr. 33 Ukážky chybného klasifikovania vegetácie pri základných parametroch.

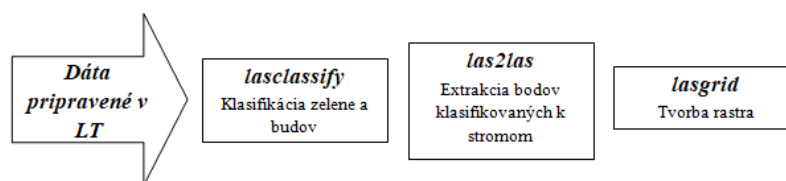
Po výbere najlepšej klasifikácie sme potrebovali dané výsledky porovnať s referenčnými dátami. Bolo treba vytvoriť *footprints* z LAS dát a to buď vo formáte shp alebo rastra. V našom prípade bola tvorba rastra oveľa spoľahlivejšia, keďže pri tvorbe formátu shp, dochádzalo k veľkým stratám presnosti.

Pre tvorbu rastra bolo potrebné vyselektovať stromy pomocou nástroja *las2las* a využiť nástroj *lasgrid*, ktorý vytvorí z LAS dát raster, v našom prípade v rozlíšení 0,33m (Tab. 4).

Tab. 4 Využité parametre v jednotlivých nástrojoch LasTools pri tvorbe rastra.

Nástroj	Parametre
<i>las2las</i>	-keep_classification 5
<i>lasgrid</i>	-step 0.333 -classification -use_bb

Následne sme tieto časti spojili tak ako to popisujeme v nasledujúcej podkapitole, teda pomocou *GrassGis* a *QGis*. Následne sme raster mohli využiť pri porovnávaní klasifikácií v *ArcMape*. Pracovný postup je načrtnutý v schéme (Obr. 34).



Obr. 34 Postup tvorby rastra stromovej vegetácie v LasTools.

3.2.2 Klasifikácia pomocou eCognition

V podkapitole 1.3.2 sme predstavili možné spôsoby segmentácie, klasifikácie pomocou softvéru eCognition. V tejto podkapitole predstavíme konkrétny postup, ktorý sme uplatnili pri klasifikovaní vegetácie.

Príprava dát

Prvým krokom bolo vytvorenie vrstiev, ktoré sme potrebovali pre klasifikáciu. Prvé tri vrstvy (RGB) sme získali z ortofotosnímkov, ktoré nám boli dodané firmou Photomap. Štvrtou vrstvou bola vrstva blízko infračerveného spektra (NIR), ktorú sme získali z CIR (Color Infrared) ortofotosnímkov, otvorením NIR spektra v ArcMape a následným vyexportovaním. Piatou vrstvou bola vrstva výšky povrchu krajiny ináč známa ako nDSM. Táto vrstva vznikla odčítaním DTM (Digitálny model reliéfu) a DSM (Digitálny model povrchu). Tvorbu DSM, DTM a nDSM si popíšeme bližšie.

DTM nám poskytol Ján Šašak, ktorý model DTM vytvoril v rámci projektu ESA. Využil pri tom softvér LasTools, kde konkrétne využil blast2dem. Pri tvorbe DTM sa využívajú LAS údaje očistené od šumu, pričom sa využíva iba mračná bodov, ktoré sú klasifikované ako zemský povrch. Tam, kde údaje nie sú (napr. pod budovami) je pomocou určitých algoritmov, vytvorená trojuholníková sieť.

DSM sme vytvárali pomocou blast2dem, resp. las2dem. Využili sme dáta, ktoré sme si vopred pripravili v LasTools (Podkapitola 3.2). Tu by sme chceli upozorniť na niekoľko problémov, ktoré môžu nastať pri vytváraní DSM. Dôležité je odstránenie šumu z dát (*lasnoise*), aby výsledky neboli skreslené. Ak sa pracuje s verziou LasTools bez licencie, je nutné pri vytváraní DTM a DSM rozdeliť LAS súbory na menšie dlaždice s menej než 1,5 mil. bodmi (*lastile*). Ináč bude dlaždica predelená hrubou čiarou, ktorá znehodnotí výstupy. My sme sa rozhodli pre veľkosť dlaždice 100 metrov. V *lasground* je potrebné klasifikovať pozemné body a následne si v *lasheight* vypočítať výšku nad povrchom a odstrániť body pod zemským povrchom. Pretože aj po

odstránení šumu, sa vyskytovali pod zemou nejaké body, ktoré neskôr skresľovali DTM aj DSM.

Isenburg (2014, 2016) opisuje niekoľko postupov tvorby DSM. Navrhol algoritmus, ktorý vytvára digitálny model povrchu bez zbytočných extrémnych hodnôt výšky (spike-free, pit-free). Po aplikovaní tohto algoritmu nám vznikli v objektoch diery, ktoré boli pre nás nežiaduce a preto sme využili iný postup, ktorý sme si prispôbili našim dátam.

Aplikovali sme funkciu *lasthin*, ktorá slúži na to aby sa predchádzalo možným dieram vo výslednom DSM modeli. Využili sme pri tom parametre uvedené v Tab. 5. Parameter *subcircle 0.1* má za úlohu zahusťovať body. Každému bodu priradí ďalších 8 bodov v diskretnom kruhu s polomerom 0,1. Spolu s parametrom *highest*, vytvorí súbor bodov, ktorý je vhodný pre tvorbu CHM alebo DSM.

Tab. 5 Využitie parametre v jednotlivých nástrojoch LasTools pri tvorbe DSM.

Nástroj	Parametre
<i>lasthin</i>	-subcircle 0.1 – step 0.16667 –highest .laz
<i>blast2dem</i>	-step 0.5 –elevation –use_tile_bb .tif


Následne sme využili novovzniknuté LAS súbory v *blast2dem* (Tab.). Tento krok je možné uskutočniť aj v *las2dem*, ale v našom prípade sa použitím nástroja *las2dem* vytvorili medzery vo výstupoch. Vzniklo nám veľké množstvo dlaždíc DSM, ktoré sme potrebovali čo najjednoduchšie spojiť.

V tomto prípade sme využili dve voľne dostupné programy GrassGis a QGIS, kde sme postupovali podľa postupu (Šašák, 2016). V GrassGis sme zadali príkaz *gdalbuildvrt output.vrt D:/Input/*.tif*

Tento príkaz nám vytvoril vrt súbor, ktorý sa uložil na lokálnom disku C. QGIS nám poslúžil na otvorenie vrt formátu a následne uloženie v *geotiff* formáte, ktorý podporuje aj ArcMap. Výsledkom bol jeden DSM tiff súbor.

V ArcMape sme využili *raster calculator*, kde sme vytvorili nDSM odčítaním DTM od DSM. Túto nDSM vrstvu bolo potrebné znovu uložiť v QGIS vo formáte geotiff a následne zmeniť koordinačný systém na pôvodný v ArcMape. Ináč nebolo možné načítať nDSM v eCognition.


