

UNIVERZITA KARLOVA V PRAZE
Přírodovědecká fakulta
Katedra aplikované geoinformatiky a kartografie



**ROZPOZNÁVÁNÍ A KLASIFIKACE
POLYGONÁLNÍCH STRUKTUR MRAZOVÝCH
KLÍNŮ Z DAT DPZ**

**RECOGNITION AND CLASSIFICATION OF PATTERNED
GROUND POLYGONS FROM REMOTE SENSING DATA**

Diplomová práce

Bc. Jan Kříž

srpen 2013

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

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně a že jsem všechny použité prameny řádně citoval.

Jsem si vědom toho, že případné použití výsledků, získaných v této práci, mimo Univerzitu Karlovu v Praze je možné pouze po písemném souhlasu této univerzity.

Svoluji k zapůjčení této práce pro studijní účely a souhlasím s tím, aby byla řádně vedena v evidenci vypůjčovatelů.

V Praze dne 23. srpna 2013

.....
Jan Kříž

Poděkování

Na tomto místě bych rád poděkoval vedoucí mé práce Ing. Markétě Potůčkové, Ph. D. za čas strávený připomínkováním mé práce, za poskytnuté rady a trpělivost. Dále bych chtěl poděkovat rodině za podporu v průběhu celého studia a Janě Spáčilové za oporu v závěrečné fázi vypracování mé práce.

Rozpoznávání a klasifikace polygonálních struktur mrazových klínů z dat DPZ

Abstrakt

Hlavním cílem práce je ověření možnosti použití objektové klasifikace při identifikaci polygonálních struktur mrazových klínů a nalezení obecné metodiky klasifikace. V práci je porovnáván objektový přístup s přístupem pixelovým. V práci byly připraveny klasifikační báze OBIA pro tři snímky senzoru HiRISE z lokalit polygonálních struktur na Marsu a byl vytvořen obecný postup pro tvorbu takovýchto klasifikačníchází. Jako referenční data jsou použity polygony manuálně vektorizované podle postupů běžných v geomorfologickém výzkumu. V případě všech tří lokalit byl výsledek objektové klasifikace přesnější oproti pixelové klasifikaci, která poskytla relevantní výsledky pouze v případě jedné lokality. Dalším cílem práce je automatizace procesu získání informace o morfometrických charakteristikách polygonů a následná klasifikace polygonů podle těchto charakteristik. V rámci této automatizace byly navrženy postupy tvorby polygonové sítě a stanoveny doporučené parametry algoritmů, z kterých se postup skládá. Tyto postupy byly realizovány díky vytvořeným nástrojům („toolboxům“) pro software ArcGIS, které jsou jedním z výstupů této práce.

Klíčová slova: strukturní půdy, mrazové polygony, DPZ, OBIA, HiRISE

Recognition and classification of patterned ground polygons from remote sensing data

Abstract

The main objective of this thesis has been to prove the possibility of using object based image analysis classification for identification of the ice-wedge polygons and to find general method for their classification. The thesis contains a comparison of the object based and pixel based classification of the subject. The three classification rulesets for OBIA were developed on three test sites on Mars captured by HiRISE sensor. As a result, the general classification approach is suggested. The manually collected datasets, which are common in geomorphological research, were used as the reference sample. The OBIA classification provided better results in all three cases, whereas the pixel classification was valid in only one case. Another objective has been the automatization of the process of gaining information about morphometric characteristics of the ice-wedge polygons and the subsequent classification of the polygons. Within the scope of the process were developed methods for creating polygonal network and specified parameters of those methods. Several toolboxes for the ArcGIS software were prepared and they are part of the results of the thesis.

Keywords: patterned ground, ice-wedge polygons, remote sensing, OBIA, HiRISE

OBSAH

OBSAH.....	5
SEZNAM OBRÁZKŮ A TABULEK	8
1 Úvod.....	9
1.1 Motivace.....	9
1.2 Cíle práce	10
2 Úvod do problematiky	11
2.1 Princip fungování dálkového průzkumu	11
2.1.1 Rozlišení dat DPZ.....	13
2.2 Přístupy ke klasifikaci dat dálkového průzkumu	14
2.2.1 Pixelová klasifikace	15
2.2.2 Objektově orientovaná analýza obrazu.....	16
2.3 Využití dat DPZ při geomorfologickém výzkumu.....	21
2.3.1 Polygonální struktury mrazových klínů na Zemi	22
2.3.2 Polygonální struktury na Marsu.....	23
3 Metodika	25
3.1 Použitá data	25
3.1.1 Data na Marsu - HiRISE.....	25
3.1.2 Data na Zemi.....	27
3.2 Použitý software.....	27
3.3 Výběr území	28
3.4 Zpracování obrazu.....	31
3.4.1 Filtrace obrazu	31
3.4.2 Klasifikace k-means.....	33
3.4.3 Objektová klasifikace	36
3.4.4 Manuální vektorizace.....	39
3.4.5 Hodnocení přesnosti	40
3.5 Klasifikace polygonálních struktur mrazových klínů	40
3.5.1 Morfometrické charakteristiky polygonů	41
3.5.2 Automatické nalezení průsečíků ohraničení polygonů.....	42
3.5.3 Automatická tvorba polygonové sítě	47
3.5.4 Vypočet statistik polygonové sítě.....	49

