

Hana STANKOVÁ, Jozef ČERŇANSKÝ

OBJEKTOVO-ORIENTOVANÁ KLASIFIKÁCIA KRAJINNEJ POKRÝVKY OBLASTI CHOPOK-JASNÁ

Stanková H., Čerňanský J.: Object-oriented classification of Chopok-Jasná land cover. Kartografické listy 2004, 12, 4 figs., 1 tab., 12 refs.

Abstract: Different changes caused by tourism today occur in mountainous areas. The most often used method for mapping and monitoring of these changes is visual interpretation of aerial images. Recently, a new method of automatic classification was developed – object-oriented classification based on segments. By the visual interpretation and object-oriented classification of Chopok-Jasná orthophotomages were created the land cover maps and databases. Accuracy of these two methods was evaluated by comparing with independent classified reference polygons.

Keywords: mountainous areas, visual interpretation, object-oriented classification, eCognition, segmentation, fuzzy logic

Úvod

Oblasť Chopok-Jasná patrí k typickým príkladom vysokohorskej krajiny značne ovplyvnenej cestovným ruchom. Je tam celkovo 12 zjazdových tratí, z ktorých mnohé sú postihnuté viditeľnými formami deštrukcie povrchu zapríčinenými vodnou a antropogénnou eróziou pôdy. Vhodným zdrojom údajov na sledovanie týchto zmien krajiny sú letecké meračské snímky, spracované metódami digitálnej fotogrametrie [6].

Najrozšírenejším spôsobom mapovania krajinej pokrývky z leteckých snímok je v súčasnosti vizuálna interpretácia, keďže automatické metódy založené na pixeloch sú vhodné najmä pre družicové snímky. Metodiku vizuálnej interpretácie krajinej pokrývky Slovenska z družicových snímok v rámci projektu CORINE Land Cover vypracovali Feranec et al. [8]. Vizuálnej interpretácii leteckých snímok vysokohorskej krajiny sa u nás venovali najmä Čerňanský, Kožuch, Stanková [7] a Boltížiar [5].

V súčasnosti sa v protiklade ku klasickým metódam obrazovej klasifikácie rozvíjajú nové klasifikačné metódy založené na tzv. objektoch alebo segmentoch. Jedna z metód objektovo-orientovanej klasifikácie je implementovaná aj v prostredí komerčného softvéru eCognition nemeckej firmy Definiens Imaging [1], pomocou ktorého bola vyhodnotená časť farebnej ortofotosnímky oblasti Chopok-Jasná. Porovnávali sa tri rôzne metódy objektovo-orientovanej klasifikácie – metóda klasifikácie definovaním funkcie členstva, fuzzy metóda štandardného najbližšieho suseda a kombinácia týchto dvoch metód.

Správnosť klasifikácie bola vyhodnotená na základe referenčných polygónov, ktoré boli nezávisle vizuálne interpretované. Rovnakým spôsobom bola vyhodnotená aj presnosť mapy krajinej pokrývky vytvorenej vizuálnou interpretáciou tej istej ortofotosnímky v rámci spracovania diplomovej práce [11].

Mgr. Hana STANKOVÁ, Doc. Ing. Jozef ČERŇANSKÝ, PhD., Katedra kartografie, geoinformatiky a DPZ, Univerzita Komenského, Prírodovedecká fakulta, Mlynská dolina 1. 842 15 Bratislava, e-mail: stankova@fns.uniba.sk, cernansky@fns.uniba.sk

Objektovo-orientovaná klasifikácia

Cieľom interpretácie leteckých a satelitných snímok je identifikácia objektov súčasnej krajiny označovaných ako krajinná pokrývka [9]. Fotointerpretáciu môžeme rozdeliť na dva hlavné druhy – vizuálnu a automatickú, známu aj ako obrazová klasifikácia.

Vizuálna interpretácia je najjednoduchšou a v súčasnosti ešte stále najrozšírenejšou metódou interpretácie. V súvislosti s rastúcimi potrebami monitoringu krajiny pokrývky a krajiny ako celku sa však stáva príliš finančne aj časovo náročnou. Okrem toho je značne subjektívna, preto mapy vytvorené rôznymi interpretátormi nie vždy poskytujú porovnateľné výsledky. Výhodou vizuálnej interpretácie je však ľudská schopnosť priestorového hodnotenia objektov a ich vzájomných vzťahov, keďže na rozdiel od obrazovej klasifikácie berie do úvahy aj kontextové informácie.