V ďalšom kroku sme orezali RGB, NIR, nDSM snímku územia. Urobili sme to nasledovne: pomocou nástroja *DRAW* sme si vyznačili územie, s ktorým sme chceli pracovať v eCognition a pri exportovaní snímok sme vybrali možnosť *Selected Graphic*. Posledným krokom prípravy bolo spojenie jednotlivých vrstiev: *Windows/Image Analysis/Composite Bands* alebo inou možnosťou je otvorenie jednotlivých vrstiev v eCognition samostatne. Z dôvodu masívnych dát sme testovanie jednotlivých parametrov aplikovali prv na malom území. Po zistení správnych parametrov sme ich aplikovali na celé územie. Jednotlivé kroky prípravy nDSM sú zhrnuté v schéme na Obr. 35.



Obr. 35 Schéma tvorby nDSM.

Klasifikácia v eCognition

V eCognition sme v novom projekte vložili pripravené vrstvy RGB (Layer 1,2,3), NIR (Layer 4), nDSM (Layer 5) a aplikovali postup, ktorý uvedieme v tejto podkapitole (Obr. 36).



Obr. 36 Snímka v RGB spektre(v ľavo),s využitím NIR spektra (v strede), nDSM(v pravo).


V okne *process tree* sme pridali hlavný proces (*execute child processes*), ktorý bol nad všetkými procesmi a jeho vykonaním sa spustili všetky procesy pod ním. Pod ním sme následne vytvárali pod procesy (*Insert child*).

Prvým procesom bola *multiresolution segmentation*. Pri tejto segmentácii sme využili parametre, ktoré sú zobrazené na Obr. 37. Segmentácia je najkomplikovanejším procesom a zaberá veľa času, v našom prípade to bola jedna hodina.

Parameter	Value
Overwrite existing level	Yes
Level Settings	
Level Name	New Level
Segmentation Settings	
Image Layer weights	1, 1, 1, 2, 3
Thematic Layer usage	Scale parameter
Scale parameter	180
Composition of homogeneity criterion	
Shape	0.3
Compactness	0.5

Obr. 37 Parametre využité pri multiresolution segmentation.

Po segmentácii sme v *Class Hierarchy* vytvorili triedy, ktoré sme potrebovali pre našu klasifikáciu.



Obr. 38 Hierarchia využitá pri klasifikovaní.

Pri klasifikácii stromov sme potrebovali vypočítať NDVI, na to sme využili *Tools/Manage Customized features*. Tu sme si vytvorili NDVI pomocou nasledovného vzorca $([Mean\ Layer\ 4] - [Mean\ Layer\ 1]) / ([Mean\ Layer\ 1] + [Mean\ Layer\ 4])$.

Klasifikáciu sme uskutočnili nasledovnými *Assign class* procesmi/algoritmami. V prvom algoritme sme klasifikovali vegetáciu (stromy aj trávnatý porast) na základe NDVI (Obr. 39).

Klasifikované, Ostatné, Stromy, unclassified with NDVI >=	
Algorithm	
assign class	
Domain	
image object level	
Parameter	Value
Level	New Level
Class filter	Klasifikované, Ostatné, S...
Threshold condition	NDVI >= 0.2
Second condition	NDVI <= 0.7
Map	From Parent
Region	From Parent
Max. number of objects	all

Algorithm parameters	
Parameter	Value
Use class	Stromy

Obr. 39 Parametre pre klasifikáciu stromov.

V ďalšom procese sme klasifikovali ostatné objekty, taktiež pomocou NDVI (Obr. 40).

Klasifikované, Ostatné, Stromy, unclassified with NDVI < 0	
Algorithm	
assign class	
Domain	
image object level	
Parameter	Value
Level	New Level
Class filter	Klasifikované, Ostatné, unclassified
Threshold con...	NDVI < 0.2
Second condit...	---
Map	From Parent
Region	From Parent
Max. number ...	all

Algorithm parameters	
Parameter	Value
Use class	Ostatné

Obr. 40 Klasifikácia ostatných objektov.

Na rozdelenie vegetácie na stromy a nižšiu vegetáciu sme využili algoritmus, ktorý využil výšku objektov na ich rozdelenie (Obr. 41).

Stromy with Mean Layer 5 <= 2 at New Level: Trávnatý po	
Algorithm	
assign class	
Domain	
image object level	
Parameter	Value
Level	New Level
Class filter	Stromy
Threshold condition	Mean Layer 5 <= 2
Second condition	---
Map	From Parent
Region	From Parent
Max. number of objects	all

Algorithm parameters	
Parameter	Value
Use class	Trávnatý porast


Obr. 41 Parametre pre vytvorenie triedy Trávnatý porast.

V ďalšom kroku sme chceli spojiť jednotlivé segmenty tak aby každý segment reprezentoval jeden strom. Nedospeli sme k žiadnemu uspokojivému výsledku. Namiesto toho sme vykonali spojenie susediacich polygónov pomocou algoritmu *Merge region* (Obr. 42). Výsledkom bolo spojenie triedy stromov do niekoľkých skupín, ak šlo o samostatne stojací strom bol mu priradený samostatný polygón.




Obr. 42 Parametre využité pri spájaní triedy Stromy a ukážka ich aplikovania.

Celkový prehľad procesov, ktoré sme využili pri našej práci je na Obr. 43.




Obr. 43 Prehľad procesov využitých pri segmentácií a klasifikácií.

Po ukončení klasifikácie a generalizovaní kategórie Stromy sme mohli exportovať naše výsledky vo formáte shp a to tak, že v *Export/Export Results* sme vyexportovali kategóriu Stromy (Obr. 44).



Obr. 44 Export kategórie Stromy.

Postup práce v eCognition je zhrnutý v schéme na Obr. 45.




Obr. 45 Postup pri klasifikácii v eCognition.

Výsledok našej klasifikácie sme mohli porovnať s klasifikáciou, ktorú manuálne uskutočnil Ján Šašak.


3.2.3 Klasifikácia pomocou modulu CANUPO

Prvým krokom pri Canupo zásuvnom module bolo vytvorenie predlohy (Obr. 46), podľa ktorej sme klasifikovali zvyšok nášho skúmaného územia. Najpresnejším spôsobom je manuálne selektovanie vegetácie, čím väčšiu a reprezentatívnejšiu predlohu si vytvoríme, tým lepšie výsledky.




Obr. 46 Predloha (vľavo) využitá pri *tréningu* (vpravo).

Ako predlohu stromov sme využili už manuálne extrahované stromy a ako druhú kategóriu sme manuálne vyselektovali budovy (Obr. 46). Následne sme využili *tréning* s parametrami zobrazenými na Obr. 46. Po priebehu klasifikácie sme dostali výsledok, v ktorom sme mali 95 % presnosť správneho priradenia bodov ku kategóriám (Obr. 47). Považovali sme to za uspokojivý výsledok a pristúpili sme ku klasifikačnému procesu väčšieho územia.