4	Výsledky	51
4.1	Lokalita A.....	51
4.2	Lokalita B.....	54
4.3	Lokalita C.....	57
4.4	Souhrnné výsledky	59
5	Diskuse.....	61
5.1	Automatizace klasifikace půdních polygonů	61
5.2	Přenositelnost navržené metodiky.....	63
5.2.1	Pozemská data aktivních polygonálních struktur mrazových klínů	64
5.2.2	Fosilní polygonové struktury v Česku	64
6	Závěr	67
	SEZNAM ZDROJŮ INFORMACÍ	68
	SEZNAM PŘÍLOH.....	72

PŘEHLED POUŽITÝCH ZKRATEK A POJMŮ

DPZ	dálkový průzkum země (ve smyslu <i>remote sensing</i> , tedy nejen na Zemi)
GIS	geografický informační systém
HiRISE	High Resolution Image Science Experiment – senzor snímající povrch Marsu
IRB	pořadí spektrálních pásem snímků HiRISE (infra-red – red – blue-green)
Jpeg2000	standard pro kompresi obrazu publikovaný Joint Photographic Experts Group
MRO	Mars Reconnaissance Orbiter – družice nesoucí senzor HiRISE
OBIA	objektově orientovaná analýza obrazu (object based image analysis)
PDS	Planetary data system – archiv dat Národního úřadu pro letectví a kosmonautiku získaných při kosmickém výzkumu
Polygon	polygonem jsou v textu nazývány vektorové objekty georeferencované vrstvy v rámci programového prostředí GIS
Polygonální struktury	skutečné útvary na povrchu planety, které jsou patrné na obrazových (rastrových) datech
RGB	barevný model RGB (red – green – blue)

SEZNAM OBRÁZKŮ A TABULEK

Obrázek 1: Schéma fungování DPZ	11
Tabulka 1: Dělení elektromagnetického spektra	12
Tabulka 2: Barvy viditelného záření.....	13
Obrázek 2: Obrazové objekty při zpracování rastrových dat	17
Obrázek 3: Chessboard segmentace	18
Obrázek 4: Quadtree segmentace	18
Obrázek 5: Princip multiresolution segmentace	19
Obrázek 6: Parametry multiresolution segmentace	20
Obrázek 7: Ukázka aplikace klasifikačních pravidel.....	21
Tabulka 3: Parametry sensoru HiRISE.....	26
Obrázek 8: Umístění zpracovávaných snímků na povrchu Marsu	29
Obrázek 9: Scény HiRISE s vyznačenými pokusnými plochami.....	30
Tabulka 4: Zpracovávané pokusné plochy	31
Obrázek 10: Porovnání originálního a filtrovaného obrazu.....	32
Tabulka 5: Zvolené parametry low pass medián filtrace pro jednotlivé snímky.....	32
Obrázek 11: Porovnání originálních a filtrovaných vstupních dat	33
Obrázek 12: Výstupy pixelové klasifikace – lokalita A	34
Obrázek 13: Nastavení morfologického filtru	35
Obrázek 14: Pixelová klasifikace – lokalita B.....	36
Obrázek 15: Průběh objektové klasifikace	38
Obrázek 16: Ukázka manuálně vektorizovaných polygonů	39
Obrázek 17: Morfometrické charakteristiky polygonu.....	41
Obrázek 18: Nástroj pro automatizovaný zisk průsečíků ohraničení polygonů	43
Obrázek 19: Princip fungování algoritmu pro hledání průsečíků.....	44
Obrázek 20: Problematická místa při určování průsečíků	45
Obrázek 21: Šířka ohraničení polygonu	46
Tabulka 6: Přehled parametrů pro automatické nalezení průsečíků polygonů.....	46
Obrázek 22: Automaticky vytvořená polygonální síť	48
Obrázek 23: Opravená geometrie polygonální sítě.....	49
Obrázek 24: Nástroj pro automatické doplnění statistik polygonové sítě	50
Graf 1: Lokalita A – histogram polygonů podle počtu hran.....	52
Graf 2: Lokalita A – histogram polygonů podle míry pravidelnosti	53
Graf 3: Lokalita A – histogram polygonů podle plochy	54
Graf 4: Lokalita B – histogram polygonů podle počtu hran	55
Graf 5: Lokalita B – histogram polygonů podle míry pravidelnosti.....	56
Graf 6: Lokalita B – histogram polygonů podle plochy	57
Graf 7: Lokalita C – histogram polygonů podle počtu hran	58
Graf 8: Lokalita C – histogram polygonů podle míry pravidelnosti.....	58
Graf 9: Lokalita C – histogram polygonů podle plochy	59
Graf 10: Porovnání relativního zastoupení n-hranných polygonů mezi lokalitami.....	60
Obrázek 25: Fosilní polygonální struktury u Kostomlat pod Řípem.....	64
Obrázek 26: Území s prokázanými fosilními polygonálními strukturami	65

