

VÝVOJ ALGORITMU SEGMENTACE OBRAZU NA BÁZI RŮSTU OBLASTÍ PRO PROSTŘEDÍ GIS GRASS

A. Tippner

Došlo: 2. července 2009

Abstract

TIPPNER, A.: *Development of segmentation algorithm based region growing for software GIS GRASS*. Acta univ. agric. et silvic. Mendel. Brun., 2010, LVIII, No. 1, pp. 207–216

Image segmentation is fundamental prerequisite for new satellite images interpretation methods. GIS GRASS provides segmentation tools enabling global image segmentation only. We designed procedure enabling local segmentation using existing GRASS tools and segmentation algorithm based on region growing that we developed with C++. This algorithm applies mathematical morphology operators to output segments, too. Principal aim of the project is creation of useful input for differentiation of base land cover classes in panchromatic high-resolution satellite image (or historical aerial photographs for example).

image segmentation, GIS GRASS, algorithm

Segmentace obrazu je prvním a zároveň klíčovým prvkem v procesu objektově orientované klasifikace družicových dat. Jde o modelování entit zemského povrchu, kde entity představují souvislé části obrazového záznamu, které jsou ve zvolené charakteristice dat homogenní. Touto charakteristikou mohou být statistické veličiny popisující rozložení hodnot části obrazového záznamu, jeho texturu či jiné charakteristiky. V současné době GIS GRASS nedisponuje přímými nástroji na segmentaci obrazu. Běžnými nástroji lze provést pouze segmentaci na globální úrovni obrazu (např. prahováním). Pro lokální segmentaci obrazu lze s pomocí GIS GRASS vytvořit mezistupně, např. obraz hran, a pro jejich zpracování dále navrhnout vhodný algoritmus. Toto řešení však může být obtížnější a na něm postavený algoritmus méně výkonný než vytvoření algoritmu vedoucího přímo k segmentaci obrazu. Proto se přistoupilo k naprogramování algoritmu na bázi růstu oblastí, který se o GIS GRASS opírá jen po stránce vstupu a výstupu dat, případně v úpravě výstupu algoritmu. Program je i nadále vyvíjen a je dostupný veřejnosti pod licencí GNU/GPL.

Segmentací družicových snímků Landsat metodou region growing za účelem rozlišení kategorií krajinného pokryvu se zabývali Schneider & Steinwender (1999). Ve své práci se zabývají vzájemnou závislostí výstupů segmentace obrazu a spektrální klasifikace a navrhuji strategii pro kombinaci těchto dvou metod interpretace snímků za účelem zpřesnění jejich klasifikace. Segmentací panchromatických dat velmi vysokého prostorového rozlišení metodou multiscale za účelem rozlišení lesních porostů se zabývali Hay et al. (2005). Problematikou region growing segmentace pro nalezení texturových objektů se zabýval, na příkladu radarových dat, Frulla, J. L. L. (1998). O možnostech GIS GRASS v oblasti zpracování družicových dat a možném alternativním použití klasifikátoru SMAP pro segmentaci snímků pojednávají Neteler & Mitasova (2008). Využití GIS GRASS a klasifikátoru SMAP v procesu objektově orientované klasifikace historických černobílých leteckých snímků zkoumali Rico & Maseda (2009) v příspěvku předneseném na International Opensource Geospatial Research Symposium 2009.