Obr. 47 Grafické a štatistické vyjadrenie výsledku tréningového procesu.

Pri klasifikácii sme využili výsledky z tréningového procesu a rozhodli sme sa zriediť bodové pole pre rýchlejší výpočet (Obr. 48).



Obr. 48 Parametre využité pri klasifikácii.

3.2.4 Výpočet a vizualizácia metrik

Po klasifikácii stromovej vegetácie bolo možné vypočítať rôzne štatistiky. My sme sa zamerali, hlavne na výpočet a grafické znázornenie percentilov. Výpočet štatistík je možné uskutočniť v rôznych programoch, rôznymi spôsobmi. My sme si vybrali LasTools, konkrétne *lascanopy*.

Postupovali sme nasledovne, prv sme si vytýčili miesta, na ktorých sme chceli dané metriky vypočítať, kvôli tomu aby sme nemuseli počítať metriky pre každú jednu

dlaždicu. Tieto miesta sme si vytýčili formou polygónov, ktoré sme následne mohli otvoriť v *lascanopy*. Keďže sme mali nelicencovanú verziu LasTools, bolo potrebné vytýčiť si menšie územia, aby nedochádzalo k nepresnostiam. *Lascanopy* sme využili dvakrát, pre tvorbu grafickej časti, vo formáte asc a pre tvorbu konkrétnych hodnôt. Ako predlohu sme využili klasifikované dáta, ktorým sme v *lastile* nastavili parameter *replace z* (Tab. 6). Aby sme dostali výšky bodov stromov. Pre tvorbu grafickej časti sme využili *lascanopy* s parametrami zobrazenými v Tab. 7, pričom cieľom bolo dosiahnuť raster maximálnych výšok. Ako výstup sme dostali niekoľko rastrov, ktoré sme spojili v *GrasGis* a následne previedli na tif formát v *QGis*.

Tab. 6 Využitie parametre v jednotlivých nástrojoch LasTools pri tvorbe grafických výstupov.

Nástroj	Parametre
<i>lastile</i>	-replace z
<i>lascanopy</i>	-keep_classification5 -step 0.333 -max -use_tile_bb .asc

Následne bolo potrebné zistiť číselné štatistiky. V *lascanopy* sme využili klasifikované dáta, ktorým sme v *lastile* zmenili parameter *replace z* a zrušili prekryty (*no buffer*). V *lascanopy* sme otvorili jednotlivé polygóny v *overlays* a zadali sme parametre z Tab. 7, v ktorých sme chceli mať obsiahnuté hlavne percentil 1, 25, 50, 75, 99.

Tab. 7 Využitie parametre v jednotlivých nástrojoch LasTools pri tvorbe štatistík.

Nástroj	Parametre
<i>lastile</i>	-replace z -no buffer
<i>lascanopy</i>	-keep_classification 5 -step 0.33 -max -avg -p 1 25 50 75 99 .csv

Po vypočítaní štatistík sme pristúpili k samotnej grafickej ukážke. Postup, ktorý sme zvolili bol opäť komplikovaný, ale neprišli sme na iné riešenie. V prvom rade bolo potrebné raster, ktorý sme vytvorili v *lascanopy*, orezať polygónmi, pre ktoré sme si vypočítali metriky. Následne pre každý raster, ktorý sme dostali, bolo potrebné vypočítať štatistiky a to pomocou *calculate statistics*. To nám umožnilo vytvoriť si v *symbology* výškové triedy, ktoré súhlasili s percentilmi. Tak bolo možné vytvoriť mapové výstupy. Našimi vybranými oblasťami boli skupiny stromov v parku na Moyzesovej ulici, na Hlavnej ulici pri spievajúcej fontáne a v parku pri staničnom námestí.

4 Výsledky mapovania mestskej zelene

Na automatickú klasifikáciu sme použili tri softvéry, pričom jeden z nich nebolo možné aplikovať na celé územia a tak porovnať zhodu pri klasifikovaní. Preto sme pre porovnanie využili iba výsledky z LasTools a eCognition.

Prv než sme mohli porovnávať bolo potrebné klasifikované dáta pripraviť a následne vyhodnotiť. Postupov ako porovnávať údaje je určite viac. My sme si pre porovnávanie vybrali softvér ArcMap.

Našimi vstupnými dátami boli rastre, resp. polygóny (výstup z eCognition) vegetácie, ktoré sme vytvorili pomocou LasTools a eCognition. Rastre bolo potrebné previesť do vektoru (*Raster to Polygon*). Polygóny bolo potrebné spojiť do jedného polygónu (*merge*), aby bola práca jednoduchšia. Po spojení sme vytvorili masku, ktorá reprezentoval naše záujmové územie, ňou sme orezali polygón stromov (*clip*) a následne spojili tieto dve vrstvy pomocou *merge*. Pomocou funkcie *clip* sme orezali vrstvu maska, vrstvou stromov a špecifikovali si *ID* vrstvy masky a polygónov. Tento istý postup sme využili aj pri druhých dátach z (referenčných dát a dát z eCognition).


Potom sme využili funkciu *Polygon To Raster*, na vytvorenie rastra. Ak sme už mali rastre pripravené mohli sme pomocou *Raster Calculator* vypočítať graficky zhodu daných rastrov. A v atribútovej tabuľke sme si vypočítali veľkosť daných plôch vynásobením počtu pixlov, druhov mocninou veľkosti pixla v našom prípade 0.33 metra.

Výsledky klasifikácií sme porovnávali v softvéry ArcMap. Vytvorili sme mapové výstupy, ktoré poukazujú na nepresnosti a odlišnosti klasifikácie. Percentuálne sme zhodnotili zhodu, chybu navýšenia a chybu vynechania. Jednotlivé mapové výstupy sme porovnali s CIR snímku, pričom sme popísali jednotlivé chyby vzniknuté rozličnými spôsobmi klasifikácie.

4.1 Porovnanie výsledkom klasifikácie z LasTools a referenčných dát

Pri výsledku klasifikácie v LasTools je viditeľne vyššia nezhoda s referenčnými dátami (Obr. 49). Aj keď boli v LasTools použité tie isté dáta, ako pri referenčných dátach, čiže LAS dáta, LasTools nedokázal veľa krát správne rozlíšiť areáli stromovej vegetácie od ostatnej plochy. Z tohto dôvodu vznikla veľká chyba navýšenia, až 22,6% (Tab. 8). A naopak chyba vynechania bola nižšia iba 7%, Výsledky tejto klasifikácie

považujeme za neuspokojivé klasifikácie, aj keď zhoda s referenčnými dátami je až 70%.



Obr. 49 Porovnanie výsledkov automatickej klasifikácie stromov v LasTools a manuálnej klasifikácie.


Tab. 8 Porovnanie výsledkov klasifikácie softvéru LasTools s referenčnými dátami.