Klasická obrazová klasifikácia je založená na obrazových elementoch (pixloch). Automaticky zaraďuje pixely podľa hodnôt zaznamenatej intenzity elektromagnetickej radiácie do tried na základe určitých pravidiel. Podľa stupňa zasahovania používateľa do klasifikačného procesu delíme automatickú klasifikáciu na riadenú a neriadenú. Pri riadenej klasifikácii používateľ riadi klasifikačný proces opisom tried krajiny pokrývky vyskytujúcich sa na scéne, na čo využíva tzv. tréningové množiny. K najznámejším metódam riadenej klasifikácie patrí rovnobežková metóda, metóda minimálnej vzdialenosti a metóda maximálnej pravdepodobnosti. Pri neriadenej klasifikácii je obraz najprv klasifikovaný zhlukovaním pixlov do prirodzených spektrálnych skupín (zhlukov) ktorým používateľ priradí identitu krajiny pokrývky. Najpoužívanejšími metódami zhlukovania pixlov je zhluková analýza, štatistické zhlukovanie a metóda zhlukovania ISODATA [10].

V ostatnom období sa začali rozvíjať rôzne nové metódy obrazovej klasifikácie založené na objektoch (segmentoch). Tieto metódy sa snažia napodobniť prirodzené vnímanie človeka, ktorý má tendenciu najprv deliť obraz na homogénne plochy a potom ich charakterizovať. V procese objektovo-orientovanej klasifikácie sa obraz tiež najprv rozdelí na homogénne segmenty, ktoré sú následne zaraďované do tried.

Výhody klasifikácie na základe objektov vystupujú do popredia najmä pri spracovaní obrazových dát s veľmi vysokým rozlíšením [12]. Klasifikácia takýchto dát na základe pixlov je pomerne obťažná a jej výsledky sú často „rozbité“, čo je spôsobené zaraďovaním jednotlivých pixelov do iných tried než ich okolie. Tento efekt sa dá čiastočne odstrániť postklasifikačným zhladením, pri ktorom však dochádza k zmene originálnych dát.

Výsledky objektovo-orientovanej klasifikácie sú v porovnaní s výsledkami klasických klasifikačných metód menej „rozbité“, a tým pádom aj ľahšie interpretovateľné, aj keď pre viaceré aplikácie by si ešte vyžadovali určitú generalizáciu. V niektorých prípadoch však môže byť citlivé zachytenie malých areálov a zložitého priebehu hraníc naopak výhodou, napríklad pri využití výsledkov klasifikácie na ekologické hodnotenie krajiny štruktúry.

Obrazová segmentácia

Proces delenia obrazu na homogénne areály sa nazýva segmentácia. Metód segmentácie je veľmi mnoho, môžeme spomenúť napríklad segmentáciu prahovaním, segmentáciu narastaním oblastí alebo rôzne texturálne segmentačné algoritmy. Takmer žiadna z týchto metód však nevedie k uspokojivým výsledkom pri spracovaní rôznych druhov dát diaľkového prieskumu Zeme. Príčinou je, že segmentácia obrazu na určitý počet regiónov má obrovský počet možných riešení. Vysoký počet stupňov voľnosti musí byť redukovaný na počet, ktorý by vyhovoval daným požiadavkám, pričom základnou požiadavkou je, aby boli výsledné objekty zmysluplné z hľadiska klasifikačnej úlohy [3].