MATERIÁL A METODY

Techniky lokální segmentace a zvolený algoritmus

Lokální segmentace obrazu na rozdíl od globálních metod segmentace využívá poznatku, že segment lze nalézt i bez znalosti celého obrazu. Je pouze třeba, aby se segment v nějaké pozorovatelné vlastnosti odlišoval od svého nejbližšího okolí. U globálních metod, které zpracovávají celý obraz najednou, pak jde spíše o oddělení určitých podobně vyhlížejících entit od zbytku obrazu, který má pak charakter pozadí. Vlastní algoritmy lokální segmentace obrazu se dělí do základních skupin na základě prioritní informace obrazového záznamu, která je k vytváření segmentu využita. Máme tak metody založené na vytváření hranic segmentů z charakteristických hran izolovaných pomocí vysokofrekvenčních filtrů a dále například metody založené na vytváření těchto oblastí. Algoritmy založené na principu separace hran lze rozdělit na ty, které používají první, resp. druhou derivaci obrazové funkce. Metoda první derivace počítá z parciálních derivací (složek gradientu) v daném pixelu vektor gradientu a hranami pak jsou místa s lokálně největšími vektory gradientu. K výpočtu složek gradientu lze využít vhodné vysokofrekvenční filtry, např. Sobelův, Prewittův, Robinsonův nebo Kirschův. Metodami druhé derivace zpravidla nacházíme místa (pixely), kde druhá derivace obrazového záznamu představuje hodnotu blízkou nule a zároveň je daný pixel inflexním bodem. Dále existují metody založené na vyhledávání hran pomocí postupného procházení rastru a jeho porovnávání se vzorem hranic. Tyto metody jsou dosti náročné na dobu výpočtu, ale lze je, na rozdíl od předešlých, použít i na detekci hran mezi objekty s texturou. Druhé uvedené metody lze dále dělit na ty, jež vytvářejí segmenty postupným dělením obrazu a následným spojováním skladebných částí budoucího segmentu a metody, které vytvářejí segmenty přímo postupným růstem oblastí. Oba přístupy vyžadují definovat kritérium homogenity segmentu, kterým může být např. maximální rozpětí hodnot úrovně šedi, podmnožina některého barvového prostoru nebo maximální rozpětí hodnot vhodně popisujících lokální dynamiku obrazové funkce (texturu). Příkladem první metody je segmentace označovaná jako split and merge. Obraz je postupně rekurzivně dělen do požadované struktury, nejčastěji quart tree struktury (kvadrantový strom), dokud v tomto případě všechny obdélníkové oblasti nesplňují kritérium homogenity. Následně jsou sousední obdélníkové oblasti z různých úrovní kvadrantového stromu dle stejného kritéria homogenity spojovány. Metody založené na přímém růstu oblastí jsou zastoupeny algoritmy region growing nebo např. algoritmem watershed, který vytváří segmenty napodobováním záplavy terénu (zde nadmořskou výšku napodobují hodnoty odrazivosti v rastru). Algoritmy region growing se mohou lišit dle konkrétní

