

OBJEKTOVO ORIENTOVANÁ KLASIFIKÁCIA DREVINOVÉHO ZLOŽENIA NA DIGITÁLNYCH LETECKÝCH SNÍMKACH ZOSUVNÉHO ÚZEMIA

OBJECT-ORIENTED CLASSIFICATION OF TREE SPECIES IN DIGITAL AERIAL PHOTOS OF LANDSLIDE AREA

MIROSLAV KARDOŠ¹⁾ - ALŽBETA MEDVEĐOVÁ²⁾ - ŠIMON SUPEK³⁾ - MARTINA ŠKODOVÁ²⁾

¹⁾ *Technická univerzita vo Zvolene, Lesnícka fakulta, Zvolen*

²⁾ *Univerzita Mateja Bela, Fakulta prírodných vied, Banská Bystrica*

³⁾ *Česká zemědělská univerzita v Praze, Fakulta životního prostředí, Praha*

ABSTRACT

The aim of the presented paper was to perform an automatic object-oriented classification of tree species composition on the landslide area near Lubietová (Central Slovakia) using color infrared orthophotos and true color orthophotos with a spatial resolution of 0.2 m, 0.5 m and 1 m. Achieved results then could be used to evaluate the effect of vegetation on slope stability. Species classification was performed using Definiens Professional software. The best classification result of the CIR images was achieved using segmentation of the scale 40 and 0.2 m pixel size, with an overall accuracy of 53%. *Salix alba*, *Salix fragilis* and *Pinus* were best classified according to the KHAT index and classification accuracy. Using higher scales of segmentation, classification accuracy reaches smaller values. The best classification accuracy of 44% was achieved in the orthophoto with 0.5 m pixel at the scale of segmentation 20. The overall classification accuracy of the image with 1 m pixel size reached the lowest values. The best classification result of RGB images is 50% at the segmentation scale 30 and 0.5 m pixel size. The highest classification accuracy of almost 84% achieved in this case the *Salix* class, but at the 0.2 m pixel size and the scale of segmentation 20. The combination of standard nearest neighbour classifier and membership functions in the CIR orthophoto with 0.2 m pixel size has improved the overall classification accuracy from 53 to 56%. In the *Salix alba* class, the classification accuracy increased by 53% and in the *Salix fragilis* class almost by 20%. The classification of a separate class *Pinus* in the CIR image with 0.2 m pixel size using membership functions reached almost 84% accuracy. In sum we can evaluate the classification results as the average, and in some cases very good.

Klíčové slová: objektovo orientovaná klasifikácia, digitálne letecké snímky, drevinové zloženie, ortofotosnímka, funkcie príslušnosti, správnosť klasifikácie, KHAT index

Key words: object-oriented classification, digital aerial photos, tree species composition, orthophoto, membership functions, classification accuracy, KHAT index

ÚVOD

Trend využívania digitálnej fotogrametrie a digitálnych leteckých meračských snímok v lesníckej praxi smeruje k širšiemu využitiu informácií zachytených na meračskej snímke. Množstvo informácií značne stúpa použitím materiálov citlivých na viac spektrálnych pásiem. Získavanie informácií o lesných ekosystémoch prostredníctvom leteckých snímok, resp. záznamov diaľkového prieskumu Zeme (DPZ), má v lesníckej praxi a výskume bohatú tradíciu. Vzhľadom na špecifika lesníckeho mapovania sú dnes najpoužívanejšie fotogrametrické metódy s podporou fotointerpretácie. Dnes sa už takmer 90 % mapovacích prác v rámci hospodárskej úpravy lesov (HÚL) vykonáva fotogrametrickou cestou (napr. HILDEBRANDT 1996; ŠANDORFI, CHUDÝ 2004; KARDOŠ, CHUDÝ 2005; ŽÍHLAVNÍK et al. 2005; HALVOŇ 2007). Ďalej sa predovšetkým jedná o klasifikáciu zdravotného stavu a drevinového zloženia lesov zo záznamov kozmického DPZ (BUCHA et al. 2000, 2010), navrhovanie regionálneho informačného systému eko-

logického a produkčného stavu lesa (BARKA 2009), resp. klasifikáciu lesa s použitím analógových čiernobielych leteckých snímok v mierke 1 : 23 000 (HALOUNOVÁ 2004). Klasifikácii krajiny pokrývky sa tiež venovali STANKOVÁ a ČERŇANSKÝ (2004) v oblasti Chopok – Jasná, ktorí za týmto účelom využili objektovo orientovaný prístup. HÁJEK (2008) opisuje automatizovanú klasifikáciu lesných štruktúr s využitím strednoformátových CIR snímok a družicových záznamov s vysokým rozlíšením súčasne s doplňujúcimi GIS vrstvami. WASER et al. (2011) opisujú problematiku poloautomatizovanej klasifikácie drevinového zloženia v rozličných lesných ekosystémoch s využitím geometrických a spektrálnych charakteristík odvodených zo snímok získanými digitálnymi kamerami ADS40 a RC30 s rozlíšením 0.25 m a 0.5 m na dvoch výskumných plochách. Celková správnosť klasifikácie na výskumnej ploche č. 1 s geometrickým rozlíšením snímok 0.25 m pre 7 druhov drevín dosiahla hodnotu 76%. Na výskumnej ploche č. 2 s geometrickým rozlíšením snímok 0.5 m pre 4 dreviny dosiahli celkovú správnosť 84%.

Samostatnú aplikáciu pri klasifikácii materiálov DPZ tvoria metódy na zisťovanie, resp. odhadovanie stromových a porastových charakteristík. Uvedenou problematikou s využitím analógových farebných infračervených snímok sa na Slovensku zaoberala napr. MAJLINGOVÁ (2006). TUOMINEN a HAAKANA (2005) opisujú využitie záznamov DPZ a leteckých snímok v mierke 1 : 60 000 pre odhadovanie porastových charakteristík a inventarizáciu lesa.

V lesníctve majú veľký význam aj aplikácie týkajúce sa klasifikácie vegetačného krytu až po úroveň určenia druhového zloženia drevín v porastoch. Pre tento účel čoraz častejšie nachádza uplatnenie objektovo-orientovaný prístup klasifikácie, založený na segmentácii obrazu, ktorý pre klasifikáciu okrem spektrálnych charakteristík využíva tiež charakteristiky textúry a rôzne fyzikálne, resp. rozmerové charakteristiky objektov na snímke (ŠITKO, SCHEER 2009). Dáta s vysokým priestorovým rozlíšením poskytujú množstvo kvantitatívnych, ale najmä kvalitatívnych informácií, ktorých obsah nemožno naplno využiť pri ich klasifikácii na základe pixelovo orientovaného prístupu. Objektovo orientovaný prístup ponúka možnosť do určitej miery automatizovať inventarizáciu lesov, čím by sa znížila časť nákladov. Prístup založený na identifikácii individuálnych korún stromov ponúka možnosť zistiť hlavné taxačné charakteristiky stromu (výška, druh, priemer koruny), údaje o strednej výške, objeme kmeňa, charakteristikách jednotlivých druhov stromov (HYYPÄ et al. 2005).

Hlavnou výhodou objektovo orientovaného prístupu v porovnaní s tradičným postupom klasifikácie pixelov je možnosť komplexnejšieho opisu stavu porastov, a to pomocou prepojenia spektrálnych, štruktúrálnych a relačných charakteristík. Využitím algoritmu klasifikácie na homogénne porastové textúry (objekty) je možné posúdiť ich zdravotný stav, prípadne stupeň rozpadu alebo zaznamenať procesy ich obnovy. Týmto spôsobom je možné výrazne zracionalizovať časovo a fyzicky náročné terénne práce (BUCHA et al. 2010). Na rozdiel od pixelovo orientovanej klasifikácie, kde jednotlivé pixele sú priradené do klasifikačných tried samostatne na základe ich digitálnych hodnôt (DN), sú pri objektovo orientovanej klasifikácii predmetom klasifikácie jednotlivé segmenty (objekty) predstavujúce pixele zlúčené na základe určitých parametrov (NEUBERT 2005; HAY et al. 2005). Objekty môžu byť popísané na základe ich tvaru, textúry, topológie, heterogenity a priestorového vzťahu s ostatnými objektmi (GAO 2009).