1 Úvod

Metody dálkového průzkumu země (dále DPZ) mají nenahraditelnou roli v mnoha oblastech poznání o Zemi. V současnosti jsou pro civilní výzkum dostupné snímky s dostatečným prostorovým rozlišením pro nové aplikace v přesném výzkumu, který byl doposud omezen na jiné (konvenční, tj. *in situ*) postupy.

Mezi časté předměty výzkumu patří vegetační poměry, jejich změna a dílčí strukturní a druhová skladba nebo např. půdní poměry a jejich změny. Skrze dlouhodobý sběr dat je možné sledovat vývoj zkoumané vlastnosti povrchu s ohledem na měnící se globální systém. Mezi nejvýznamnější změny systému patří vývoj podnebí na globální i lokální úrovni a změny související s lidskou aktivitou. Mimo civilní výzkum je dálkového průzkumu země hojně využíváno v ložiskové geologii při hledání nových zdrojů surovin. V těchto oborech se v současné době dostaly do popředí oblasti hůře dostupné a dříve pro výzkum nerentabilní. Často jde o území ve vysokých zeměpisných šířkách, daleko od lidského osídlení a postrádající základní infrastrukturu. V těchto podmínkách je DPZ často prvotním zdrojem dat. V civilním výzkumu však tyto oblasti nebyly a do jisté míry stále nejsou běžným objektem zájmu studií s daty vysokého prostorového rozlišení.

V těchto oblastech lze pozorovat mnohé probíhající (recentní) jevy, které utváří určité krajinné složky a tyto jevy popsat. Mezi takovéto jevy patří mrazové klíny vytvářející za běžných periglaciálních podmínek půdní mrazové polygonální struktury v permafrostu s obvyklou velikostí od 5 do 50 metrů (Ballantyne, 2007). Ty vznikají periodickým působením mrazu v důsledku tepelné roztažnosti půdy a jejích částic (Murton, 2007). Aktivní polygony se liší mimo jiné objemem vody v různých svých částech.

Obdobné struktury byly pozorovány i na Marsu (např. Mangold, 2005), kde se další průzkum soustřeďuje na možnou spojitost vzniku struktur s výskytem vody. V případě výzkumu polygonálních struktur na Marsu se využívají pouze prostředky DPZ. S dostupností dat odpovídajícího prostorového rozlišení vznikají komparační studie marsovských a pozemských polygonálních struktur (Ulrich, Hauber, Herzsuh, Härtel, & Schirrmeister, 2011).

1.1 Motivace

Procesy vzniku a vývoje aktivních polygonů jsou předmětem výzkumu především na Sibiři v oblasti delty Leny (Grosse et al., 2007; Langer, Westermann, & Boike, 2010). Na Katedře fyzické geografie a geoekologie se zájem upírá především na kanadské lokality (Kysilka, 2009). Mimo základní poznání procesů vytváření tvarů zemského povrchu v recentních podmínkách je důvodem výzkumu poznání těchto procesů pro paleogeografické vyhodnocení fosilních půdních mrazových polygonů z pozdního pleistocénu na našem území.

Pro automatizaci procesu se jeví být perspektivní přístup objektové klasifikace. Tento přístup byl doposud spíše využíván pro rozpoznávání zástavby a lidského osídlení. Současní

autoři, kteří se primárně zabývají výzkumem půdních polygonů, využívají data DPZ k vizuální interpretaci. Kysilka ve své práci přímo zmiňuje objektovou klasifikaci jako jednu z možností přínosu DPZ pro geomorfologický výzkum (Kysilka, 2009). Při rešerši dostupných dat a metodických postupů lze nalézt použití objektové klasifikace např. pro klasifikaci lesních porostů. Pro zkoumání polygonálních struktur jak na Marsu, tak na Zemi však tato metoda doposud nebyla použita.