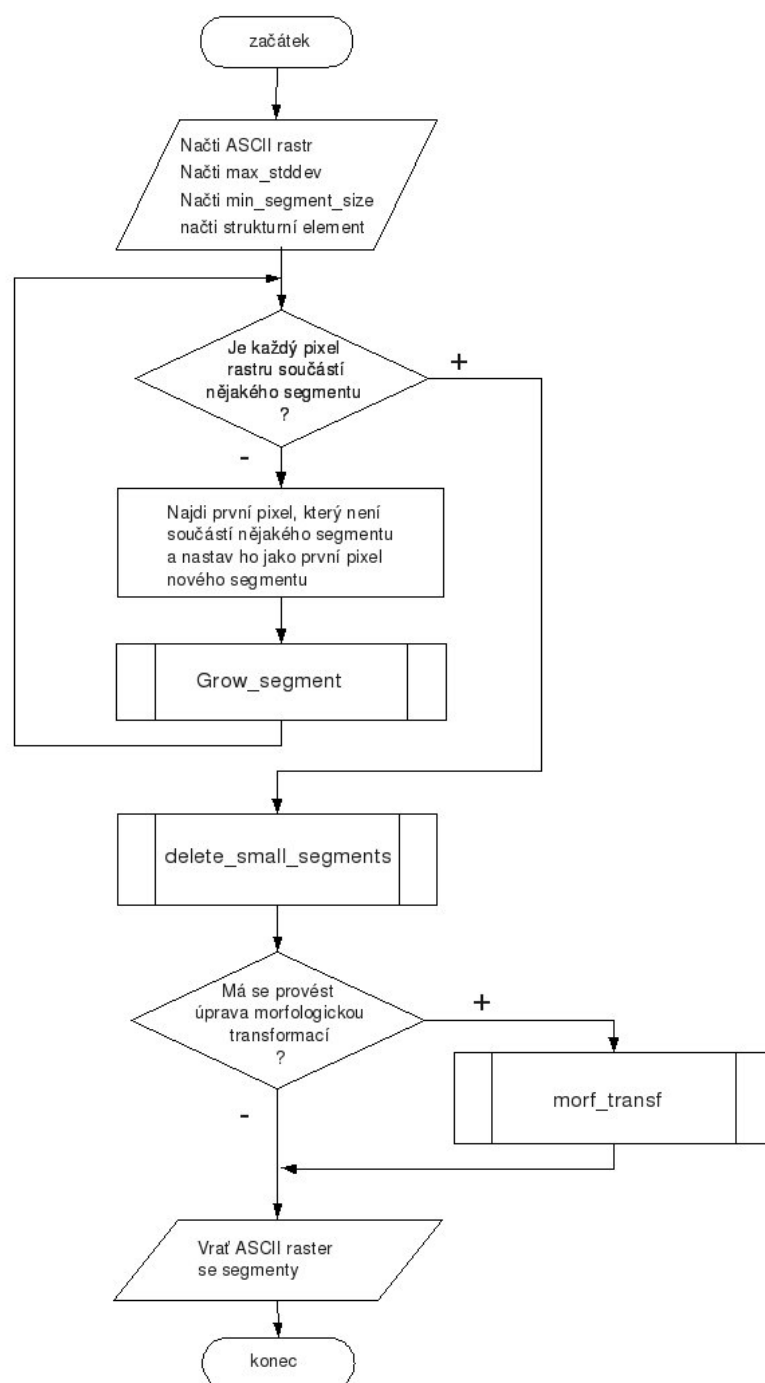
implementace algoritmu, podle použitého kritéria homogenity nebo podle způsobu určení výchozích pixelů šíření označovaných jako seeds. Mezi metodami přímého vytváření oblastí mají nezastupitelné místo rovněž metody porovnávání se vzorem. Jako u metod hledání hran i zde jsou vhodné na vyhledávání segmentů vyznačujících se texturou. Přehledné pojednání o segmentačních metodách reprezentuje *Počítačové vidění* (Hlaváč, Šonka; 1992). Předmětem naší práce je segmentace na principu vytváření oblastí metodou region growing. Segmentačním kritériem je zde úroveň homogenity hodnot odrazivosti v segmentu, na jejímž základě je obraz rozdělen do homogenních oblastí. Úroveň homogenity je vyjádřena maximální odchylkou hodnoty pixelu od průměrné hodnoty postupně rostoucího segmentu. Dále se vychází z velikosti těchto homogenních oblastí a z jejich uspořádání. Algoritmus je navržen pro panchromatické snímky s velmi vysokým prostorovým rozlišením.

Realizace segmentačního algoritmu na bázi růstu oblastí

Zvoleným programovacím jazykem je C++ s využitím jeho standardních knihoven. Implementace algoritmu do prostředí GIS GRASS byla původně řešena prostřednictvím skriptu v jazyce BASH shell. Vše je tedy vyvíjeno pro OS GNU/Linux. Později se však vhodnější alternativou jeví začlenění GRASS příkazů a systémových nástrojů přímo do kódu C++.

Vstupem programu je název GRASS rastrové vrstvy, maximální odchylka hodnoty pixelu od průměru hodnot pixelů segmentu, minimální velikost segmentu a název výstupní vrstvy. Tato rozhodnutí musí uživatel podpořit znalostí zpracováváných dat – statistickým rozložením hodnot v rastru a prostorovým rozlišením rastru. Program převádí vstupní GRASS rastr na GRASS ASCII rastr, který je dále zpracováván vlastním algoritmem. Výsledek segmentace je zapsán opět do GRASS ASCII rastru a importován do formátu nativního GRASS rastru. Samotný segmentační algoritmus provádí, dle přání uživatele, též úpravu segmentů operátory matematické morfologie (viz dále) pomocí uživatelem definovaného strukturního elementu (v textovém souboru), výsledek tohoto procesu je ale dále korigován stávajícími moduly GIS GRASS.