Dáta	Plocha (m ²)	Zhoda (%)	Chyba navýšenia (%)	Chyba vynechania (%)
Referenčné dáta	842857,9	100,0	0,0	0,0
Dáta z LasTools	1011892,2	70,4	22,6	7,0

Pri porovnávaní s referenčnými dátami, sme prišli na niekoľko typov problémov, ktoré mali za následok chybné klasifikovanie.

Chyby a odlišnosti:

V ojedinelých prípadoch LasTools klasifikoval stromovú vegetáciu správne oproti referenčným dátam (Obr. 50). Častým problémom bola zlá identifikácia malých strieň, altánkov (Obr. 50).



Obr. 50 Správne klasifikovaný strom v LasTools (vľavo), mylne klasifikovaná stieška (vpravo).

LasTools veľa krát klasifikoval okrem stromu aj okolie stromu ako stromovú vegetáciu (Obr. 51).


Stromy, ktoré prečnievali nad budovu neboli identifikované, kvôli vypnutej funkcii prečnievania stromov. Funkciu prečnievania stromov nad budovy sme vypli kvôli ešte väčším chybám vo výsledku (Obr. 51).

Nepriavidelné strechy boli taktiež klasifikované nesprávne, ako aj výčnelky na strechách a rovné steny na budovách (Obr. 51).




Obr. 51 Oblasť okolo stromu, klasifikovaná ako strom (vľavo), stromy nad strechou, ktoré LasTools neklasifikoval ako stromy (v strede), zlé klasifikované nepriavidelné strechy (vpravo).

Podobne ako pri eCognition, v LasTools boli stromy v tieni rozoznávajú lepšie, než pri referenčných dátach (Obr. 52). Veľkou chybou bolo nesprávne klasifikovanie stĺpov, vagónov (Obr. 52).



Obr. 52 Správne klasifikované stromy, ktoré boli zatienené budovou (vľavo), nesprávne klasifikované stĺpy a vagóny na železnici (vpravo).

Na Obr. 53 je možné vidieť nedostatky pri identifikácii stožiarov, žeriavov. Správne boli klasifikované medzery medzi stromami oproti referenčným dátam.



Obr. 53 Žeriavy, ktoré v čase skenovania boli na danom území, boli taktiež nesprávne klasifikované (vľavo), správna klasifikácia areálov medzi stromami v LasTools.

4.2 Porovnanie výsledkom klasifikácie z eCognition a referenčných dát


Výsledky klasifikácie v eCognition boli na prvý pohľad uspokojivé, ale pri porovnávaní s referenčnými dátami sme zistili nedostatky, pričom mnohé z nich nastali nastavením nevhodných parametrov (Obr. 54). Veľá odchýlok vzniklo kvôli tomu, že sa porovnávali výsledky z dvoch typov dát (LAS a snímky), kde všeobecne dochádza k istým odlišnostiam.

Zhoda manuálnej identifikácie a identifikácie v eCognition bola skoro 76% (Tab. 9). Vzniknutá chyba z navýšenia (areáli, ktoré boli klasifikované v eCognition ako stromová vegetácia, avšak nie pri referenčných dátach) dosiahla 13%. Chyba vynechania (areáli, ktoré boli klasifikované ako stromová vegetácia v referenčných

dátach, ale nie pomocou eCognition) bola 11%. Tieto chyby boli dosť vysoké a preto bolo potrebné zistiť ako k nim došlo, aby sa pri ďalších výskumoch neopakovali.

Tab. 9 Porovnanie výsledkov klasifikácie softvéru eCognition s referenčnými dátami.

Dáta	Plocha (m ²)	Zhoda (%)	Chyba navýšenia (%)	Chyba vynechania (%)
Referenčné dáta	842857,9	100,0	0,0	0,0
Dáta z eCognition	865461,6	75,7	13,2	11,0



Obr. 54 Porovnanie výsledkov automatickej klasifikácie stromov v eCognition a manuálnej klasifikácie.

Chyby a odlišnosti:


V eCognition bola nesprávne nastavená veľkosť segmentov, ktorá zapríčinila v niektorých prípadoch nesprávne zaradenie istých úsekov k stromom (Obr. 55).

Softvér eCognition priradil v niektorých prípadoch živé ploty k stromom (Obr. 55). Nastalo to kvôli tomu, že živý plot má podobnú hodnotu NDVI ako stromy a výšku väčšiu než 2 metre.




Obr. 55 Nesprávne identifikovaná plocha kvôli nesprávnej veľkosti segmentov (vľavo), živý plot klasifikovaný ako strom (vpravo).

Veľké, nesprávne identifikované plochy najčastejšie vznikali kvôli vegetácií na strechách a stenách budov (Obr. 56). Častá chyba vznikala, kvôli nesprávne nastaveným parametrom segmentácií. Pravdepodobne bola váha výšky (nDSM) menšia než sa vyžadovalo, resp. veľkosť segmentov bola príliš veľká.



Obr. 56 Chybne klasifikovaná vegetácia situovaná na vyvýšených objektoch (vľavo), mylne klasifikované stromy (vpravo).

V niektorých prípadoch môžeme konštatovať, že eCognition správne klasifikoval stromy, ktoré neboli manuálne klasifikované (Obr. 57). Niektoré stromy v eCognition neboli klasifikované ako stromy, kvôli tieneniu budov.



Obr. 58 Správne klasifikované stromy v eCognition (vpravo), neklasifikované stromy kvôli tieneniu (vľavo).

Tienenie budov negatívne vplývalo aj na zber dát LLS, pretože niektoré stromy za budovami boli klasifikované v eCognition, ale nie manuálne (Obr. 59). V mnohých prípadoch bol strom správne klasifikovaný. Chyba nastávala v okolí stromov, kde boli jednotlivé plochy nesprávne identifikované (Obr. 59). V prípade eCognition je to chybou zovšeobecneného segmentovania. V prípade manuálnej selekcií, ľudská chyba.



Obr. 59 Klasifikácia ovplyvnená tienením budov pri manuálnej klasifikácii (vľavo), chybné klasifikované územie, spôsobené ľudskou chybou (vpravo).

V referenčných dátach bola pravdepodobne za stromy klasifikovaná aj vegetácia nižšia než 2 m, pričom v eCognition sme za stromy považovali vegetáciu vyššiu než 2 m (Obr. 60). A preto sa v mnohých prípadoch stávalo, že síce bol správne klasifikovaný strom, ale neboli klasifikované časti nižšie než 2 m.

Porovnávaním vrstiev sme zistili, že dáta ktoré boli vytvárané ručne zahrňovali aj stromy, ktoré sú už odumreté, naopak eCognition tieto stromy vynecháva (Obr. 60). Tento jav by mohol pomôcť pri vyhľadávaní odumretých stromov v meste a následne ich nahrádzanie novými.


Celková chyba pri klasifikácii nastala tým, že v eCognition boli použité dáta z LLS ale aj letecké snímky. Snímky sú na určitých územiach skreslené viac (Obr. 60).