Je pravdepodobné, že dnes dostupné metódy nie je možné použiť pre všetky typy lesov. Štúdie rôznych segmentačných metód použitých na odlišných typoch lesov sú dôležité pre objasnenie vhodnosti použitia určitej metódy na špecifický typ lesa. Toto poznanie môže slúžiť na vybudovanie expertného systému, ktorý by bolo možné použiť pri extrakcii individuálnych korún stromov v akomkoľvek type lesa (BECHTEL 2007).

Napriek tomu stále zotrúva problém automatizovanej klasifikácie objektov na záznamoch s vysokou priestorovou rozlišovacou schopnosťou, kvôli ich vysokej spektrálnej variabilite (napr. MILLETTE, HYWARD 2005; YU et al. 2006; BOHLIN et al. 2007; CHANG et al. 2008; WANG et al. 2008; DARVISHSEFAT et al. 2011). Isté zlepšenie segmentácie ponúka TIEDE et al. (2006) vo svojej práci, kde ako prvé vo vyššej úrovni klasifikoval typy porastov.

Zahrnutím špecifických geodát do procesu klasifikácie je tiež možné zlepšiť výsledky klasifikácie (napr. FÖRSTER, KLEINSCHMIT 2008). Použitím lokálnych maxím možno dosiahnuť efektívnejšiu extrakciu korún (TIEDE et al. 2006; MAJLINGOVÁ 2007).

DARVISHSEFAT et al. (2011) pre klasifikáciu drevinového zloženia v Iráne používali letecké snímky z kamery UltraCam s vyšším geometrickým rozlíšením. Pri klasifikácii 5 druhov drevín dosiahli celkovú správnosť až 79 %, pričom však treba vziať do úvahy, že klasifikovali málo heterogénne porasty.

V našom prípade sme sa zamerali práve na využitie záznamov DPZ s vysokou rozlišovacou schopnosťou. Jednalo sa o digitálne letecké meračské snímky v syntéze v prirodzených farbách a infračervenom farebnom vyjadrení s geometrickým rozlíšením 20 cm na zemskom povrchu. Tieto materiály sú v súčasnosti štandardne využívané pri vyhotovovaní tematických lesníckych máp a pri reambulácii základnej lesníckej mapy, čím je umožnená aj ich väčšia dostupnosť pre iné oblasti lesníckeho výskumu, ako napr. klasifikácia drevinového zloženia. Cieľom bolo preskúmať možnosti využitia takýchto materiálov pre automatizovanú klasifikáciu drevinového zloženia pomocou vzorových objektov uložených v tzv. TTA (Training or Test Areas) maske s využitím programového vybavenia Definiens v porastoch s bohatou drevinovou skladbou.

Klasifikácia nie je kompletná dovtedy, pokiaľ nie je vyhodnotená jej správnosť (LILLESAND et al. 2008). Prvoradým predpokladom v celom procese hodnotenia správnosti je skutočnosť, že tabuľka správnosti klasifikácie (kontingenčná tabuľka) je reprezentatívna pre celú mapovanú oblasť. Správnosť klasifikácie udáva jej pravdivosť v porovnaní so skutočným stavom. Jedná sa v podstate o určenie percenta správne klasifikovaných obrazových prvkov z ich celkového počtu v príslušnej klasifikačnej triede. KHAT index (kappa index), ktorý predstavuje štatistickú mieru zhody medzi referenčnými a klasifikovanými údajmi vylučujúc zhodu z titulu náhody, vychádza z predpokladu, že i pri náhodnej klasifikácii môže byť časť výsledkov správna. Pohybuje sa v rozsahu od 0 do 1 a vyjadruje odpovedajúce obmedzenie chyby získanej klasifikátorom, ktorá bola porovnávaná s chybou náhodného klasifikátora (ŽÍHLAVNÍK, SCHEER 2001).

MATERIÁL A METODIKA

Charakteristika skúmaného územia

Klasifikáciu drevinového zloženia sme realizovali na území tzv. katastrálneho zosuvu v katastri obce Ľubietová (okres Banská Bystrica, Slovensko) (obr. 1). Skúmané územie leží na hranici oblastí Slovenské stredohorie a Slovenské rudohorie (MAZÚR, LUKNIŠ 1980). Predmetom štúdia sú ľavobrežné severovýchodne orientované svahy toku Hutná (ľavostranného prítoku Hrona). Teleso samotného zosuvu sa nachádza na hranici geomorfologických celkov Zvolenská kotlina a Veporské vrchy v centrálnej časti bazénu a je súčasťou zníženej eróznio-tektonického pôvodu v podcelku Povraznícka brázda (MAZÚR, LUKNIŠ 1980). Prúdový zosuv (o výmere 32 ha) nepravidelného tvaru dosiahol dĺžku cca 1300 m, maximálna šírka zosuvu bola 400 m, priemerný sklon 6–7°. Prevýšenie odľučnej steny telesa nad akumuláciou jeho čela je 170 m (440–610 m n. m.). Hrúbka zosuvného delúvia sa odhaduje na 6–8 m v čele zosuvu, 15–20 m v strednej časti a až 30 m v odľučnej oblasti zosuvu.

Od poslednej reaktívácie zosuvu v roku 1977 a následnej sanácie svahu je územie zosuvu hospodársky nevyužívané a sukcesne zarastá. Predpokladáme, že vegetácia (najmä dreviny) môžu v predmetnom zosuvnom území zohrávať istú stabilizačnú úlohu. Pre hodnotenie stabilizačnej funkcie je nevyhnutné poznať skladbu, plošné zastúpenie jednotlivých drevín, prípadne výšku porastu. Drevinové zloženie je veľmi pestré, výškovo, priestorovo a druhovo veľmi diverzifikované. Terénnym prieskumom lokality sa zistilo nasledovné zastúpenie drevín: javor poľný (*Acer campestre*), hrab obyčajný (*Carpinus betulus*), čerešňa vtáčia (*Cerasus avium*), lieska obyčajná (*Corylus avellana*), smrek obyčajný (*Picea abies*), borovica lesná (*Pinus silvestris*), dub letný (*Quercus robur*), dub zimný (*Quercus petraea*), agát biely (*Robinia pseudoacacia*), vrbka biela (*Salix alba*), vrbka krehká (*Salix fragilis*), vrbka rakyta (*Salix caprea*), lipa malolistá (*Tilia cordata*), topol osika (*Populus tremula*), jablňoň (*Malus*), roztrúsene borievka obyčajná (*Juniperus communis*) a zmiešané kroviny.

Automatizovanú klasifikáciu drevinového zloženia sme vykonali na infračervených ortofotosnímках (CIR) a ortofotosnímках v pravých farbách (RGB). Základom pre vytvorenie ortofotosnímkov boli digitálne letecké meračské snímky získané kamerou UltraCamX s priestorovým rozlíšením (ďalej len rozlíšenie) 0.2 m. Z nich boli vyhotovené ortofotosnímky s rozlíšením 0.2, 0.5 a 1 m, pre posúdenie vplyvu rozlíšenia na správnosť klasifikácie. Pre výpočet orientácie leteckých snímkov a vytvorenie ortofotomáp s požadovaným rozlíšením sme použili fotogrametrický systém od spoločnosti Inpho. Pre výpočet prvkov vonkajšej orientácie jednotlivých snímkov sme využili modul MATCH-AT a pre digitálne diferenciálne prekresľovanie modul OrthoMaster a OrthoVista. Ortofotosnímky s rôznym geometrickým rozlíšením sme vytvorili procesom prerastovania s využitím bikubickej metódy interpolácie v programe OrthoMaster. Vektorizácia vzorov na základe terénnej identifikácie prebiehala v 3D prostredí Summit Evolution. Na prípravu TTA masky slúžil program ArcGis.