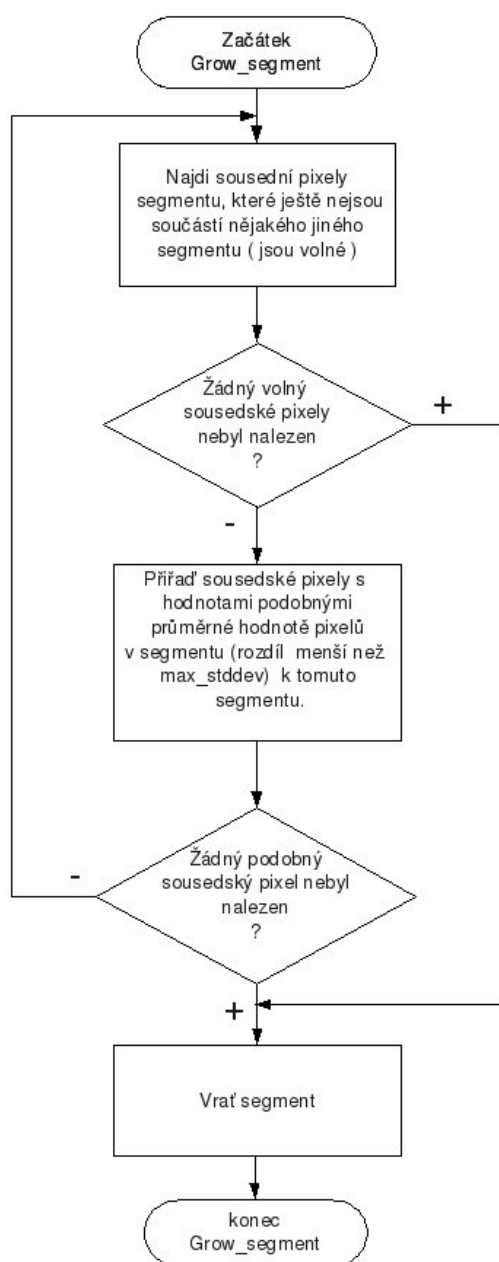
Vlastní segmentační algoritmus v C++ je popsán vývojovým diagramem na obr. 1, jeho submoduly pak na obr. 2 a 3. Algoritmus vždy nastaví počátek segmentu na první nalezený volný pixel (tzn. pixel, který ještě nebyl zařazen k nějakému segmentu), a dále volá submodul `grow_segment`, který se stará o růst segmentu do okolních volných pixelů, které postupně rostoucímu segmentu vyhovují z hlediska kritéria homogenity. Po vrácení dokončeného segmentu se cyklus opakuje, dokud jsou k dispozici volné pixely. Touto procedurou je vytvořen rastr (mezistupeň), ve kterém segmenty vyhovují z hlediska kritéria maximální odchylky hodnoty pixelu od průměrné hodnoty v segmentu. Pro tuto fázi je



1: Zjednodušený vývojový diagram v pseudokódu – hlavní část programu
 1: Simplified pseudocode flow diagram - main part of program

tedy klíčový parametr maximální odchylky hodnoty pixelu od průměrné hodnoty pixelů segmentu. Dále tento mezistupeň postupuje do submodulu delete_small. Pro něj je klíčové kritérium minimální velikosti segmentu. Zde jsou postupně odstraňovány segmenty menší než toto kritérium, přičemž se algoritmus opírá o teorii, že dostatečně velký shluk drobných segmentů je pravděpodobně segmentem s texturou. Drobné segmenty tvořící shluky nebo jen

malé shluky drobných segmentů jsou naopak pokládány spíše za méně informačně významné, a tudíž připojovány k okolním segmentům. Důsledky těchto předpokladů jsou zmiňovány v popisu výsledků. Výsledek segmentace je pak dále možné dle přání uživatele upravit operátory matematické morfologie (vývojový diagram tohoto submodulu zde neuvádíme). Cílem aplikace této procedury by mělo být přerušení segmentů v jejich úzkých oblastech



2: Zjednodušený vývojový diagram v pseudokódu – podmodul grow_segment
2: Simplified pseudocode flow diagram - grow_segment subunit

(mostech), a tedy vytvoření nových kompaktnějších segmentů a dále zjednodušení jejich tvaru. Tohoto je docíleno binárním otevřením a to s použitím uživatelsky definovaného strukturního elementu.