Obr. 60 Stromy nižšie než 2 m (vľavo), odumretý strom (v strede), skreslenie leteckých snímok.

4.3 Výsledky klasifikácie modulu CANUPO

Proces klasifikácie trval veľmi dlho aj napriek využitiu výkonného počítača. Vo výsledku klasifikácie boli viditeľné nepresnosti (Obr. 61). Najviac nepresností sa prejavilo pri klasifikovaní bytových budov a častí striech. Použili sme niekoľko možných nastavení pre zlepšenie výsledkov klasifikácie, využili sme iné predlohy (stromy a ostatné objekty), ale výsledky boli porovnateľné.




Obr. 61 Výsledky klasifikácie pomocou zásuvného modulu CANUPO.

Keďže do procesu klasifikácie vstupovalo veľa premenných, trval veľmi dlho, výsledky zaberali veľa miesta a pamäť RAM bola veľmi vyťažená, rozhodli sme sa, že nebude aplikovať túto klasifikáciu na celé územie. Ale po dosiahnutí výsledkov na skúšobnom území, môžeme skonštatovať, že klasifikácia pomocou tohto softvéru, by nebola najlepšia.

4.4 Porovnávanie s referenčnými bodmi

Pri porovnávaní s referenčnými dátami, ktoré boli manuálne identifikované, sme zistili, že je potrebné určiť si inú metódu porovnávania, pretože naše referenčné dáta neboli na 100% správne. Preto sme sa rozhodli použiť metódu, pri ktorej bolo náhodne rozmiestnených 500 bodov (*Create random points*) po celej záujmovej oblasti. Každému bodu sme priradili hodnotu strom alebo ostatná plocha, podľa ortofotomapy a nDSM. Týmto bodom sme následne priradili hodnotu z rastrov klasifikácií eCognition, LasTools, referenčných dát pomocou *Extract value to points*.

Ako výstup sme vytvorili mapu v ktorej sú zobrazené náhodne body, a geometrickými tvarmi sme zobrali chybné klasifikované body (Obr. 62). Potvrdilo sa, že najlepšia klasifikácia bodov bola pomocou referenčných dát s 98% úspešnosťou. O čosi horšie s 97% úspešnosťou klasifikoval softvér eCognition a najhoršie dopadol softvér LasTools, ktorý mal 95,2% úspešnosť. V niektorých prípadoch nebolo možné jednoznačne určiť, či sa v danom bode nachádza časť stromu alebo nie. Je to hlavne pri tých bodoch, ktoré boli na okraji koruny alebo v oblasti, kde bola nižšia vegetácia. Na mape sú to zväčša tie body, ktoré boli dvomi softvérmi klasifikované ako nesprávne. Nestalo sa však to, aby bol nejaký bod klasifikovaný nesprávne všetkými tromi spôsobmi, čo potvrdzuje správnosť vizuálneho klasifikovania bodov.




Obr. 62 Porovnanie ručne klasifikovaných bodov s ďalšími metódami klasifikácie.

4.5 Aplikovanie metrík

Z dát leteckého laserového skenovania je možné zistiť rôzne údaje o stromoch, ako napríklad výšku, veľkosť koruny a pod. V našom prípade sme sa zamerali na určenie výškových stupňov na základe percentilov, v troch skúšobných oblastiach mesta. Na Moyzesovej ulici, pri spievajúcej fontáne na Hlavnej ulici a v časti mestského parku. Úlohou bolo zistiť približne akých výšok dosahujú stromy v daných oblastiach, v akých výškach je najviac biomasy a naopak najmenej.


V oblasti Mestského parku výška stromov siaha až do 31,5 metra (Obr. 63). Ich priemerná výška je okolo 16 metrov. Najviac biomasy sa predpokladá vo výškach od 16tich do 28mich metrov.



Obr. 63 Výška stromov rozdelená podľa percentilov v oblasti Mestského parku pri stanici.

V oblasti Mojzesovho parku sú stromy viditeľne nižšie až o 10 metrov oproti stromom v Mestskom parku (Obr. 64). Aj priemerná výška je o 5 metrov nižšia, z čoho vyplýva, že najviac biomasy je sústredených vo výškach v rozmedzí nad 12 metrov do 18tich metrov. Môžeme si však všimnúť, že 1% percentil je až do 3,5 metra, čo svedčí o vyšších kmeňoch, resp. sa koruna začína rozvetvovať vyššie.

V oblasti spievajúcej fontány je priemerná výška stromov vyššia a teda najviac biomasy je pravdepodobne nad 13 do 23 metrov (Obr. 64).



Obr. 64 Výška stromov rozdelená podľa percentilov v oblasti Mojzesovho parku (vľavo) a okolí spievajúcej fontány v centre mesta (vpravo).

Týmito mapovými výstupmi sme chceli poukázať na využiteľnosť dát z LLS aj v oblasti určovania stavu stromovej vegetácie, to znamená, či sa jedná o nižší porast (mladá výsadba) alebo vyšší porast (staršie stromy) a iné.

5 Diskusia

Vo výsledkoch bola zhodnotená úspešnosť klasifikácie LasTools a eCognition porovnávaním s referenčnými dátami a referenčnými bodmi. Zistili sme, že softvér eCognition je oveľa spoľahlivejší pri klasifikácii stromovej zelene ako softvér LasTools. Avšak výsledky, ktoré sme dosiahli pri porovnávaní s referenčnými dátami nezodpovedajú skutočnosti. Pretože rozdiel zhody medzi softvérmí je iba 5%, ale pri vizuálnom pozorovaní sú chyby v LasTools markantnejšie a nedajú sa prehliadnuť. K stromovej vegetácii zahrnul rôzne antropogénne prvky, kvôli čomu bola aj chyba navýšenia výrazne vyššia (22,6%) a nedá sa táto klasifikácia pokladať za vyhovujúcu. Na druhej strane eCognition, mal zhodu s referenčnými dátami skoro 76%, ale chyby, ktoré vznikli navýšením (13%) či vynechaním (11%), neboli v niektorých prípadoch chyby, ale správne klasifikovaná zeleň. Z čoho vyplýva, že dáta, ktoré sme brali ako referenčné, neboli úplne správne a teda bolo potrebné využiť inú metódu na určenie úspešnosti klasifikácie. Z tohto dôvodu sme si vytvorili referenčné body, ktorým sme manuálne priradili hodnotu (strom, ostatná plocha) a porovnávali s výsledkami automatických klasifikácií. Odhalilo nám to prevažne tie isté chyby, ktoré sme určili pri porovnávaní s referenčnými dátami, ale v tomto prípade to bolo vyhodnotené aj percentami, pričom najlepšie dopadli referenčné dáta. To z časti potvrdilo správny výber referenčných dát. Samozrejme sú aj iné metódy porovnávania a spoľahlivejšie spôsoby určovania referenčných bodov, resp. dát, ale pre poukázanie na zaujímavé výsledky klasifikácií boli postačujúce aj tieto metódy.