Zber terénnych údajov – vizuálna interpretácia

Vizuálna interpretácia sa vykonala na základe podkladov terénneho prieskumu. Druhy, ktoré boli jednoznačne určené v teréne, slúžili ako vzory pre určenie druhov drevín pri samotnej vizuálnej interpretácii na stereomodeli. Pre záujmové územie je charakteristická výrazná heterogénnosť porastu: rozmanitá druhová skladba, výška a vek drevín. Dreviny sú miestami silne zapojené, miestami plošne roztrúsené. Z CIR ortofotosnímkov bolo jednoduché vizuálne určiť *Pinus silvestris* a *Picea abies* vo vyšších vekových stupňoch. Najväčší problém predstavovali listnaté dreviny. Dobré sa dali rozoznať *Tilia cordata*, *Quercus petraea*, *Cerasus avium*, *Salix alba* a *Salix fragilis*, hoci *Salix alba* pri silne osvetlených korunách vykazovala podobné spektrálne vlastnosti ako trávny porast. *Carpinus betulus*, *Populus tremula* a *Corylus avellana* bolo možné identifikovať len na základe terénneho prieskumu. Údaje potrebné pre vytvorenie vzorovej masky na riadenú klasifikáciu boli získané terénnou metódou interpretácie, ktorá spočívala v porovnávaní snímkov so skutočnosťou s cieľom presne identifikovať jednotlivé objekty (dreviny) podľa interpretačných prvkov. Na základe terénnej identifikácie bola vytvorená vzorová maska drevín (obr. 2).

Segmentácia obrazu

Pri objektovo orientovanej klasifikácii predstavuje segmentácia základný kameň pre všetky nasledujúce kroky. Jej cieľom bola tvorba objektov čo najlepšie zodpovedajúcich korunám stromov, pričom sme porovnávali viacero mierkových parametrov segmentácie pri rôznom priestorovom rozlíšení snímkov. Uplatnená viacúrovňová segmentácia ortofotomáp (Multiresolution Segmentation) patrí k tzv. metódam „zdola – nahor“ (ECKERT 2006). Začína jednotlivými pixlami – objektmi, ktoré sú postupne, v malých krokoch zjednocované a získavajú na ploche. Kritériom je minimálna heterogénnosť v rámci objektu a/alebo maximálna heterogénnosť na hraniciach so susednými objektmi. Zoskupovanie objektov sa zastaví pri prekročení prahovej hodnoty definovanej parametrom mierky. Homogenita je počítaná zo štyroch parametrov: farba, tvar, kompaktnosť a hladkosť. Pre každé kritérium homogenity je možné zadať jeho váhu pri segmentácii. Táto váha nadobúda hodnoty 0–1 (okrem parametra farby, ktorého minimálna hodnota musí byť 0,1) a volí sa podľa účelu klasifikácie. Súčet váh parametrov farby a tvaru musí byť rovný 1, takisto ako súčet váh kompaktnosti a hladkosti musí byť rovný 1. Zároveň tieto parametre nie sú rovnocenné, ale parameter tvaru pozostáva z parametrov kompaktnosti a hladkosti. Pre stanovenie vhodnej veľkosti váhy jednotlivých kritérií homogenity, ktoré majú byť použité pre samotnú klasifikáciu drevinového zloženia, sa hodnotil vplyv rôznych kombinácií týchto váh na správnosť výslednej klasifikácie.

Klasifikácia drevinového zloženia

Prvým krokom klasifikácie bolo oddelenie plôch bez drevín (neles) od plôch porastených drevinami (les). Dôvodom vylúčenia triedy neles z ďalšej klasifikácie je minimalizovanie informácií (predovšetkým spektrálnych), ktoré negatívne ovplyvňujú priebeh a výsledok klasifikácie. Pri klasifikovaní tried les a neles sa použilo kritérium najbližší sused (Nearest Neighbour). V prvom kroku sa vykonala segmentácia obrazu pri mierke segmentácie 60. Výsledné segmenty triedy les sme uložili do formátu .shp a upravili v prostredí ArcGis (obr. 3). Úprava spočívala v dodatočnej manuálnej editácii nesprávne klasifikovaných segmentov. Výsledné polygóny boli spojené funkciou „merge“ do jednej vrstvy, ktorá slúžila na orezanie rastrov ortofotosnímkov. Následne sme v prostredí eCognition pre klasifikáciu používali už len orezané ortofotosnímky s rôznym rozlíšením.

Pre klasifikáciu drevinového zloženia sme použili klasifikátor štandardný najbližší sused (Standard Nearest Neighbour, SNN) s priemernými hodnotami jasu pixelov príslušnej vrstvy (Mean Layer Brightness). Pri ňom je priestor prvku (príznakový priestor) definovaný pre celý projekt jednotne, kým v prípade najbližšieho suseda ho možno definovať nezávisle pre každú triedu. Klasifikovaných bolo desať druhov drevín (obr. 2) a trieda tieň, ktorá nebola ďalej hodnotená z hľadiska správnosti. Vzory pre jednotlivé triedy sme získali importovaním TTA masky, ktorú sme zároveň použili pri hodnotení správnosti klasifikácie (s inými definovanými vzormi). Skvalitnenie výsledkov klasifikácie sme docielili kombináciou klasifikátora štandardný najbližší sused a funkcií príslušnosti, pričom v oboch prípadoch sa jedná o fuzzy klasifikáciu. Funkcie príslušnosti boli aplikované iba na dreviny vizuálne dobre rozpoznateľné na CIR snímke: *Pinus silvestris*, *Salix alba* a *Salix fragilis*. Klasifikácia prebehla na infračervenej snímke s rozlíšením 0.2 m, s mierkou segmentácie 40 a nasledovnými váhami kritérií homogenity: farba 0.2, tvar 0.8, kompaktnosť 0.2, hladkosť 0.8.

Funkcie príslušnosti dovoľujú zahrnúť do procesu klasifikácie odborné skúsenosti užívateľa – experta. Funkcie umožňujú definovať „jednodimenzionálne členstvo“. Ich použitie sa odporúča vtedy, ak sa jedna trieda odlišuje od ostatných jednou alebo len niekoľkými vlastnosťami. Funkcia príslušnosti je definovaná jej ľavou a pravou hraničnou hodnotou. Pre triedu *Pinus* bola zvolená gaussova funkcia s prahovými hodnotami 0.33 a 0.38 (obr. 4), ktoré boli zvolené na základe nadobúdaných hodnôt v jednotlivých vzoroch triedy. Funkcia bola vybratá pre červený kanál snímkov z dôvodu špecifických spektrálnych vlastností borovice na infračervených ortofotosnímках. Vďaka nim možno borovicu pomerne ľahko odlišiť od ostatných drevín.

Jednotlivé funkcie príslušnosti je možné skombinovať použitím operátorov. Pri vytváraní novej triedy sú jej podmienky kombinované minimálnym operátorom „and (min)“. V našom prípade sa použil pre kombináciu manuálne definovanej funkcie príslušnosti, automaticky generovanej funkcie príslušnosti a štandardného najbližšieho suseda maximálny fuzzy operátor „or (max)“, ktorý používa najväčšiu hodnotu príslušnosti.

Pre *Salix alba* a *Salix fragilis* boli použité funkcie príslušnosti, ktoré boli automaticky generované. Pri *Salix fragilis* sme funkciu príslušnosti generovali automatizovane softvérom z priemernej hodnoty červeného spektra (Mean Layer 1) a pri *Salix alba* z priemernej hodnoty modrého spektra elektromagnetického žiarenia (Mean Layer 3).

Osobitne sa ešte klasifikovala len trieda *Pinus* kombináciou funkcie príslušnosti a štandardného najbližšieho suseda. Funkcia príslušnosti bola manuálne definovaná pre pomernú hodnotu červeného kanála (Ratio – Layer 1). Štandardný najbližší sused bol použitý len pre triedu *Pinus* a triedu ostatné dreviny, generovaním vzorov z TTA masky, ktorá bola použitá v predchádzajúcej klasifikácii.

VÝSLEDKY

Segmentácia obrazu

Cieľom segmentácie bolo generovanie segmentov, ktoré by čo najlepšie reprezentovali koruny stromov, alebo skupiny stromov toho istého druhu. Avšak tento cieľ nebol úplne splnený. Dochádzalo ku:

- rozdeleniu koruny na dva alebo viac objektov, pri niektorých ihličnatých drevinách prechádzala hranica segmentov cez vrchol korún;
- zlúčeniu viacerých stromov rôzneho druhu do jedného segmentu;
- rozdeleniu obrazu na veľký počet segmentov čím sú niektoré stromy rozdelené;
- nezachyteniu všetkých drevín.

Uvedené nedostatky vo všeobecnosti predstavujú dva druhy chýb – podsegmentovanie a nadsegmentovanie.