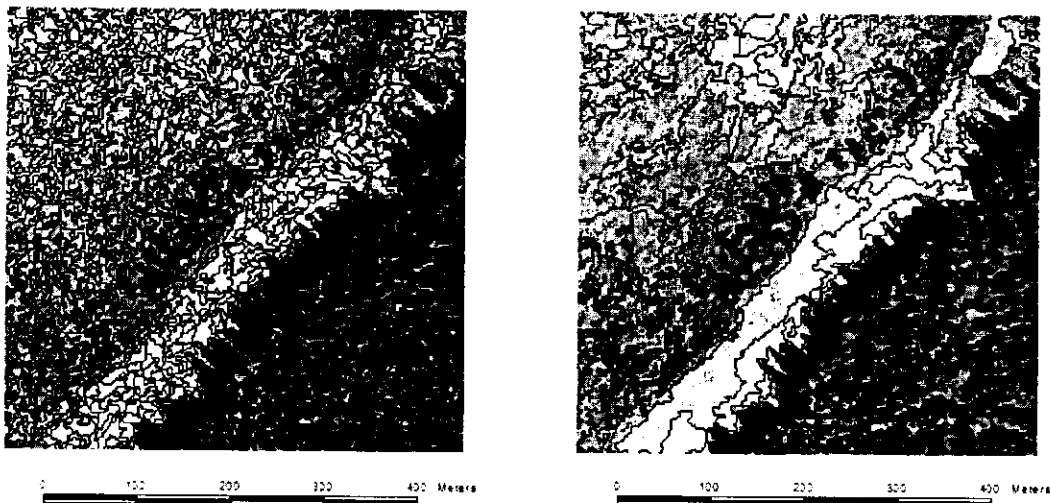
Segmenty obrazu majú vždy určitú mierku (úroveň abstrakcie). Štruktúry reálneho sveta však existujú v rôznych mierkach súčasne (napr. domy sú subštruktúrami mestských štvrtí a mestské štvrte zasa miest). Táto hierarchická mierková závislosť, známa aj ako fraktálny geometrický aspekt, je evidentná nielen pri pozorovaní javov v reálnom svete, ale takisto aj pri ich zobrazení na

snímkach [4]. Z toho vyplýva, že segmenty v obraze nikdy nepredstavujú zmysluplné objekty vo všetkých mierkach. Ideálna mierka neexistuje a pre rôzne aplikácie je potrebné kombinovať objekty s rôznou úrovňou segmentácie (priestorovo) alebo s rôznym významom (ekologicky). Pri tom musí používateľ vziať do úvahy mierku riešeného problému a typ obrazových dát.

Nedávno bola vyvinutá nová metóda segmentácie, ktorá umožňuje vytvárať segmenty v rôznych mierkach súčasne. Je založená na tzv. fraktálnom sieťovom evolučnom prístupe [2], ktorý je súčasťou komerčného softvéru eCognition. Zvlášť je vhodná pre obrazové dáta s vysokým rozlíšením.

Procedúra viacúrovňovej segmentácie sa dá opísať ako techniku zlučovania oblastí. Na začiatku každý pixel predstavuje obrazový objekt. V každom ďalšom kroku sa dvojica obrazových objektov zlúči do jedného väčšieho objektu. Rozhodnutie o zlúčení je založené na kritériu minimálnej zmeny heterogenity objektov pred a po zlúčení. Toto kritérium pozostáva z dvoch častí – z kritéria spektrálnej heterogenity (heterogenity farby) a z kritéria priestorovej heterogenity (heterogenity tvaru). Kritérium tvaru opäť pozostáva z dvoch kritérií – z kritéria pre vyhľadanie a z kritéria pre kompaktnosť.

Veľkosť výsledných objektov je možné ovplyvniť pomocou tzv. parametra mierky (obr. 1). Teoretický rámec na využitie viacúrovňovej segmentácie však ešte nie je k dispozícii, preto musí používateľ vhodnú mierku, resp. segmentačnú úroveň hľadať metódou "pokus – omyl". Ak je mierka príliš veľká, nie sú zachytené všetky objekty záujmu (nadsegmentovanie), ak je naopak príliš malá, výsledkom je veľké množstvo segmentov, ktoré neumožňujú rýchlu a efektívnu klasifikáciu (podsegmentovanie). Tento problém čiastočne rieši možnosť vzájomného prepájania rôznych segmentačných úrovní pomocou tzv. segmentácie založenej na klasifikácii.