Na potvrdenie týchto výsledkov sme hľadali publikácie, ktoré sa zaoberajú danými metódami klasifikácie a využívaním podobných softvérov ako sme využili my. Čo sa týka softvéru LasTools, nenašli sme konkrétne publikácie, ktoré by potvrdzovali naše výsledky, z tohto dôvodu nevieme usúdiť, či sme postupovali správne a nebola iná možnosť ako klasifikovať vegetáciu v mestskom prostredí pomocou softvéru LasTools. Omnoho viac bola využívaná metóda OBIA, ktorá je vo všeobecnosti veľmi presná. Článok Ma el al. (2017), potvrdzuje časté využívanie tejto metódy a poukazuje na aplikovanie tejto metódy na rôzny typ územia, s pomerne vysokou úspešnosťou klasifikácie, či už išlo o vegetáciu alebo iné plochy. Taktiež poukazuje na rastúci trend využívania tejto metódy, z čoho usudzujeme správnosť výberu metódy a výsledkov, ktoré sme dosiahli pomocou softvéru eCognition.

V práci bol využitý aj softvér Cloud Compare – Canupo, ktorého výsledky sme síce neaplikovali na celé územie, ale vidíme jeho potenciál na klasifikovanie zelene v mestskom prostredí. Ako už bolo vo výsledkoch zmienené, nie je publikovaných veľa prác, ktoré využívajú tento modul na klasifikovanie a pravdepodobne nie je žiadna práca o mapovaní v mestskom prostredí. V samotnom manuáli Canupo a v práci Brodu and Lague (2012) bolo uvedené, že táto metóda najlepšie funguje na prirodzených územiach. Čo sa týka hustoty bodov, resp. vzdialenosti bodov od seba, nebol veľký rozdiel medzi našimi dátami a dátami, ktoré využili Brodu and Lague (2012). Dôvod, prečo sa im podarilo lepšie klasifikovať vegetáciu, je pravdepodobne iné prostredie, čiže lepšia rozlišovacia schopnosť modulu medzi vegetáciou a terénom než medzi vegetáciou a niektorými budovami, resp. časťami budov.

Záver

Cieľom tejto práce bolo navrhnúť postup automatizovaného mapovania stromovej vegetácie, ktorého výsledky boli porovnávané s referenčnými dátami a referenčnými bodmi.

V práci boli využívané dáta z LLS či leteckej fotogrametrie. Na prípravu dát bolo nutné využiť rôzne softvéry, hlavne softvér LasTools, pričom bola využívaná jeho nelicencovaná verzia. Tento fakt spomaľoval a komplikoval celkový progres, preto jedným zo záverov je návrh na zakúpenie licencovanej verzie.

Najťažšou časťou tejto práce, nebola samotná klasifikácia stromovej vegetácie a porovnávanie výstupov s referenčnými dátami, ale pochopenie princípov fungovania jednotlivých softvérov, konkrétnych funkcií či nástrojov. Preto bol v tejto práci kladený dôraz aj na pochopenie fungovania jednotlivých nástrojov, aby sa prípadní čitatelia rýchlejšie zoznámili s problematikou a vedeli dané softvéry využiť.

Na klasifikáciu stromovej zelene sme si vybrali tri softvéry, pričom klasifikáciu pomocou zásuvného modulu Canupo v softvéri Cloud Compare sme nemohli aplikovať na celé skúmané územie, a to z dôvodu zdĺhavého procesu klasifikácie a vysokým výpočtovým nárokom. Ale na základe výsledkov, ktoré sme dosiahli na skúšobnom území, môžeme skonštatovať, že by tento softvér nemal najlepšie výsledky. Každopádne vidíme v tomto softvéri potenciál pre klasifikáciu stromovej zelene a preto by bolo vhodné ďalšie testovanie tohto softvéru.

Na klasifikovanie stromovej zelene na celom sledovanom území sme preto využili iba dva softvéry LasTools a eCognition a ich výsledky sme porovnali s referenčnými dátami. Pri eCognition išlo o 75,7 % zhodu a 70,4% pri LasTools. Tieto hodnoty nemôžeme považovať za úplne správne, hlavne z dôvodu nie úplne presných referenčných dát, ktoré vznikali prevažne manuálnou klasifikáciou. Čísla ale potvrdzujú, že softvér eCognition je vhodnejší na klasifikáciu stromovej zelene a vie efektívne klasifikovať stromovú zeleň, pričom využíva jednoduché princípy a to hodnotu NDVI a výšku objektov z nDSM.

Aby sme potvrdili správnosť referenčných dát a klasifikácií vo vybraných softvéroch. Rozhodli sme sa využiť metódu referenčných bodov. Výsledky tejto porovnávacjej metódy potvrdili správnosť našich referenčných dát (úspešnosť 98%),

úspešná bola aj klasifikácia pomocou eCognition (úspešnosť 97%), potvrdili sa aj o čosi horšie výsledky softvéru LasTools (úspešnosť 95,2%).

Výsledky porovnávaní s referenčnými dátami a bodmi sú úplne odlišné, a nezainteresovaný človek by tieto výsledky mohol pochopiť nesprávne. Je potrebné povedať, že percentuálna zhoda v prvom prípade bola robená vzhľadom na stromy, nie vzhľadom na celé územie. V druhom prípade, boli body rozmiestnené po celom území a teda porovnávanie bolo vzhľadom na celé územie, preto bola úspešnosť oveľa lepšia.

Dosiahnuté výsledky mohli byť lepšie, ak by sme mali viac skúseností s danými programami a ovládali aj pokročilejšie funkcie, ktoré dané programy ponúkajú. Taktiež lepším pochopením princípov klasifikovania, by sme mohli zvoliť lepšie parametre, ktoré sa viac hodia pre našu oblasť.

Posledným cieľom bolo poukázať na využiteľnosť LAS dát na vizualizáciu metrík, v našom prípade výšky stromov vo vybraných oblastiach. Samozrejme, aplikovanie na celé územie by bolo možné, ale bránil nám v tom nelicencovaný LasTools. Zistením však bolo, že stromy v jednotlivých častiach nie sú rovnako vysoké, čo vplýva aj na objem biomasy a teda aj na množstvo vyprodukovaného kyslíka, spotreby oxidu uhličitého, či zachytávania prachu a ostatných škodlivých látok. Preto môžeme skonštatovať, že údaj o percentuálnom podiele stromovej vegetácie (16,5%), nie je jediným podstatným údajom pre určenie množstva stromovej vegetácie na území mesta.

Môžeme teda tvrdiť, že stanovené ciele boli z veľkej časti splnené, pričom bolo poukázané na perspektívu využívania automatizovaných postupov na klasifikáciu stromovej zelene v mestskom prostredí.