Dôvodom pre tvorbu takýchto výsledkov je najmä použitý fraktálny sieťový evolučný prístup v programe Definiens, ktorý zlučuje regióny na základe ich homogenity. Tento algoritmus je vhodný pri segmentácii krajiny, pri rozpoznávaní stromov má však nedostatky. Stromy vykazujú väčšiu heterogenitu oproti voľným plochám, hranice susediacich stromov sú nejasné. Vhodné by bolo použiť lokálne maximá jednotlivých korún, avšak nástroje pre použitie takéhoto postupu chýbajú (HEURICH 2006).

Obr. 5a dokumentuje rozdelenie korún smreka cez stred a priradenie časti korún do segmentu tieňa pri mierke segmentácie 40 a CIR snímke s rozlíšením 0.2 m. Na obr. 5b je dobre viditeľné zlúčenie jednotlivých korún, avšak nástroje pre použitie takéhoto postupu chýbajú (HEURICH 2006).



Obr. 1.
Lokalizácia záujmového územia

Fig. 1.
Localization of the study area



Obr. 2.
Vzorová TTA maska druhov drevín zobrazená na RGB ortofotosnímke záujmového územia

Fig. 2.
Sample TTA mask of tree species in the RGB orthophoto of the study area



Obr. 3.
Výsledok klasifikácie lesa na CIR ortofotosnímke

Fig. 3.
Result of the forest classification in the CIR orthophoto

sú podobné spektrálne vlastnosti oboch tried (plôch) pri osvetlení slnečnými lúčmi.

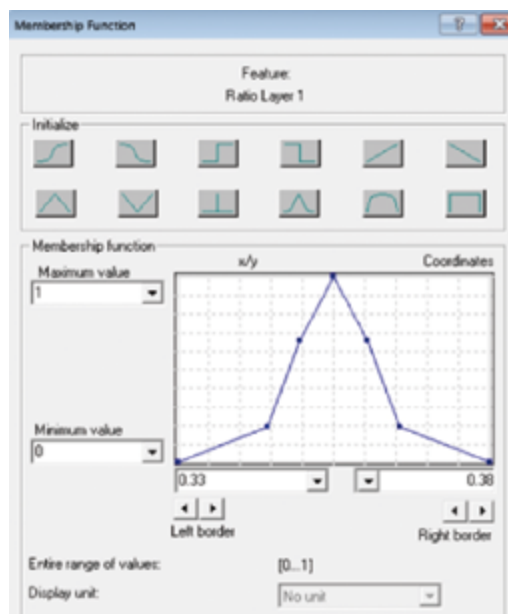
Najvhodnejšiu kombináciu váh pre klasifikáciu drevinového zloženia osobitne pre druh snímky a rozlíšenie v našom prípade zobrazuje tab. 1.

Tab. 1.

Parametre segmentácie – ortofotosnímka s rozlíšením 0.2 m, 0.5 m, 1m
Segmentation parameters – orthophoto with the 0.2 m, 0.5 m, 1 m pixel size

Parametre segmentácie/Segmentation parameters				
Parameter mierky/Scale parameter	Kritériá homogenity/Homogeneity criterions			
	Farba/ Color	Tvar/ Shape	Nastavenie tvaru/Shape settings	
			Kompaktnosť/ Compactness	Hladkosť/ Smoothness
Snímka CIR/RGB, priestorové rozlíšenie 0.2 m/ CIR/RGB orthophoto, pixel size 0.2 m				
20	0.2	0.8	0.2	0.8
30	0.2	0.8	0.2	0.8
40	0.2	0.8	0.2	0.8
50	0.2	0.8	0.8	0.2
60	0.2	0.8	0.8	0.2
Snímka CIR/RGB, priestorové rozlíšenie 0.5 m/ CIR/RGB orthophoto, pixel size 0.5 m				
20	0.2	0.8	0.8	0.2
30	0.2	0.8	0.8	0.2
40	0.2	0.8	0.8	0.2
Snímka CIR/RGB, priestorové rozlíšenie 1 m/ CIR/RGB orthophoto, pixel size 1 m				
10	0.2	0.8	0.8	0.2
20	0.2	0.8	0.8	0.2
30	0.2	0.8	0.8	0.2

Obr. 6 znázorňuje výsledok segmentácie na snímke s rozlíšením 0.2 m pri použití rôznych mierok segmentácie (20, 30, 40, resp. 90), s hodnotami kritérií farby (0.2), tvaru (0.8), kompaktnosti (0.8) a hladkosti (0.2). Z obrázkov je dobre vidieť, ako sa menia hranice segmentov pri zmene kritérií, čo má vplyv na zaradenie objektov do klasifikačných tried a v konečnom dôsledku aj vplyv na celkový výsledok klasifikácie.



Obr. 4.

Funkcia príslušnosti definovaná Gaussovou krivkou

Fig. 4.

Membership function defined by the Gauss curve


Tab. 2.

Výsledky klasifikácie – CIR ortofotosnímka s rozlíšením 0.2 m, 0.5 m a 1 m pri rôznych mierkach segmentácie s využitím klasifikátora najbližšieho suseda (v poslednom prípade v kombinácii s funkciami príslušnosti)


Results of the classification – CIR orthophoto with the 0.2m, 0.5 m and 1 m pixel size at various scales of segmentation with utilization of the standard nearest neighbour classifier (SNN) (in the last case in combination with the membership functions (MF))

Triedy/Classes	Mierka segmentácie/Scale of segmentation				
	10	20	30	40	40 SNN + MF
carpinus	x x 0.10	0.18 0.11 0.05	0.16 0.36 -0.04	0.41 0.44 x	0.53 x x
cerasus	x x -0.05	0.14 0.53 0.00	0.32 0.39 -0.04	0.17 0.25 x	0.03 x x
corylus	x x 0.36	0.33 0.45 0.38	0.26 0.49 0.09	0.45 0.36 x	0.25 x x
picea	x x 0.09	0.14 0.24 0.12	0.13 0.09 0.14	0.13 -0.02 x	0.10 x x
pinus	x x 0.64	0.55 0.70 0.50	0.65 0.57 0.57	0.63 0.46 x	0.65 x x
populus	x x 0.20	0.35 0.40 0.20	0.46 0.28 0.14	0.45 0.23 x	0.53 x x
quercus	x x -0.02	0.14 0.37 0.02	0.03 -0.02 0.04	0.11 -0.02 x	0.57 x x
salix alba	x x 0.82	0.68 0.69 0.44	0.66 0.43 0.06	0.42 0.44 x	0.64 x x
salix fragilis	x x 0.35	0.51 0.43 0.34	0.52 0.49 0.30	0.51 0.32 x	0.61 x x
tilia	x x 0.10	0.21 0.03 0.15	0.33 0.07 0.08	0.32 0.10 x	0.21 x x
Správnosť/Accuracy	x x 0.43	0.48 0.52 0.40	0.52 0.47 0.34	0.53 0.40 x	0.56 x x
KHAT	x x 0.33	0.39 0.44 0.30	0.44 0.38 0.23	0.45 0.30 x	0.48 x x

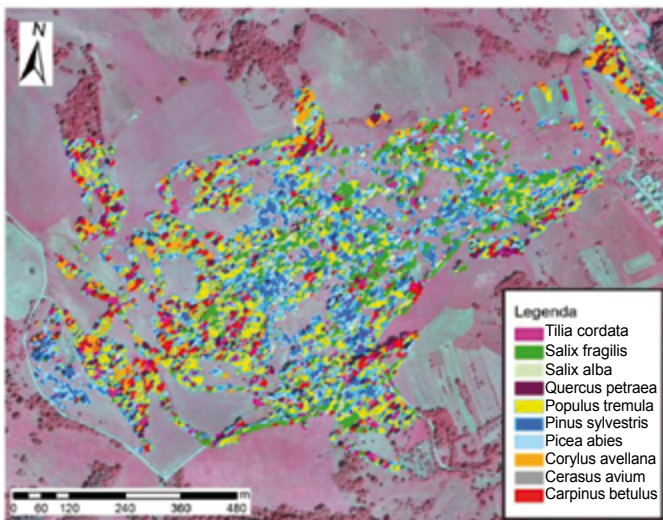
KHAT po triedach/
KHAT by classes




Obr. 5.
Zobrazenie nedostatkov segmentácie
Fig. 5.
Visualization of errors in segmentation



Obr. 6.
Segmentácia pri mierke segmentácie 20, 30, 40, 90 – pixelové zobrazenie (a, b, c, d), priemerné hodnoty segmentov (e, f, g, h)
Fig. 6.
Segmentation at the scale 20, 30, 40, 90 – pixel view (a, b, c, d), object mean view (e, f, g, h)



Obr. 7.
Výsledok klasifikácie – CIR ortofotosnímka s rozlíšením 0.2 m
Fig. 7.
Result of the classification – orthophoto with the 0.2 m pixel size



Obr. 8.
Výsledok klasifikácie triedy borovica s využitím funkcií príslušnosti
Fig. 8.
Result of the classification of single class “*Pinus*“ using membership functions

Výsledky klasifikácie drevinového zloženia

Na zhodnotenie správnosti klasifikácie sa použili tabuľky správnosti, vychádzajúce z TTA masky. Tabuľka správnosti klasifikácie porovnáva klasifikované obrazové prvky s referenčnými údajmi. KHAT index je podľa LILLESAND et al. (2008) štatistická miera diferencie medzi referenčnými dátami a automatizovanou klasifikáciou. Celková správnosť je pomer medzi počtom správne určených pixlov ku celkovému počtu referenčných pixlov.