Obr. 1 Ukážka segmentácie s rôznym parametrom mierky: vľavo – parameter mierky 10, vpravo – parameter mierky 35


Súčasťou viacúrovňovej segmentácie je aj integrácia sémantických pravidiel do spracovania obrazu, t. j. budovanie sémantiky medzi objektmi v rámci jednej úrovne aj medzi jednotlivými úrovňami (obr. 2). Tak každý objekt, okrem svojich susedov, „pozná“ aj svoje subobjekty (všetky objekty lokalizované v objekte na nasledujúcej nižšej hierarchickej úrovni) a svoj superobjekt (objekt na nasledujúcej vyššej hierarchickej úrovni, v ktorom je objekt lokalizovaný). Tieto kontextové informácie sú pre pochopenie obrazu veľmi dôležité [1].

Objektovo-orientovaná fuzzy klasifikácia v prostredí eCognition

Softvér eCognition je určený na objektovo-orientovanú klasifikáciu leteckých a družicových snímok. Celá procedúra pozostáva z piatich krokov:

1. import vstupných obrazových a iných pomocných vrstiev (model terénu, tematické vrstvy atď.),
2. tvorba obrazových objektov viacúrovňovou segmentáciou,
3. tvorba hierarchie klasifikačných tried,
4. vlastný proces klasifikácie,
5. export výstupných rastrových a vektorových vrstiev.

Vlastná klasifikácia v eCognition je založená na fuzzy logike. Fuzzy logika alebo princíp neurčitosti je matematický prístup na kvantifikáciu neurčitých dát. Hlavnou ideou je nahradenie dvoch striktných dát "áno" a "nie" kontinuálnym rozsahom od 0 do 1, kde 0 znamená "úplne nie" a 1 "úplne áno". Každý objekt môže mať fuzzy príslušnosť ku každej triede vyjadrenú stupňom členstva v nej v intervale od 1 do 0, kde 1 znamená plné členstvo a 0 absolútne nečlenstvo. Stupeň členstva závisí od toho, ako objekt spĺňa podmienky opisujúce danú triedu. Výsledkom je klasifikácia, kde každému objektu je priradený stupeň členstva v klasifikačnej triede.



Obr. 2 Schematické znázornenie hierarchickej siete obrazových objektov

Fuzzy klasifikátory patria medzi tzv. „mäkké“ klasifikátory. Na rozdiel od „tvrdých“ klasifikátorov, ktoré vyjadrujú členstvo objektov v triedach binárnym spôsobom (1 ak objekt patrí do danej triedy, resp. 0, ak do nej nepatrí), „mäkké“ klasifikátory môžu vyjadriť neurčitosť priradenia objektu do určitej triedy. Tento spôsob viac vyhovuje ľudskému uvažovaniu a lepšie vystihuje reálny svet. Väčšina aplikácií pracujúcich s údajmi o krajinej pokrývke však nevie pracovať s takto klasifikovanými dátami, preto ich treba neskôr previesť na tvrdo klasifikované na základe maximálneho stupňa členstva. V tomto procese však dochádza k strate presnosti a vernosti.

Jednotlivé klasifikačné triedy sú v eCognition opísané pomocou fuzzy pravidiel, ktoré sú založené na jednodimenzionálnej funkcii členstva alebo na fuzzy klasifikátore najbližšieho suseda, ktorý pracuje nad viacdimeznionálnym priestorom vlastností.

Funkcia členstva (membership function) je označenie triedy na základe jednej podmienky (napr. trieda voda môže byť definovaná podľa nízkej priemernej hodnoty v červenom kanále spektra). Triedu môžeme opísať aj kombináciou viacerých funkcií členstva pomocou fuzzy operátorov

“and”, “or” a “not” (napr. v triede voda môžeme vyčleniť podtriedy vodný tok a vodná plocha na základe pomeru dĺžky a šírky objektov). Tým sa zároveň tvorí hierarchická štruktúra klasifikačných tried.

Fuzzy klasifikátor najbližšieho suseda funguje na princípe priameho zadávania funkcie členstva v multidimenzionálnom priestore na základe vzorových (trénovacích) objektov. Objektu, ktorý chceme klasifikovať, je priradená hodnota členstva v danej klasifikačnej triede podľa jeho vzdialenosti od vzorových objektov danej triedy v priestore vlastností. Čím je táto vzdialenosť menšia, tým je hodnota členstva väčšia, a naopak.