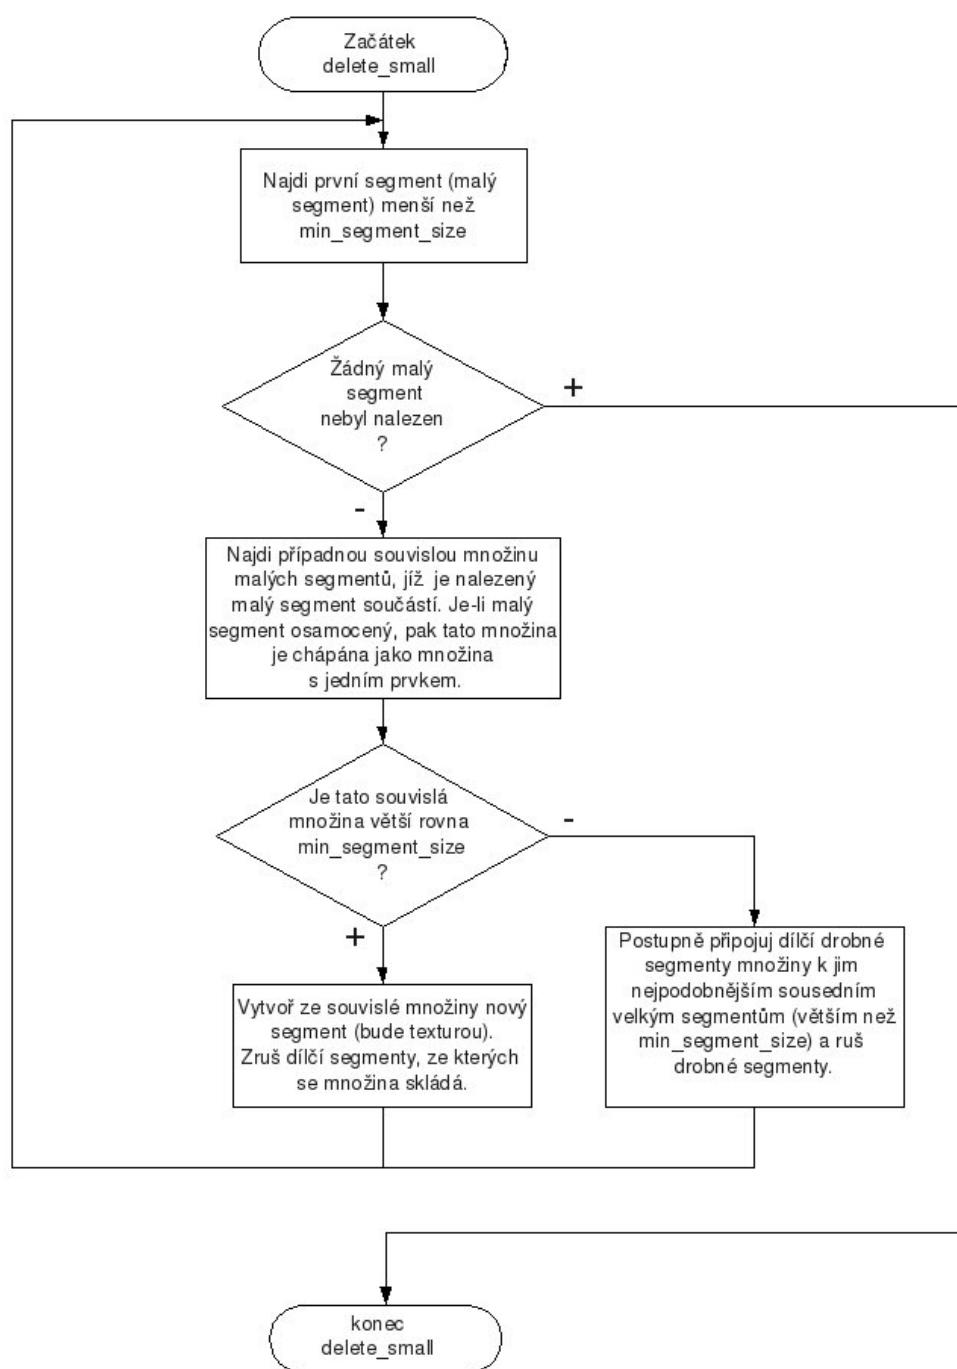
VÝSLEDKY

Segmentace byla testována na panchromatických datech družice IKONOS pořízených 1. 11. 2005 cca v 9:58 GMT a též na panchromatických datech družice WorldView pořízených 29. 5. 2008 cca v 9:53 GTM. Data jsou z okolí města Lednice. Prostorové rozlišení PAN IKONOS činí 1 m, WorldView pak 0,5 m. Data byla lineárně přeškálo-