Pre stanovenie správnosti klasifikácie sa použili náhodne rozmiestnené referenčné polygóny.

Správnosť klasifikácie na CIR ortofotosnímках

Správnosť klasifikácie pre ortofotosnímkou s rozlíšením 0.2 m, 0.5 m a 1 m zobrazuje tab. 2., ktorá znázorňuje KHAT index pre jednotlivé triedy, celkový KHAT index a celkovú správnosť klasifikácie.

Najlepší výsledok klasifikácie sa dosiahol na ortofotosnímkou s rozlíšením 0.2 m, pri mierke segmentácie 40 (tab. 2, obr. 7), kde celková miera správnosti bola v percentuálnom vyjadrení 53 % a KHAT index dosiahol hodnotu 45 %. Naopak, najmenšia hodnota celkovej správnosti sa dosiahla pri mierke segmentácie 20. Pri pohľade na výsledky KHAT indexu pre jednotlivé triedy je vidieť, že najväčšiu hodnotu dosiahla trieda *Salix alba*, ale pri mierke segmentácie 20, kde bola dosiahnutá najmenšia celková správnosť klasifikácie a najnižšia celková hodnota KHAT indexu. Trieda *Salix fragilis* a *Pinus* mali KHAT indexy pri všetkých použitých mierkach segmentácie nad 50 %. Všeobecne možno povedať, že najlepšie výsledky klasifikácie boli dosiahnuté pri mierke segmentácie 30 a 40.

Na ortofotosnímkou s rozlíšením 0.5 m sa dosiahla najväčšia celková správnosť pri mierke segmentácie 20, kde KHAT index dosiahol hodnotu 44 % a celková správnosť až 52 %. Pri použití väčšej hodnoty mierky segmentácie dosahuje správnosť klasifikácie čoraz menšie hodnoty. Z tabuľky ďalej vidieť, že pri mierke segmentácie 30 a 40 dosahuje trieda *Quercus* zápornú hodnotu KHAT indexu a nulovú hodnotu správnosti klasifikácie. Príčinou je veľmi nízky výskyt týchto drevín a zatriedenie väčšej časti objektov *Quercus* do triedy *Populus*. Zápornú hodnotu KHAT indexu dosahuje aj trieda *Picea*, väčšia časť objektov ktorej bola zaradená do triedy *Corylus*. Dreviny, ktoré boli

najlepšie klasifikované z hľadiska KHAT indexu a správnosti klasifikácie, sú *Salix alba*, *Salix fragilis* a *Pinus*.

Na ortofotosnímkou s rozlíšením 1 m celková správnosť klasifikácie a KHAT index dosahujú najmenšie hodnoty v porovnaní s ostatnými hodnotenými CIR ortofotosnímками. Hodnota KHAT indexu je najväčšia pri mierke segmentácie 10, rovnako ako aj dosiahnutá celková správnosť (takmer 43 %). Pri klasifikácii sa nepodarilo vyčleniť triedu *Cerasus* ani pri jednej zvolenej mierke segmentácie. Vo všetkých prípadoch dosahuje KHAT index záporné hodnoty. Pri mierke 10 a 20 bola väčšia časť tejto triedy včlenená do triedy *Populus* a pri mierke 10 do triedy *Carpinus*. Trieda *Carpinus* taktiež dosahuje zápornú hodnotu KHAT indexu. V procese klasifikácie bola zaradená do tried *Cerasus* a *Tilia*. Väčšia časť triedy *Quercus* bola zaradená do tried *Populus* a *Cerasus*. Zaujímavosťou je, že v prípade triedy *Salix alba* pri mierke segmentácie 10 dosahuje KHAT index takmer 82%. Táto hodnota je najväčšia medzi CIR ortofotosnímками, kde pri zvyšných mierkach segmentácie dosiahla trieda *Salix alba* maximálnu výšku KHAT 69 %.

Správnosť klasifikácie na RGB ortofotosnímках

Správnosť klasifikácie pre RGB ortofotosnímkou s rozlíšením 0.2 m, 0.5 m a 1 m zobrazuje tab. 3 znázorňujúca KHAT index pre jednotlivé triedy, celkový KHAT index a celkovú správnosť klasifikácie.

Z tab. 3 je vidieť, že najväčšia správnosť klasifikácie na RGB ortofotosnímkou s rozlíšením 0.2 m je 48 % a dosiahla sa pri mierke segmentácie 30. S rastúcou mierkou segmentácie dochádza k znižovaniu celkovej správnosti a KHAT indexu, ktoré zapríčiňuje zvyšujúca sa heterogenita objektov. Najvyšší KHAT index dosiahla trieda *Salix alba*, kde hodnota správnosti klasifikácie je takmer 84%. V klasifikácii došlo tiež ku zatriedeniu väčšej časti tried *Cerasus* a *Picea* do iných, druhovo bohatších tried.

Najvyššiu celkovú presnosť a najpriaznivejšie hodnoty KHAT indexu sa nám podarilo dosiahnuť na RGB snímke s rozlíšením 0.5 m a mierke segmentácie 30. V percentuálnom vyjadrení je hodnota správnosti 50 % a KHAT indexu 41 %. Aj v tomto prípade sa javia ako najlepšie klasifikované triedy *Salix alba* a *Salix fragilis*. Pri tomto rozlíšení nevykazuje ani jedna trieda zápornú hodnotu KHAT indexu.

Tab. 3.

Výsledky klasifikácie – RGB ortofotosnímkou s rozlíšením 0.2 m, 0.5 m a 1 m pri rôznych mierkach segmentácie s využitím klasifikátora najbližšieho suseda

Results of the classification – RGB orthophoto with the 0.2 m, 0.5 m and 1 m pixel size at various scales of segmentation with utilization of the standard nearest neighbour classifier

Triedy/Classes	Mierka segmentácie/Scale of segmentation			
	10	20	30	40
carpinus	x x 0.18	0.08 0.33 0.34	0.22 0.40 0.21	0.28 0.21 x
cerasus	x x 0.48	0.23 0.46 0.21	0.11 0.08 0.24	-0.01 0.36 x
corylus	x x 0.31	0.46 0.32 0.30	0.50 0.41 0.03	0.32 0.28 x
picea	x x 0.04	0.03 0.01 -0.01	0.07 0.06 -0.05	0.04 0.13 x
pinus	x x 0.28	0.32 0.36 0.20	0.24 0.44 0.01	0.22 0.39 x
populus	x x 0.30	0.25 0.28 0.39	0.32 0.35 0.09	0.28 0.30 x
quercus	x x 0.09	0.13 0.27 -0.04	0.28 0.02 0.23	0.25 0.19 x
salix alba	x x 0.79	0.84 0.55 0.50	0.82 0.64 0.03	0.76 0.31 x
salix fragilis	x x 0.79	0.65 0.68 0.62	0.73 0.65 0.39	0.70 0.54 x
tilia	x x 0.13	0.05 0.21 -0.02	0.09 0.25 0.07	0.13 0.07 x
Správnosť/Accuracy	x x 0.48	0.46 0.47 0.42	0.48 0.50 0.24	0.44 0.43 x
KHAT	x x 0.38	0.35 0.38 0.32	0.38 0.41 0.13	0.34 0.34 x

Celková správnosť klasifikácie na RGB snímke s rozlíšením 1 m je najvyššia pri mierke segmentácie 10, kde dosahuje hodnotu takmer 48 % a KHAT index 38 %.