Ak je trieda oddelená od ostatných len na základe jednej alebo niekoľkých vlastností, môžeme použiť kombináciu funkcií členstva. V opačnom prípade je vhodnejšie použiť fuzzy metódu najbližšieho suseda, pretože čím väčší je počet vlastností, tým väčší je prekryt medzi nimi [1].

Výsledky


V softvéri eCognition 3.0 na Lesníckej fakulte TU vo Zvolene bola klasifikovaná časť farebnej ortofotosnímky oblasti Chopok-Jasná z r.1998. Ortofotosnímka vznikla ako výsledný produkt fotogrametrického spracovania leteckých meračských snímkov v približnej mierke 1:27 000, ktoré poskytol Úrad geodézie, kartografie a katastra. Snímky boli spracované v digitálnom fotogrametrickom systéme ImageStation v rámci diplomovej práce [11]. Presnosť vytvoreného stereomodelu bola $m_{xy} = 0,5$ m, výsledná ortofotosnímka s priestorovým rozlíšením 1 m zachytáva územie veľkosti 3,2 km x 4 km.

V rámci diplomovej práce [11] sa uskutočnila aj vizuálna interpretácia ortofotosnímky podľa legendy špeciálne navrhutej pre účely mapovania a hodnotenia zmien krajinej pokrývky v oblasti vysokých pohorí. Legenda vychádzala z už existujúcej legendy pre mapovanie krajinej pokrývky CORINE Land Cover [7], ktorá bola ďalej podrobnejšie rozčlenená. Obsahovala spolu 32 kategórií krajinej pokrývky, z toho 7 pre antropogénne a zvyšných 25 pre prírodné areály. Minimálna mapovacia jednotka pri vizuálnej interpretácii bola 10 m². Výsledkom bola mapa krajinej pokrývky záujmového územia v mierke 1:10 000.

Navrhnutá legenda bola použitá aj pri objektovo-orientovanej klasifikácii ortofotosnímky v prostredí eCognition, na tieto účely však musela byť upravená. Nie všetky kategórie prírodných areálov bolo možné vyčleniť automatizovanou klasifikáciou, preto bola kategorizácia zjednodušená a pôvodný počet 25 kategórií bol redukovaný na 11.

Takisto antropogénne areály ako cesty, budovy a rôzne zastavané plochy nebolo možné metódami objektovo-orientovanej klasifikácie správne identifikovať. Pomocné objekty tvorili antropogénne objekty vektorizované v rámci vizuálnej interpretácie a vložené do prostredia eCognition ako tematická vektorová vrstva, zohľadnená najprv pri segmentácii a potom pri klasifikácii. Zvyšná časť územia bola klasifikovaná automaticky. Preto je vhodnejšie hovoriť o poloautomatizovanej interpretácii.

V prostredí eCognition bol klasifikovaný výrez z ortofotosnímky veľkosti 3,2 km x 2 km, zachytávajúci severnú, prevažne zalesnenú časť záujmového územia so strediskom Jasná a okolitými zjazdovkami a zariadeniami cestovného ruchu (obr. 3). Pri segmentácii bol zvolený parameter mierky 35. Jednotlivé triedy krajinej pokrývky boli definované jednak pomocou funkcií členstva a trénovacích množín. Opis tried na základe trénovacích množín sa ukázal omnoho jednoduchší než manuálne zadávanie funkcií členstva, a pre väčšinu tried aj výstižnejší. Niektoré triedy sa však dali vystihnúť jedine pomocou funkcií členstva. Preto boli obe metódy kombinované do tretej, ktorá pozostávala z klasifikácie hlavných tried fuzzy metódou najbližšieho suseda a ich rozčlenení na podtriedy na základe funkcií členstva.