vána do 256 úrovní jasu. Výsledné rozložení hodnot celých výřezů viz v následujícím přehledu.

I: Statistické rozložení hodnot pixelů rastrů
I: Statistical distribution of pixel values

	IKONOS PAN	WorldView PAN
Minimum	16	4
Maximum	251	255
Průměrná hodnota	70,90	129,58
Směrodat. odchylka	31,07	26,79




3: Zjednodušený vývojový diagram v pseudokódu – podmodul delete_small

3: Simplified pseudocode flow diagram - delete_small subunit



Z obrázků č. 5–7 je zřejmé, že algoritmus vyžaduje správnou volbu vstupních parametrů maximální odchylky hodnoty pixelu od průměrné hodnoty pixelů segmentu a minimální velikosti segmentu. To dále vyžaduje dobrou znalost rozložení hodnot v obrazových datech. Lze zjistit, že s rostoucí velikostí parametru minimální velikosti segmentu dochází často k nevhodným přiřazením jinak význačných entit k větším, a často i charakterem odlišným, segmentům. Správnou volbu parametru maximální

odchylky hodnoty pixelu od průměru hodnot pixelů segmentu s ohledem na cíl segmentace nejlépe dokumentuje rozdíl mezi obr. 12 a 13, kde se v prvním případě nepodařilo zachytit téměř žádné obrysy polí. Obr. 14 dále dokumentuje význam vztahu mezi absolutní velikostí entit a prostorovým rozlišením družicového snímku. Pro přesnější vymezení entit zastavěných oblastí je vhodnější větší prostorové rozlišení snímku. Úprava výsledku segmentace použitím matematické morfologie je znázorněna





4 a 5: Výsledek segmentace pro maximální odchylku hodnoty od průměru 20, minimální velikost segmentu 107 pixelů a bez morfologické transformace (data IKONOS PAN 1 m)

4 and 5: Result of segmentation with max. pixel-value deviation from mean 20, min. size of segment 107 pixels and without a morphological transformation (IKONOS PAN 1 m)





6 a 7: Výsledek segmentace panchromatických dat IKONOS (1 m) pro maximální odchylku hodnoty od průměru 20, minimální velikost segmentu 19 pixelů a bez morfologické transformace (vlevo), segmentace pro maximální odchylku hodnoty od průměru 10, minimální velikost segmentu 19 pixelů a bez morf. transformace (vpravo)

6 and 7: Result of segmentation of IKONOS panchromatic data (1 m) with max. pixel-value deviation from mean 20, min. size of segment 19 pixels and without a morphological transformation (on the left), segmentation with max. pixel-value deviation from mean 10, min. size of segment 19 pixels and without a morphological transformation (on the right)





8 a 9: Rozdíl mezi segmentacemi dat IKONOS PAN 1m: pro maximální odchylku hodnoty od průměru 20, minimální velikost segmentu 107 pixelů a bez morfologické transformace (vlevo), stejné parametry s morf. transformací strukturálním elementem viz uvnitř obrázku – 1 prvek elementu, 2 střed elementu, prvek elementu (vpravo)

8 and 9: Difference between segmentations of IKONOS PAN data (1m): with max. pixel-value deviation from mean 20, min. size of segment 107 pixels and without a morphological transformation (on the left), same parameters but with a morphological transformation by using structuring element (see on picture - 1 atom of structuring element, 2 both center of structuring element and atom of structuring element (on the right))



10 a 11: Výsledek segmentace dat IKONOS PAN 1 m pro maximální odchylku hodnoty od průměru 20, minimální velikost segmentu 200 pixelů a bez morfologické transformace (vlevo), výsledek segmentace pro maximální odchylku hodnoty od průměru 10, minimální velikost segmentu 200 pixelů a bez morfologické transformace (vpravo)