Správnosť klasifikácie pri použití kombinácie klasifikátora SNN a funkcií príslušnosti

Klasifikácia drevinového zloženia kombináciou klasifikátora SNN a funkcií príslušnosti sa vykonala na CIR snímke s rozlíšením 0.2 m. Z tab. 2 je vidieť, že došlo k zlepšeniu celkovej správnosti klasifikácie z 53 % na 56 %. Pri triede *Salix alba* má KHAT index hodnotu až 64 % oproti hodnote 42 %, ktorá sa dosiahla pri použití jediného klasifikátora SNN. Takisto zlepšenie nastalo aj pri triede *Salix fragilis*, kde sa hodnota KHAT indexu zvýšila takmer o 20 %. Zlepšenie hodnôt KHAT indexov nastalo aj pri triedach, pri ktorých sa nepoužili funkcie príslušnosti. Pravdepodobne je to spôsobené tým, že časť týchto tried bola pri klasifikácii len klasifikátorom SNN zatriedená do inej triedy. Pri použití kombinácie funkcií príslušnosti a SNN boli triedy jednoznačnejšie špecifikované. Klasifikácia samostatnej triedy *Pinus* na CIR snímke s rozlíšením 0.2 m a využitím funkcií príslušnosti dosiahla hodnotu správnosti takmer 84 % (obr. 8).

Stupeň zhody výsledkov našej klasifikácie na CIR a RGB ortofotosnímok s referenčnými údajmi na základe hodnôt KHAT indexov (tab. 4, LANDIS, KOCH 1977) môžeme sumárne vyhodnotiť ako priemerný až veľmi dobrý.

Tab. 4.

Stupeň zhody na základe KHAT hodnôt podľa Landis, Koch (1977)
Degree of compliancy according to the KHAT values (Landis, Koch 1977)

Stupeň zhody/Degree of compliancy	Rozsah /Range
Žiadny/None	0.00–0.05
Veľmi slabý/Very weak	0.05–0.20
Slabý/Weak	0.20–0.40
Priemerný/Average	0.40–0.55
Dobrý/Good	0.55–0.70
Veľmi dobrý/Very good	0.70–0.85
Výborný/Fine	0.85–0.99
Dokonalý/Perfect	0.99–1.00

DISKUSIA A ZÁVER

Z pohľadu kritérií pre segmentáciu sa ako kombinácia váh pre klasifikáciu drevinového zloženia osobitne pre druh ortofotosnímky (RGB a CIR) a rozlíšenie (0.2, 0.5, 1 m) v našom prípade javia hodnoty uvedené v tab. 1. So znižujúcim sa rozlíšením odporúčame pre dosiahnutie lepších výsledkov zmeniť kritériá váh kompaktnosti a hladkosti oproti váham použitým pri ortofotosnímokach s vysokým rozlíšením. Pri ortofotosnímokach s rozlíšením 0.2 m a 0.5 m odporúčame použiť väčší mierkový parameter (30–40), pri ortofotosnímokach s rozlíšením 1 m menší mierkový parameter (10). Mierku segmentácie je vhodné voliť vzhľadom na rozlíšenie použitých materiálov, nakoľko veľkosť vytvorených segmentov závisí práve od rozlíšenia snímky. Pri všetkých rozlíšeniach použitých CIR snímkov najlepšie výsledky klasifikácie dosiahla trieda *Pinus*, *Salix fragilis* a *Salix alba*, čo súvisí so spektrálnymi vlastnosťami daných tried. Tieto drevisy sú najlepšie identifikovateľné aj pomocou vizuálnej interpretácie.

Klasifikácia CIR ortofotosnímky

Na základe dosiahnutých hodnôt celkovej správnosti klasifikácie a KHAT indexu môžeme konštatovať, že pri klasifikácii CIR snímky s rozlíšením 0.2 m sa dosiahli najlepšie výsledky pri mierke segmentácie 30 a 40. Celková dosiahnutá správnosť bola 53 % a KHAT index 45 %. Použitie menšej alebo väčšej mierky má za následok celkové zhoršenie výsledkov klasifikácie.

Hodnota KHAT indexu a správnosť klasifikácie sú na CIR snímke s rozlíšením 0.5 m najpriaznivejšie pri mierke segmentácie 20 (celková správnosť 52 %). Drevisy, ktoré boli najlepšie klasifikované z hľadiska KHAT indexu a správnosti klasifikácie sú *Salix alba*, *Salix fragilis* a *Pinus*. Trieda *Quercus* dosiahla záporné hodnoty správnosti klasifikácie, nakoľko bola zaradená nesprávne do triedy *Populus*. Rovnako trieda *Picea* bola z väčšej časti zaradená do triedy *Corylus*.

Na CIR snímke s rozlíšením 1 m sme dosiahli najpriaznivejšie výsledky pri mierke segmentácie 10 (celková správnosť 43 % je však najnižšia zo všetkých posudzovaných CIR ortofotosnímkov). Pri klasifikácii sa nepodarilo vyčleniť triedu *Cerasus* ani pri jednej zvolenej mierke segmentácie. Pri mierke 10 a 20 bola väčšia časť tejto triedy včlenená do triedy *Populus* a pri mierke 10 do triedy *Carpinus*. Väčšia časť triedy *Quercus* bola zaradená do tried *Populus* a *Cerasus*. Trieda *Salix alba* pri mierke segmentácie 10 dosahuje KHAT index takmer 82 %. Táto hodnota je najväčšia medzi CIR ortofotosnímokami, kde pri zvyšných mierkach segmentácie dosiahla trieda *Salix alba* maximálnu výšku KHAT indexu 69 %.

Klasifikácia RGB ortofotosnímky

Na RGB ortofotosnímke s rozlíšením 0.2 m sa najväčšia správnosť klasifikácie, takmer 48 %, dosiahla pri mierke segmentácie 30. S rastúcou mierkou segmentácie dochádza k znižovaniu celkovej správnosti a KHAT indexu, ktoré zapríčiňuje zvyšujúca sa heterogenita objektov. Najvyšší KHAT index dosiahla trieda *Salix alba*, kde hodnota správnosti klasifikácie je takmer 84 %. Pri klasifikácii došlo tiež k zaradeniu väčšej časti tried *Cerasus* a *Picea* do iných, druhovo bohatších tried.

Z vyhodnotenia výsledkov klasifikácie na RGB ortofotosnímke vyplýva, že najväčšia správnosť bola dosiahnutá na snímke s rozlíšením 0.5 m a mierke segmentácie 30, kde hodnota celkovej správnosti je takmer 50 % a KHAT index 41 %.

Pri klasifikácii na RGB snímke s rozlíšením 1 m sme dosiahli celkovú správnosť klasifikácie najvyššiu pri mierke segmentácie 10, ktorá dosahuje hodnotu takmer 48 % a KHAT index 38 %.

Najlepšie sa podarilo klasifikovať triedy *Salix alba* a *Salix fragilis*, a to bez ohľadu na rozlíšenie použitých RGB snímkov. Pri voľbe mierky segmentácie sme dospeli k rovnakým záverom ako pri CIR snímkach.

Vo všeobecnosti možno povedať, že pri klasifikácii drevinového zloženia, ktorého súčasťou sú ihličnaté drevisy, je výhodnejšie použiť CIR snímky. V tomto prípade na základe spektrálnych vlastností triedy *Pinus* je túto možnosť dobre rozoznať pri vizuálnej interpretácii. Pri samostatnej automatizovanej klasifikácii sa správnosť jej klasifikácie pohybovala okolo 65 %, na rozdiel od RGB snímkov, kde bola najvyššia hodnota KHAT indexu len 44 %. Na druhej strane trieda *Salix alba* a *Salix fragilis* boli najlepšie zhodnotené z hľadiska ich správnosti na RGB snímke. Na RGB snímke s rozlíšením 0.2 m sme dosiahli pri triede *Salix alba* hodnotu KHAT indexu až 84 %.