Obr. 3 Lokalizácia záujmového územia: a – hranica záujmového územia, b – hranica výrezu zobrazeného na obr. 4

Problematickou bola kategória vodné plochy, ktorá sa nedala bezo zbytku odlíšiť od zalesených plôch kvôli ich spektrálnej podobnosti. Rovnako tieň stromov a budov spôsobovali chyby v klasifikácii tiených plôch. Nesprávne klasifikované areály bolo nutné manuálne reklasifikovať, v opačnom prípade by boli plochy niektorých kategórií (najmä trávne porasty a obnažená pôda) výrazne redukované oproti ich skutočnej hodnote. Najpravdepodobnejší typ krajiny pokrývky na tienenej ploche bol určený vizuálnou interpretáciou na základe čiastočnej priepustnosti tieňov a okolitej krajiny pokrývky.

Správnosť poloaufomatizovanej a vizuálnej interpretácie bola vyhodnotená na základe porovnania s referenčnými plochami, ktoré boli vybrané z plôch vytvorených segmentáciou s parametrom mierky 50 tak, aby pokrývali minimálne 5 % hodnoteného územia. Následne boli vizuálne interpretované, pričom boli vylúčené všetky plochy reprezentujúce viac ako jednu kategóriu krajiny pokrývky. Keďže náhodne vybrané plochy reprezentovali najmä les, bolo potrebné doplniť ďalšie referenčné plochy, aby mohli byť správne vyhodnotené všetky kategórie krajiny pokrývky.

Výsledky hodnotenia ukazuje tab. 1. Najväčšie chyby z nadhodnotenia aj z podhodnotenia boli zaznamenané v kategórii trávne porasty s obnaženou pôdou, ktorá má veľký spektrálny prekryt s kategóriou obnažená pôda s trávnyimi porastami. Relatívne veľké chyby boli v kategórii trávne porasty s krami, ktorá je spektrálne podobná s kategóriou les.

Tab. 1 Hodnotenie presnosti poloautomatizovanej a vizuálnej interpretácie

Kategória	1		2		3		4	
	EO	EC	EO	EC	EO	EC	EO	EC
budova	0,05	0,03	0,00	0,01	0,00	0,01	0,00	0,01
zastavaná plocha	0,04	0,01	0,00	0,00	0,00	0,00	0,00	0,00
odpočívadlo	0,05	0,00	0,00	0,00	0,00	0,00	0,00	0,00
parkovisko	0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,00
areál výstavby	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00
cesta	0,01	0,03	0,00	0,00	0,00	0,00	0,00	0,00
TP s obnaženou pôdou	0,44	0,65	0,72	0,58	0,42	0,56	0,39	0,57
obnažená pôda s TP	0,70	0,56	0,06	0,30	0,24	0,10	0,23	0,08
obnažená pôda	0,26	0,53	0,08	0,06	0,33	0,13	0,08	0,08
TP s krami	0,14	0,15	0,35	0,51	0,66	0,69	0,09	0,40
trávne porasty	0,44	0,18	0,16	0,11	0,32	0,20	0,14	0,08
vodná plocha	0,05	0,00	0,00	0,00	0,55	0,13	0,00	0,00
les	0,02	0,03	0,02	0,01	0,03	0,06	0,02	0,01
OA	0,89		0,94		0,89		0,95	
Kappa	0,77		0,87		0,77		0,89	

Vysvetlivky:

1 – vizuálna interpretácia

2 – klasifikácia definovaním funkcií členstva

3 – klasifikácia fuzzy metódou štandardného najbližšieho suseda

4 – klasifikácia kombinovanou metódou

EO – chyby z podhodnotenia (Errors of Omission)

EC – chyby z nadhodnotenia (Errors of Commission)

OA – celková presnosť (Overall Accuracy)


TP – trávne porasty

Z hodnotených metód sa ukázala najpresnejšou kombinovaná metóda klasifikácie (Kappa koeficient 0,89). Takmer rovnako presná je aj metóda klasifikácie definovaním funkcie členstva (Kappa koeficient 0,87), ktorá je však časovo náročnejšia. Menšia presnosť fuzzy metódy štandardného najbližšieho suseda spôsobila skutočnosť, že pri tejto metóde neboli upravené vodné plochy a tie ne manuálnou reklasifikáciou.