10 and 11: Result of segmentation of IKONOS panchromatic data (1m) with max. pixel-value deviation from mean 20, min. size of segment 200 pixels and without a morphological transformation (on the left), result of segmentation with max. pixel-value deviation from mean 10, min. size of segment 200 pixels and without a morphological transformation (on the right)



12 a 13: Výsledek segmentace dat KONOS PAN 1 m pro maximální odchylku hodnoty od průměru 20, minimální velikost segmentu 34 pixelů a bez morfologické transformace (vlevo), Výsledek segmentace pro maximální odchylku hodnoty od průměru 10, minimální velikost segmentu 34 pixelů a bez morfologické transformace (vpravo)


12 and 13: Result of segmentation of IKONOS panchromatic data (1m) with max. pixel-value deviation from mean 20, min. size of segment 34 pixels and without a morphological transformation (on the left), result of segmentation with max. pixel-value deviation from mean 10, min. size of segment 34 pixels and without a morphological transformation (on the right)

obrázky 8 a 9. Aplikací operátoru binárního otevření (strukturní element viz obrázek) došlo ke zjednodušení tvaru a byly od sebe odděleny přemostěné části segmentů. Po aplikaci této procedury však již neplatí podmínka minimální velikosti segmentu. Dále uvádíme segmentace pokusných výřezů v software DEFINIENS eCognition (obr. 15 až 17). Segmentace v tomto profesionálním programu poskytuje bezesporu lepší výsledky, neboť segmentační proces pracuje s větším množstvím informace v obraze, mimo jiné též s popisem tvaru vytvářeného segmentu a zpracovává texturu.

DISKUSE




Algoritmus je i nadále vyvíjen. Vývoj je nyní směřován zejména k schopnosti rozlišení textur a vý-

znamu předzpracování dat. K rozlišení textur předpokládáme jako stěžejní popis velikosti (hrubosti) textury, kterou lze zjistit z dostatečně velké množiny drobných segmentů (viz metodika), která byla doposud pokládána za samostatný objekt s texturou, bez ohledu na rozmístění velikostí těchto segmentů. Předzpracování vstupních dat Gaussovým filtrem umožňuje potlačit detaily v obraze a výsledné segmenty pak lépe vystihují základní rysy obrazu. Rovněž se tato úprava jeví vhodná pro následné odlišení různých textur, neboť dochází ke zjednodušení rysů v textuře a k částečnému vyrovnání velikostí skladebných homogenních plošek textury. Jak již bylo uvedeno, segmentační algoritmus je velmi závislý na znalosti zpracovávaných dat. Tento přístup bude i nadále upřednostňován jako základ, do budoucna



14: Výsledek segmentace pro maximální odchylku hodnoty od průměru 18, minimální velikost segmentu 428 pixelů a bez morfologické transformace (data WorldView PAN 0,5 m)

14: Result of segmentation with max. pixel-value deviation from mean 18, min. size of segment 428 pixels and without a morphological transformation (WorldView PAN 0,5 m)



15, 16 a 17: Výsledky segmentací v software DEFINIENS eCognition pro faktory scale 50, shape 0,1, compactness 0,5, smoothness 0,5 (data IKONOS PAN 1 m)

15, 16 and 17: Results of segmentations in DEFINIENS eCognition software with scale factor 50, shape factor 0,1, compactness factor 0,5 (IKONOS PAN 1 m)

bude ale vhodné vstupní parametry též zobecnit, např. zadáním relativní hodnoty homogenity. Rovněž lze navrhnout speciální nastavení parametrů dle převládajícího povrchu na snímku, a tedy větší specializaci algoritmu na potřeby odlišení kategorií

krajinného pokryvu. Do budoucna je též třeba uvažovat o zapojení více kritérií do procesu segmentace, zejména pak stanovení jejich vah. To se týká zejména vztahu mezi velikostí segmentu a jeho odlišností od segmentů okolních.