Zoznam literatúry

- ABOELATA, A.A.A., 2017. Study the Vegetation as Urban Strategy to Mitigate Urban Heat Island in Mega City Cairo. In: *Procedia Environmental Sciences*, Vol. 37, 386-395.
- ACKERMANN, F., 1999. Airborne laser scanning — Present status and future expectations. In: *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 54, 64-67.
- ALONZO, M., BOOKHAGEN, B., MCFADDEN, J.P., SUN, A., ROBERTS, D.A., 2015. Mapping urban forest leaf area index with airborne lidar using penetration metrics and allometry. In: *Remote Sensing and Environment*, Vol. 162, 141-153.
- ALONZO, M., BOOKHAGEN, B., ROBERTS, D. A., 2014. Urban tree species mapping using hyperspectral and lidar data fusion. In: *Remote Sensing of Environment*, Vol. 148, 70-83.
- BAKUŁA, K., 2015. Multispectral airborne laser scanning – a new trend in the development of LiDAR technology. In: *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 27, 25-44.
- BAKUŁA, K., KUPIDURA, P., JEŁOWICKI, Ł., 2016. Testing of land cover classification from multispectral airborne laser scanning data. *Int. Archiv. Photogram. Rem. Sens. Spatial Inform. Sci. XLI-B7*, 161-169.
- BELWARD, A.S., SKØIEN, J.O., 2015. Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. In: *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 103, 115-128.
- BERALDIN, J.A., BLAIS, F., LOHR, U., 2010. *Airborne and Terrestrial Laser Scanning: Laser Scanning Technology 1*. Dunbeath: Whittles.
- BITTERER, L., 2005. *Základy fotogrametrie*. 3.vydanie. Žilina: Žilinská univerzita v Žiline.
- BLASCHKE, T., 2010. Object based image analysis for remote sensing. In: *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 65(1), 2-16.
- BLASCHKE, T., HAY, G.J., KELLY, M., LANG, S., HOFMANN, P., ADDINK, E., ET AL., 2014. Object-based image analysis – towards a new paradigm. In: *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 87, 180-191.
- BRODU, N., LAGUE, D., 2012. 3D terrestrial lidar data classification of complex natural scenes using a multi-scale dimensionality criterion: Applications in geomorphology. In: *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 68, 121-134.

-
- BURNETT, C. AND T. BLASCHKE., 2003. A multi-scale segmentation/object relationship modeling methodology for landscape analysis. In: *Ecological Modeling*, Vol. 168, 233-249.
- BUYADI, S.N.A., MOHD, W.M.N.M., MISNI, A., 2015. Vegetation's Role on Modifying Microclimate of Urban Resident. In: *Procedia – Social and Behavioral Sciences*, Vol. 202, 400-407.
- CARY AND ASSOCIATES, 2009. *The global market for airborne LiDAR systems and services*. Dostupné na: <http://www.caryandassociates.com>
- CHENGQI, CH., BIN, L., TING, M., 2003. The application of very high resolution satellite image in urban vegetation cover investigation: A case study of Xiamen City. In: *Journal of Geographical Sciences*, Vol. 13, 265-270.
- COOMES, D.A, DALPONTE, M., JUCKER, T., ASNER, G.P., BANIN, L.F., ET AL., 2017. Area-based vs tree-centric approaches to mapping forest carbon in Southeast Asian forests from airborne laser scanning data. In: *Remote Sensing of Environment*, Vol . 194, 77-88.
- COX, T. C. D., HUDSON L.H., SHANAHAN, F.D., FULLER, A.R., GASTON, J.K., 2017. The rarity of direct experiences of nature in an urban population. In: *Landscape and Urban Planning*, Vol. 160, 79-84.
- ESCOBEDO, F. J., & NOWAK, D. J., 2009. Spatial heterogeneity and air pollution removal by an urban forest. In: *Landscape and Urban Planning*, Vol. 90, 102-110.
- FRAŠTIA, M., 2017. Vybrané aplikácie fotogrametrie v oblasti merania posunov: habilitačná práca. Bratislava: Slovenská technická univerzita.
- GAITINI, N., BURUD, I., THIIS, T., SANTAMOURIS, M., 2017. High-resolution spectral mapping of urban thermal properties with Unmanned Aerial Vehicles. In: *Building and Environment*, Vol. 121, 215-224.
- GAVAZZI, G.M., MADRICARDO, F., JANOWSKI, L., KRUSS, A., BLONDEL, P., SIGOVINI, M., FOGLINI, F., 2016. Evaluation of seabed mapping methods for fine-scale classification of extremely shallow benthic habitats – application to the Venice Lagoon, Italy. In: *Estuarine Coast. Shelf Sci.* 170, 45-60.
- GERÇEK, D. GÜVEN, İ.T. & OKTAY, İ.Ç, 2016. Analysis of the intra-city variation of urban heat island and its relation to land surface/cover parameters. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (ISPRS Archives)*, VI, WG VI/4, 123-129.
- GKATSOPOULOS, P., 2017. A Methodology for Calculating Cooling from Vegetation Evapotranspiration for Use in Urban Space Microclimate Simulations. In: *Procedia Environmental Sciences*, Vol. 38, 477-484.
-

-
- GUO,L., CHEHATA, N., MALLET,C., BOUKIR,S., 2011. Relevance of airborne LiDAR and multispectral image data for urban scene classification using random forests. *In: Journal of Photogrammetry and Remote Sensing*, Vol. 66, 56-66.
- HALL, J. M., HANDLEY, J. F., & ENNOS, A. R., 2012. The Potential of Tree Planting to Climate-proof High Density Residential areas in Manchester,UK. *In: Landscape and Urban Planning*, 104(3-4), 410–417.
- HANZL, V., 2006. *Fotogrammetrie: Teoretické základy fotogrametrie*. Brno: Vysoké učení technické v Brně.
- HAY, G.J., BLASCHKE, T., 2010. Special issue: geographic object-based image analysis (GEOBIA). *In: ISPRS Journal of Photogrammetry and Remote Sensing*, Vol .76, 121-122.
- HODSON, C.B., SANDER, H.A., 2017. Green urban landscapes and school-level academic performance. *In: Landscape and Urban Planing*, Vol. 160, 16-27.
- HOFIERKA, J., GALLAY, M., KAŇUK, J., ŠUPINSKÝ, J., ŠAŠAK, J., 2017. High-resolution urban greenery mapping for micro-climate modelling based on 3D city models. *In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (ISPRS Archives)*, XLII-4/W7, 7-12.
- HOFIERKA, J., KAŇUK, J., GALLAY, M., 2014. *Geoinformatika*. Vysokoškolská učebnica. Košice: Univerzita Pavla Jozefa Šafárika v Košiciach. ISBN 978-80-8152-178-2.
- HUANG, X., ZHANG L., GONG, W., 2011. Information fusion of aerial images and LiDAR data in urban areas: Vector-stacking, re-classification and post-processing approaches. *In: International Journal of Remote Sensing*, Vol. 32, 69-84.
- ISENBURG, M., 2013a. Tutorial quality checking. Blog rapidlasso.com, Dostupné na: <https://rapidlasso.com/2013/04/20/tutorial-quality-checking/>
- ISENBURG, M., 2013b. Tutorial lidar preparation. Blog rapidlasso.com, Dostupné na: <https://rapidlasso.com/2013/10/13/tutorial-lidar-preparation/>
- ISENBURG, M., 2013c. Tutorial derivate production. Blog rapidlasso.com, Dostupné na: <https://rapidlasso.com/2013/10/20/tutorial-derivative-production/>
- ISENBURG, M., 2016. Generating spike free digital surface models from lidar. Blog rapidlasso.com, Dostupné na: <https://rapidlasso.com/2016/02/03/generating-spike-free-digital-surface-models-from-lidar/>
-