Z hodnotenia presnosti vyplynulo, že kombináciou objektovo-orientovanej klasifikácie a vizuálnej interpretácie môžeme dosiahnuť lepšie výsledky než samotnou vizuálnou interpretáciou, plne automatizovaná objektovo-orientovaná klasifikácia však nedosahuje presnosť vizuálnej interpretácie. Porovnanie výsledkov vizuálnej interpretácie a objektovo-orientovanej klasifikácie ukazuje obr. 4.



a









b



c

Vysvetlivky:

-  zastavaná plocha
-  les
-  trávne porasty
-  trávne porasty s obnaženou pôdou
-  obnažená pôda s trávnymi porastami
-  obnažená pôda

0 100 200 300 400 500 Meters

Obr. 4 Porovnanie výsledkov vizuálnej interpretácie a objektovo-orientovanej klasifikácie: a – výrez z ortofotosnímkky, b – výrez z mapy vytvorenej vizuálnou interpretáciou, c – výrez z mapy vytvorenej klasifikáciou definovaním funkcií členstva

Záver

Najjednoduchšou a najrozšírenejšou metódou fotointerpretácie je v súčasnosti vizuálna interpretácia, ktorú najmä pri spracovaní dát s veľmi vysokým rozlíšením automatické metódy obrazovej klasifikácie nie sú schopné nahradiť. V ostatnej dobe však boli vyvinuté nové metódy obrazovej klasifikácie založené na objektoch, ktoré majú oproti štandardným metódam založených na pixloch viacero výhod. Ich výsledky sú ľahšie interpretovateľné a viac sa približujú výsledkom vizuálnej interpretácie.

Tromi metódami objektovo-orientovanej klasifikácie v prostredí eCognition bola spracovaná časť farebnej ortofotosnímkky oblasti Chopok-Jasná. Ukázalo sa, že antropogénne objekty je možné správne identifikovať len vizuálnou interpretáciou, preto boli metódy obrazovej klasifikácie aplikované iba na zvyšnú časť územia. Presnosť metód bola spolu s presnosťou vizuálnej interpretácie tej istej ortofotosnímkky vyhodnotená na základe porovnania s náhodne vybranými referenčnými plochami. Najpresnejšou sa ukázala kombinácia fuzzy metódy štandardného najbližšieho suseda a definovania funkcií členstva.

Kombináciou objektovo-orientovanej klasifikácie a vizuálnej interpretácie teda môžeme dosiahnuť porovnateľné, resp. lepšie výsledky než pri použití vizuálnej interpretácie. Zároveň však treba pripomenúť, že plne automatizovaná objektovo-orientovaná klasifikácia nie je schopná nahradiť vizuálnu interpretáciu v prípade spracovania snímok zachytávajúcích antropogénne objekty, ktoré by mali podobnú mierku a rozlíšenie ako nami použité snímky.

Poloautomatizovaná interpretácia leteckých snímok by mohla byť vhodným nástrojom pri monitorovaní zmien vysokohorskej krajiny. V procese ďalšieho výskumu však bude potrebné posúdiť vhodnosť použitia objektovo-orientovanej klasifikácie pri interpretácii snímok z oblastí nad hornou hranicou lesa, ako aj pri interpretácii snímok z viacerých časových horizontov.