Z dosiahnutých výsledkov klasifikácie drevinového zloženia vyplýva, že použitím kombinácie klasifikátora SNN a funkcií príslušnosti sa dosiahnu lepšie výsledky správnosti klasifikácie. Na CIR snímke s rozlíšením 0.2 m došlo k zlepšeniu celkovej správnosti klasifikácie z 53 % na 56 %. Pri triede *Salix alba* má KHAT index hodnotu až 64 % oproti 42 %, ktorá sa dosiahla pri použití jediného klasifikátora SNN. Takisto

zlepšenie nastalo aj pri triede *Salix fragilis*, tu sa hodnota KHAT indexu zvýšila takmer o 20%. Zlepšenie hodnôt KHAT indexov nastalo aj pri triedach, pri ktorých sa nepoužili funkcie príslušnosti. Pravdepodobne je to spôsobené tým, že časť týchto tried bola zaradená do inej triedy pri klasifikácii len klasifikátorom SNN. Klasifikácia samostatnej triedy *Pinus* na CIR snímke s rozlíšením 0.2 m a využitím funkcií príslušnosti dosiahla hodnotu správnosti takmer 84%.

Ďalšie vylepšenie výsledkov klasifikácie do budúcnosti predstavuje aplikovanie digitálneho modelu terénu a digitálneho modelu povrchu (najmä údajov laserového skenovania), vďaka čomu by sa dali odlíšiť jednotlivé stromy od voľnej plochy a tieňa. Vizuálna interpretácia v kombinácii s GPS meraním v teréne (zameranie približných súradníc stromu alebo skupiny stromov) sa javí ako veľmi efektívna pri klasifikovaní menších území alebo vzácnych biotopov. Perspektívnou metódou (postupom) sa pre automatizovanú klasifikáciu drevinového zloženia javí vytváranie farebných syntéz z leteckých snímok procesom panchromatického zaostrovania s ohľadom na zvýraznenie alebo potlačenie určitých prvkov podľa konkrétnych požiadaviek.

Podakovanie:

Tento príspevok bol spracovaný ako súčasť riešenia projektu Operačného programu Výskum a vývoj Centrum excelentnosti na podporu rozhodovania v lese a krajine, ITMS kód 26220120069, spolufinancovaného z Európskeho fondu regionálneho rozvoja, ďalej projektu VEGA MŠ SR 1/0157/10 Dynamika svahových procesov – syntéza geologických, geomorfologických a hydrologických aspektov a projektu KEGA 018UMB-4/2011 Regionálna výchova v geografickej edukácii regiónu Horného Pohronia.

LITERATÚRA

- BARKA I. 2009. Návrh regionálneho informačného systému ekologického a produkčného stavu lesa na báze údajov DPZ. In: Bucha T., Pavlendová H. (eds.): Dialkový prieskum Zeme – lesy v meniacich sa prírodných podmienkach. Zborník vedeckých prác. Vedecký seminár Zvolen, 19 november 2009. Zvolen, NLC: 123–142.
- BECHTEL B. 2007. Objektextraktion von Bäumen aus Luftbildern. Vergleich und Steuerung von Segmentierungsverfahren zur Vorbereitung eines Expertensystems. Hamburg: 149 s. Diplomarbeit.
- BOHLIN J., OLSSON H., OLOFSSON K., WALLERMAN J. 2007. Tree species discrimination by aid of template matching applied to digital air photos. In: Koukal T., Schneider W. (eds.): 3D remote sensing in forestry. International workshop. Proceedings. Vienna, 14th–15th Feb. 2006. Vienna, University of Natural Resources and Applied Life Sciences (BOKU): 210–214. Dostupné na World Wide Web: http://www.rali.boku.ac.at/fileadmin/_/H85/H857/workshops/3drforestry/Proceedings_3D_Remote_Sensing_2006_rev_20070129.pdf [cit. 9.9.2013]
- BUCHA T., VLADOVIČ J. 2000. Klasifikácia zdravotného stavu lesov pomocou kozmických snímok Landsat TM na modelovom území Lomnístej a Vajskovskej doliny. Lesnícky časopis – Forestry Journal, 46 (2): 117–127.
- BUCHA T., VLADOVIČ J., JURÍŠ M., BARKA I. 2010. Aplikácie dialkového prieskumu Zeme využiteľné v prácach HÚL. [online]. [cit. 15.07.2012]. Dostupné na World Wide Web: <http://www.nlcsk.sk/files/1590.pdf>.
- DARVISHSEFAT A.A., RAFIEYAN O., BABAII S., MATAJI A. 2011. Object-based classification using UltraCam-D images for forest tree identification (Case study: Hyrcanian forest of Iran). [online]. In: 34th International symposium on Remote sensing of Environment. The GEOSS era: towards operational environmental monitoring. Sydney, 10–15 April 2011. [cit. 24.7.2012]. Dostupné na World Wide Web: <http://www.isprs.org/proceedings/2011/isrse-34/211104015Final00222.pdf>
- ECKERT S. 2006. A Contribution to sustainable forest management in Patagonia. Object-oriented classification and forest parameter extraction based on ASTER and Landsat ETM+Data. Zürich, Universität Zürich: 154 s.
- FÖRSTER M., KLEINSCHMIT B. 2008. Object-based classification of QuickBird data using ancillary information for the detection of forest types and NATURA 2000 habitats. In: Blaschke T. et al. (eds.): Object-based image analysis. Spatial concepts for knowledge-driven remote sensing applications. Berlin, Springer: 275–290.
- GAO J. 2009. Digital analysis of remotely sensed imagery. New York, McGraw Hill: 645 s.
- HÁJEK F. 2008. Process-based approach to automated classification of forest structures using medium format digital aerial photos and ancillary GIS information. European Journal of Forest Research, 127 (2): 115–124.
- HALOUNOVÁ L. 2004. Textural classification of B&W aerial photos for forest classification. In: Goossens R. (ed.): Remote sensing in transition. Proceedings of the 23rd EARSeL Symposium. Ghent, Belgium, 2–5 June, 2003. Rotterdam, Millpress: 173–180.
- HALVOŇ L. 2007. Digitálna fotogrametria a GNSS v lesníckom mapovaní. In: Zihlavník Š., Tunák D. (eds.): Aktuálne problémy lesníckeho mapovania. Zborník referátov. Sympóziu s medzinárodnou účasťou. Technická univerzita vo Zvolene, 13. november 2007. Zvolen, Technická univerzita vo Zvolene: 93–107.
- HAY G.J., CASTILLA G., WULDER M.A., RUIZ J.R. 2005. An automated object-based approach for the multiscale image segmentation of forest scenes. International Journal of Applied Earth Observation and Geoinformation, 7: 339–359.
- HEURICH M. 2006. Evaluierung und Entwicklung von Methoden zur automatisierten Erfassung von Waldstrukturen aus Daten flugzeuggetragener Fernerkundungssensoren. Freising, Lehrstuhl für Forstl. Arbeitswissenschaft und Angewandte Informatik: 328 s.
- HILDEBRANDT G. 1996. Fernerkundung und Luftbildmessung: für Forstwirtschaft, Vegetationskartierung und Landschaftsökologie. Heidelberg, Wichmann: 676 s.
- HYYPÄ J., MIELONEN T., HYYPÄ H., MALTAMO M., YU X., HONKAVAARA E., KAARTINEN H. 2005. Using individual tree crown approach for forest volume extraction with aerial images and laser point clouds. [online] In: Vosselman G., Brenner C. (eds.): ISPRS Workshop Laser Scanning 2005. Enschede, the Netherlands, September 12–14, 2005. Lemmer, GITS: 144–149. [cit. 19.07.2012]. Dostupné na World Wide Web: <http://www.isprs.org/proceedings/XXXVI/3-W19/papers/144.pdf>.
- CHANG A., KIM J.O., RYU K., KIM Y.I. 2008. Comparison of methods to estimate individual tree attributes using color aerial photographs and LiDAR data. WSEAS Transactions on Signal Processing, 4 (1): 21–27.
- KARDOŠ M., CHUDÝ F. 2005. Posúdenie tvorby modelu terénu prostriedkom digitálnej fotogrametrie. In: Dialkový prieskum Zeme a lesnícke mapovanie. Zborník referátov. Sympóziu, 9. december 2005, Technická univerzita vo Zvolene. Zvolen, Technická univerzita vo Zvolene: 24–28.
- LANDIS J.R., KOCH G.G. 1977. The measurement of observer agreement for categorical data. Biometrics, 33: 159–174.