-
- ISENBURG, M., 2016. Rasterizing perfect canopy height models from lidar. Blog rapidlasso.com, Dostupné na: <https://rapidlasso.com/2014/11/04/rasterizing-perfect-canopy-height-models-from-lidar/>
- KATALINOVÁ, K., 2015. *Použitelnosť archívnych snímkových materiálov pre identifikáciu zmien v krajine na príklade katastrálneho územia Kremnica*: diplomová práca. Zvolen: Technická univerzita vo Zvolene.
- KHATAMI, R., MOUNTRAKIS, G., STEHMAN, S.V., 2016. A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: general guidelines for practitioners and future research. *In: Remote Sensing Environment*, Vol. 177, 89-100.
- KOPECKÁ, M., SZATMÁRI, D., ROSINA, K., 2017. Analysis of Urban Green Spaces Based on Sentinel-2A: Case Studies from Slovakia. *In: Land*, Vol 6(2), 25.
- LEHMANN, J.R.K., NIEBERDING, F., PRINZ, T., KNOTH C., 2015. Analysis of unmanned aerial system-based CIR images in forestry - a new perspective to monitor pest infestation levels. *In: Forests*, Vol. 6, 594-612.
- LEIGH, H.W., MAGRUDER, L.A., 2016. Using dual-wavelength, full-waveform airborne lidar for surface classification and vegetation characterization. *In: J. Appl. Rem.Sens.* 10 (4), 045001.
- LIU, L., COOPS, N.C., AVEN, N.W., PANG, Y., 2017. Mapping urban tree species using integrated airborne hyperspectral and LiDAR remote sensing data. *In: Remote Sensing of Environment*, Vol. 200, 170-182.
- MA, L., LI, M., MA, X., CHENG, L., DU, P., LIU, Y., 2017. A review of supervised object-based land-cover image classification. *In: ISPRS Journal of Photogrammetry and Remote Sensing*, Vol . 130, 277-293.
- MCGEE, J. A., DAY, S. D., WYNNE, R. H., & WHITE, M. B., 2012. Using geospatial tools to assess the urban tree canopy: Decision support for local governments. *In: Journal of Forestry*, 110(5), 275-286.
- MYINT, S.W., BRAZEL, A., OKIN, G., & BUYANTUYEV, A., 2010. Combined effects of impervious surface and vegetation cover on air temperature variations in a rapidly expanding desert city. *In: GIScience & Remote Sensing*, Vol. 47, 301-320.
- NOWAK, D., CRANE, D., STEVENS, J., HOEHN, R., WALTON, J., & BOND, J., 2008. A ground-based method of assessing urban forest structure and ecosystem services. *In: Arboriculture & Urban Forestry*, Vol. 34(6), 347-358.
- ONAČILLOVÁ, K., GALLAY, M., 2018. Spatio-temporal analysis of surface urban heat island based on LANDSAT ETM+ and OLI/TIRS imagery in the city of
-

-
- Košice, Slovakia. In: *Carpathian Journal of Earth and Environmental Sciences*, 13(2), 395 - 408.
- PONTIUS, J., HANAVAN R.P., HALLETT, R.A., COOK, B.D., CORP, L.A., 2017. High spatial resolution spectral unmixing for mapping ash species across a complex urban environment. In: *Remote Sensing of Environment*, Vol. 199, 360-369.
- SANKEY, T., DONAGER, J., MCVAY, J., SANKEY, J.B., 2017. UAV lidar and hyperspectral fusion for forest monitoring in the southwestern USA. In: *Remote Sensing of Environment*, Vol. 195, 30-43.
- SMREČEK, R., 2013. Inventarizácia mestskej zelene z dát leteckého laserového skenovania. In: *Zborník z konferencie GIS Ostrava, 21. -23.1.2013*. Ostrava: VŠB -Technická univerzita Ostrava, p. 1-6.
- ŠAŠAK, J., 2016. Spracovanie údajov leteckého laserového skenovania geoinformatickými open - source nástrojmi: diplomová práca. Košice: Univerzita Pavla Jozefa Šafárika v Košiciach.
- ŠTATISTICKÝ ÚRAD SR, databáza DATAcube, 2011: Výmera územia, využitie pôdy. Bratislava (ŠÚSR). Dostupné na: <http://datacube.statistics.sk>
- TENCER, T., 2012. *Pořizování 3D dat: Študijné materiály*. Brno: Masaryková Univerzita. Dostupné na: https://is.muni.cz/el/1421/podzim2012/AEA_73/Tencer_-_LiDAR_-_Porizovani_3D_dat.pdf
- TIGGES, J., LAKES, T., HOSTERT, P., 2013. Urban vegetation classification: Benefits of multitemporal RapidEye satellite data. In: *Remote Sensing of Environment*, Vol. 136, 66-75.
- TRIMBLE GERMANY GMBH, 2014. eCognition® Developer: User Guide. Mníchov: Trimble Documentation.
- UN-HABITAT , 2011. Cities and climate change: *Global report on human settlements*. London: Earthscan Ltd.
- VOOGT, J.A. & OKE, T.R., 2003. Thermal remote sensing of urban climates. In: *Remote Sensing of Environment*. 86 (3), 370-384.
- VÝBERČI, D., LABUDOVÁ, L., EŠTÓKOVÁ, M., FAŠKO, P. & TRIZNA, M., 2017. Human mortality impacts of the 2015 summer heat spells in Slovakia. In: *Theoretical and Applied Climatology*, 1-12.
- 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 Ann. Photogram. Rem. Sens. Spatial Inform. Sci. II-3/W5*, 113-119.
- YAN, W.Y., SHAKER, A., EL-ASHMAWY, N., 2015. Urban land cover classification using airborne LiDAR data: A review. *In: Remote Sensing of Environment*, Vol. 158, 295-310.
- ZOU, X., ZHAO, G., LI, J., YANG, Y., FANG, Y., 2016. 3D land cover classification based on multispectral lidar point clouds. *Int. Archiv. Photogram. Rem. Sens. Spatial Inform. Sci. XLI-B1*, 741-747.