Literatúra

- [1] BAATZ, M., BENZ, U., DEGHANI, I., HEYNE, M., HÖLTJE, A., HOFMANN, P., LINGENFELDER, I., MIMLER, M., SOHLBACH, M., WEBER, M., WILLHAUCK, G.: *eCognition User Guide*. Definiens AG, München, 2003, 480 s. <http://www.definiens-imaging.com/down/index.htm>.
- [2] BAATZ, M., SCHÄPE, A.: Multiresolution Segmentation – an optimization approach for high quality multi-scale image segmentation. In: Strobl, J. et al. *Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGIT-Symposium Salzburg 2000*. Karlsruhe, Herbert Wichmann Verlag, 2000, s. 12–23.
- [3] BLASCHKE, T., LANG, S., LORUP, E., STROBL, J., ZEIL, P.: Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. In: Cremers, A. - Greve, K. (eds.): *Environmental Information for Planning Politics and the Public*. Metropolis-Verlag, Marburg, Volume II, 2000.
- [4] BLASCHKE, T., HAY, G.J.: Object-oriented Image Analysis and Scale-space: Theory and Methods for Modeling and Evaluating Multiscale Landscape Structures. *International Archives of Photogrammetry and Remote Sensing*, Vol. 34, Part 4/w5, 2001, s. 22–29.
- [5] BOLTŽIAR, M.: Mapovanie a analýza vzťahu krajinnej štruktúry a reliéfu vysokohorskej krajiny Tatier s využitím údajov DPZ a GIS, *Kartografické listy*, 11, 2003, s. 5–15.
- [6] ČERŇANSKÝ, J., KOŽUCH, M.: Monitorovanie zmien národného parku Nízke Tatry metódami digitálnej fotogrametrie, *Geodetický a kartografický obzor*, 8–9, 2001, s. 242–249.
- [7] ČERŇANSKÝ, J., KOŽUCH, M., STANKOVÁ, H.: Sledovanie a hodnotenie zmien vysokohorskej krajiny s využitím ortofotomáp, In.: *Geoinformatizácia kartografie*. Kartografická spoločnosť SR, Bratislava, Zvolen, 2001, s. 93–100.
- [8] FERANEC et al.: Inventory of major landscape changes in the Czech Republic, Hungary, Romania and Slovak Republic 1970s – 1990s. *JAG*, Volume 2, Issue 2, 2000, s. 129–139.
- [9] FERANEC, J., OŤAHEL, J.: *Krajinná pokrývka Slovenska*. VEDA, Bratislava, 2001, 124 s.
- [10] LILLESAND, T. M., KIEFER, R. W.: *Remote Sensing and Image Interpretation*. Third Edition, John Wiley & Sons, Inc., New York, 1994, 750 s.
- [11] STANKOVÁ, H.: *Hodnotenie zmien krajinnej pokrývky v oblasti Chopok - Jasná metódami digitálnej fotogrametrie*. Prírodovedecká fakulta Univerzita Komenského, [diplomová práca], Bratislava, 2002, 105 s.
- [12] TUČEK, J.: Špecifické metódy digitálneho spracovania materiálov DPZ s vysokou priestorovou rozlišovacou schopnosťou pre lesnícke účely. In.: *Geoinformatizácia kartografie*. Kartografická spoločnosť SR, Bratislava, Zvolen, 2001, s. 280–293.

S u m m a r y

Object-oriented classification of Chopok-Jasná land cover

Land cover mapping by visual interpretation from aerial images is well known and often used method. Different pixel-based automatic classification methods are convenient for remotely sensed data, but not for aerial images. Recently, a new object-oriented approach to image analysis was developed. This approach is based on objects or segments, which are relatively homogeneous image areas. The extraction of real world objects is expected result from many classification tasks and this cannot be fulfilled by common, pixel-based approach.

Objects or segments are created by the process of segmentation. There are a few methods of segmentation, but multiresolution segmentation seems to be the most appropriate, because it allows creation of segments with different scale. This method is now implemented in commercial software eCognition by Definiens Imaging, which is assigned for fuzzy-rule object-oriented classification.

In eCognition 3.0 were compared three methods of object-oriented classification - classification by definition of membership functions, standard nearest neighbour method and combine method. As input data was used the orthophotoimage of Chopok-Jasná, which is the most important center of ski tourism in Slovakia. Accuracy was assessed by comparing with manually classified reference polygons. The most accurate seems to be the combine method of classification (Kappa coefficient 0.9).

In each of compared object-oriented methods, the visual interpretation of artificial objects was necessary. This semi-automatic interpretation method is more accurate than the visual interpretation, whereas the fully automatic classification method seems to be less accurate.

Fig. 1 Segmentation with different scale parameter (a – scale parameter 10, b – scale parameter 35)

Fig. 2 Hierarchical network of image objects in abstract illustration

Fig. 3 Area of interest localization (a – area of interest, b – map section on Fig.4)

Fig. 4 Comparison of visual interpretation and object-oriented classification results (a – orthophotoimage, b – visual interpretation, c – classification by definition of membership function)

Tab. 1 Semi-automatic and visual interpretation accuracy assessment

Lektoroval:

**Mgr. Tomáš CEBECAUER, PhD.,
Geografický ústav SAV, Bratislava**