- LILLESAND T.M., KIEFER R.W., CHIPMAN J.W. 2008. Remote sensing and image interpretation. Hoboken, Wiley: 756 s.
- MAJLINGOVÁ A. 2007. Digitálna obrazová analýza dát DPZ s vysokým priestorovým rozlíšením a jej využitie v lesníctve. [online]. In: Sympozium GIS Ostrava. Ostrava, 28.–31.1.2007. Ostrava, VŠB TU Ostrava. [cit. 19.6.2012]. Dostupné na World Wide Web: http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2007/sbornik/Referaty/Sekce2/majlingova.pdf
- MAZÚR E., LUKNIŠ M. 1980. Geomorfologické jednotky. In: Mazúr E. (ed.): Atlas SSR. Bratislava, SAV a SÚGaK: 54–55.
- MILLETTE T., HAYWARD C. 2005 Detailed forest stand metrics taken from AIMS-1sensor data. In: Geospatial goes global. From your neighbourhood to the whole planet. ASPRS annual conference. Baltimore, Maryland, March 7–11, 2005. Conference proceedings. [online]. American Society for Photogrammetry and Remote Sensing. [cit. 20.7.2012]. Dostupné na World Wide Web: https://www.mtholyoke.edu/sites/default/files/acad/geolab/docs/millette_b.pdf
- NEUBERT M. 2005. Bewertung, Verarbeitung und segmentbasierte Auswertung sehr hoch auflösender Satellitenbilddaten vor dem Hintergrund landschaftsplanerischer und landschaftsökologischer Anwendungen. Berlin, Rhombos Verl.: 152 s.
- SITKO R., SCHEER L. 2009. Návrh systému hodnotenia vybraných funkcií lesa na báze údajov DPZ a terestrických informácií. In: Bucha T., Pavlendová H. (eds.): Dialkový prieskum Zeme – lesy v meniacich sa prírodných podmienkach. Zborník vedeckých prác. Zvolen, 19. november 2009. Zvolen, Národné lesnícke centrum: 15–35.
- STANKOVÁ H., ČERŇANSKÝ J. 2004. Objektovo-orientovaná klasifikácia krajiny pokrývky oblasti Chopok-Jasná. Kartografické listy č. 12, 2004. Bratislava: Kartografická spoločnosť SR a Geografický ústav SAV: 10 s.
- ŠANDORFI K., CHUDÝ F. 2004. Digitálna fotogrametria – nezvratný trend lesníckeho mapovania. In: Aktuálne problémy lesníckeho mapovania – II. Sympózium. Zborník referátov. 21. október 2004, Technická univerzita vo Zvolene. Zvolen, Technická univerzita vo Zvolene: 14–22.
- TIEDE D., LANG S., HOFFMANN CH. 2006. Supervised and forest type-specific multi-scale segmentation for a one-level-representation of single trees. [online]. In: Lang S. et al. (eds.): Bridging remote sensing. 1st international conference on object-based image analysis (OBIA 2006). Salzburg, July 4–5, 2006. [cit. 25.7.2012]. Dostupné na World Wide Web: http://www.isprs.org/proceedings/XXXVI/4-C42/Papers/OBIA2006_Tiede_Lang_Hoffmann.pdf
- TUOMINEN S., HAAKANA M. 2005. Landsat TM imagery and high altitude aerial photographs in estimation of forest characteristics. *Silva Fennica*, 39 (4): 573–584.
- WANG Z., BOESCH R., GINZLER CH. 2008. Integration of high resolution aerial images and airborne LiDAR data for forest delineation. In: Chen J. et al. (eds.): XXIst ISPRS Congress. July 3–11, 2008, Beijing, China. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXVII, Part B7: 1203–1207. Dostupné na World Wide Web: http://www.isprs.org/proceedings/XXXVII/congress/7_pdf/6_WG-VII-6/27.pdf
- WASER L.T., GINZLER C., KUECHLER M., BALTSAVIAS E., HURNI, L. 2011. Semi-automatic classification of tree species in different forest ecosystems by spectral and geometric variables derived from Airborne Digital Sensor (ADS40) and RC30 data. *Remote Sensing of Environment*, 115 (1): 76–85.
- YU Q., GONG P., CLINTON N., BIGING G., KELLY M., SCHIROKAUER D. 2006. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. *Photogrammetric Engineering & Remote Sensing*, 72 (7): 799–811.
- ŽÍHLAVNÍK Š., SCHEER L. 2001. Dialkový prieskum Zeme v lesníctve. Zvolen, Technická univerzita vo Zvolene: 289 s.
- ŽÍHLAVNÍK Š., CHUDÝ F., KARDOŠ M. 2005. Digitálna fotogrametria v lesníckom mapovaní. Zvolen, Technická univerzita vo Zvolene: 80 s.

OBJECT-ORIENTED CLASSIFICATION OF TREE SPECIES IN DIGITAL AERIAL PHOTOS OF LANDSLIDE AREA

SUMMARY

The work deals with the automatic object-oriented classification of tree species composition of landslide area in the region of Lúbietová (Central Slovakia) focusing on the use of high resolution aerial remote sensing data. During the use of such data remains the problem of automatic classification of objects as they have very high spectral variability. There were used color infrared orthophotos and true color orthophotos with a spatial resolution of 0.2 m, 0.5 m, and 1 m. At present, these materials are used in the process of forestry thematic maps creation and during the renewal process of basic forestry map, what enables their greater accessibility to other research areas, such as classification of tree species composition.

Our aim was to examine possibilities of the utilization of such materials for automated classification of tree species composition through the sample objects in the so-called TTA mask using software Definiens in the forests stands with rich tree species composition. Species classification was performed using standard nearest neighbour classifier TTA mask, which is used to create samples of individual species depending on different parameter settings of segmentation. In the orthophoto, which reached the highest value of classification accuracy, a classification was carried out using a combination of standard nearest neighbour classifier and membership functions. Classification accuracy was evaluated based on the accuracy of the classification tables. A first we investigated the influence of the scale factor and settings of the homogeneity criterions on the classification accuracy (Tab. 1, Fig. 6).

The best classification result of the CIR orthophotos was achieved at the scale of segmentation 40 and 0.2 m pixel size, with an overall accuracy of 53 % (Tab. 2, Fig. 7). *Salix fragilis* and *Pinus* classes had KHAT indexes for all used scales of segmentation more than 50 %. The trees that were best classified according to the KHAT index and classification accuracy are *Salix alba*, *Salix fragilis* and *Pinus* species. Using higher value scale segmentation, classification accuracy reaches smaller values. In the CIR orthophoto with the 0.5 m pixel size was achieved highest overall accuracy of 52% with the segmentation scale 20. The overall classification accuracy of the CIR orthophoto with 1m pixel size reached the lowest accuracy. KHAT index value was the largest at the scale of segmentation 10, while the classification accuracy of the class *Salix alba* reached 82%, due to spectral characteristic of the class. The combination of the standard nearest neighbour classifier and membership functions has improved the overall classification accuracy from 53% to 56%. In the class *Salix alba* classification accuracy increased by 53%, as well as the class *Salix fragilis* almost 20%. The classification of a separate class *Pinus* in the CIR orthophoto with the 0.2 m pixel size and with the use of membership functions, reached almost 84% accuracy (Fig. 8).

The best classification result of the RGB orthophotos is 50% at the scale of segmentation 30 and 0.5 m pixel size (Tab. 3). The highest classification accuracy of almost 84% also achieved the class *Salix*, but with the 0.2 m pixel size and the scale of segmentation 20.

Overall, we can evaluate the results of classification according to the KHAT index values (LANDIS, KOCH 1977, Tab. 4) as the average, or in some classes such as *Salix*, *Pinus* due to use of membership functions as very good.

In general we can say that the classification of tree species composition, which includes coniferous trees, gets better results when using CIR photos. In this case, based on the spectral characteristics of pine is it possible to distinguish it well using visual interpretation. Classification accuracy can be improved by adding a variety of geographic data (especially laser scanning) in the classification process, as described by FÖRSTER, KLEINSCHMIT (2008), or by creating a synthesis from color aerial photos by the process of pansharping with regard to enhancement or suppression of certain elements.

Recenzováno

ADRESA AUTORA/CORRESPONDING AUTHOR:

Ing. Miroslav Kardoš, PhD., Technická univerzita vo Zvolene, Lesnícka fakulta
T. G. Masaryka 24, 960 53 Zvolen, Slovenská republika
tel.: +421 0455 206 248; e-mail: miroslav.kardos@tuzvo.sk