SOUHRN

Příspěvek stručně popisuje vyvíjený algoritmus segmentace obrazu na bázi růstu oblastí, implementačně závislý na GIS GRASS a GNU/Linux, který, jak doufáme, bude užitečný pro objektový přístup klasifikací v tomto svobodném GIS. Program v jazyce C++ využívá GIS GRASS spíše podpůrně, zejména co se týče zajištění vstupního formátu dat algoritmu a import výsledku segmentace. Algoritmus vytváří nejdříve homogenní plošky podle kritéria maximální odchylky hodnoty pixelu od průměrné hodnoty pixelů segmentu a tyto plošky pak dále zpracovává podle kritéria minimální velikosti segmentu, přičemž vnikají homogenní segmenty (dostatečně velké homogenní plošky) i segmenty s texturou (shluky malých homogenních plošek). Výstup segmentace lze upravit operátory matematické morfologie, s využitím uživatelsky definovaného strukturního elementu. Algoritmus je navržen na zpracování panchromatických dat s velmi vysokým prostorovým rozlišením a zejména s cílem odlišit jednotlivé složky krajinného pokryvu. Program je uvolněn pod licencí GNU/GPL a nadále vyvíjen. Vývoj nyní sleduje zejména potřebu odlišení jednotlivých typů textury a použití předzpracování dat s ohledem na cíl segmentace.

segmentace obrazu, GIS GRASS, C++, GNU/GPL

SUMMARY

This paper describe development of segmentation algorithm based region growing that is dependent on GIS GRASS and GNU/Linux. We expect, that this algorithm will be usefull to object-oriented image classification with free software GRASS. C++ program uses GIS GRASS to creation of needed data format and to import result of segmentation. Algorithm first creates homogeneous components according maximum standard deviation parameter and then this components are processing according to parameter of minimum size of segment. Results of this process are homogeneous segments or segment with texture (cluster of segments smaller than parameter of minimum size of segment). Result of segmentation can be modified with using operators of Mathematical morphology. Users must define structuring element. The algorithm is designed to processing of panchromatic data with a very fine resolution. Principial aim is differentiation of main categories of land cover. The Program is released under the GNU/GPL and its development is continued. Now is development of algorithm oriented to differentiate texture types and to data preprocessing with regard to target of segmentation.

Tento příspěvek byl řešen v rámci grantového projektu 51/2008 Interní grantové agentury LDF MZLU v Brně. Děkuji Interní grantové agentuře LDF MZLU v Brně za poskytnutí finančních prostředků.

LITERATURA

- FRULLA, J. L. L., 1998: *An automated region growing algorithm for segmentation of texture regions in SAR images*. International Journal of Remote Sensing, Vol. 19, No. 18, pp. 3595–3606. ISSN 0143-1161.
- HLAVÁČ, V., ŠONKA, M., 1992: *Počítačové vidění*. Grada, Praha. ISBN 80-85424-67-3.
- HAY, G. J., CASTILLA, G., WULDER, M. A. and 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*, Vol. 7, pp. 339–359. ISSN: 0303-2434.
- NETELER, M., MITASOVA, H., 2008: *Open Source GIS A GRASS GIS Approach*, 3rd ed. Springer, NY, USA, 406 pp. ISBN 978-0-387-35767-6, p. 326–328.
- SCHNEIDER, W., STEINWENDER, J., 1999: Land-cover mapping by interrelated segmentation and classification of satellite images. *International Archives of Photogrammetry and Remote Sensing*, Vol. 32, Part 7-4- W6.
- RICO E. C., MASEDA, R. C., 2009: *An alternative approach to object oriented classification of historical black & white aerial photographs using GRASS GIS and R*. Dostupné z: <http://laborate.usc.es/files/an-alternative-approach-to-object-oriented-classification-of-historical-black-white-aerial-photographs-using-grass-gis.pdf>, [cit. 14. 12. 2009].
- eCognition: object oriented image analysis: user guide* [online]. Dostupné na: http://www.rstc.msstate.edu/wfd/ecog/User_Guide/index.htm. [cit. 14. 12. 2009].

Adresa

Ing. Aleš Tippner, Ústav geoinformačních technologií, Mendelova zemědělská a lesnická univerzita v Brně, Zemědělská 1, 613 00 Brno, Česká republika, e-mail: xtippner@node.mendelu.cz