1.2 Cíle práce

Diplomová práce se zaměřuje na poskytnutí metodiky pro automatizaci úkonů s obrazovými daty, které se dále používají v geomorfologickém a navazujícím výzkumu. Současná praxe je založena na manuálním zpracování těchto dat. To poskytuje pro daný účel dostatečnou přesnost. Manuální zpracování je však časově náročné a neumožňuje zkoumat rozsáhlejší datové sady.

Hlavním cílem práce je ověření možnosti použití metodiky objektové klasifikace pro identifikaci jednotlivých polygonů v polygonálních strukturách na Marsu a její porovnání s klasickým přístupem pixelové klasifikace.

Dalším cílem je zpracování dat získaných klasifikací obrazu v rámci GIS tak, aby bylo možné s polygony dále pracovat a klasifikovat je automatickým procesem podle popisných charakteristik (počet stran polygonů, poměr délky os polygonů a další veličiny obvyklé v geomorfologickém výzkumu).

První část diplomové práce je věnována obecnému úvodu do principů DPZ a jsou popsány jednotlivé klasifikační metody s důrazem na možnost použití při řešení cílů práce. Stěžejní část práce je věnována popisu metodiky, která byla v rámci práce použita. V závěru je zhodnocena možnost zobecnění metodiky, která je v diplomové práci ověřována na třech lokalitách na Marsu.

2 Úvod do problematiky


„Dálkový průzkum je věda i umění získávat užitečné informace o objektech, plochách či jiných jevech prostřednictvím dat měřených na zařízení, která s těmito zkoumanými objekty, plochami či jevy nejsou v přímém kontaktu.“ (Lillesand & Kiefer, 1994)

2.1 Princip fungování dálkového průzkumu

Z definice uvedené výše vyplývá, že pro realizaci DPZ je třeba prostředník, který dokáže informaci přenést mezi zkoumaným objektem a senzorem v měřicí aparatuře. Takovým prostředníkem je obvykle elektromagnetické pole, resp. záření. V obecné rovině lze k přenosu použít i jiná silová pole, např. tíhové pole v případě gravimetru. Nejrozšířenějším prostředkem dálkového průzkumu jsou oči, které jsou citlivé na určitou část spektra – takzvanou viditelnou oblast elektromagnetického záření. Fyzikálním jevem, na kterém je celý proces dálkového průzkumu založen, je interakce elektromagnetického záření se zkoumaným látkovým objektem (Kolář, 1990). Informaci o průběhu interakce nese energie záření šířícího se po interakci a následně zaznamenaná detektorem na určených vlnových délkách.

Dálkový průzkum můžeme rozdělit do několika na sebe navazujících dějů, které jsou schematicky zobrazené na Obrázek 1.

Obrázek 1: Schéma fungování DPZ



A – zdroj záření, B – elektromagnetické záření, C – zkoumaný povrch, D – měřicí aparatura, E – přenos naměřených dat, F – zpracování naměřených dat, G – interpretace dat
Zdroj: CCRS, 2007

Velikost měřené veličiny závisí především na zdroji záření (A). Tím může být nejčastěji Slunce, těleso samotné nebo v případě aktivních senzorů samotné zařízení instrumentu

dálkového průzkumu (anténa radaru). Tyto zdroje vysílají elektromagnetické záření (B), které interaguje se zkoumaným povrchem (C). Měřicí aparatura (D) zaznamenává energii záření odraženého nebo vyzářeného zkoumaným povrchem. Typy senzoru se podle svých parametrů a schopností zaznamenat určitý rozsah elektromagnetického záření pojmenovávají jako skenery, radiometry, fotografické kamery, radary, spektrometry. Senzory bývají umístěny na různých nosičích – např. umělých družicích, letadlech či balónech. Z nich se data přenáší (E) do přijímací stanice. Následně se data ve specializovaných softwarech zpracovávají (F) a interpretují (G).

Elektromagnetické záření je charakteristické svou vlnovou délkou (resp. frekvencí). Kontinuum souhrnně označované jako elektromagnetické spektrum dělíme podle vlastností, obvyklého výskytu a podmínek, za kterých se záření o určitých vlnových délkách vyskytuje, do několika kategorií (viz Tabulka 1).

Tabulka 1: Dělení elektromagnetického spektra

Záření	Vlnová délka [m]
Kosmické (gama)	$< 3 \cdot 10^{-11}$
Rentgenové	$3 \cdot 10^{-11} - 3 \cdot 10^{-7}$
Ultrafialové	$3 \cdot 10^{-7} - 38 \cdot 10^{-8}$
Viditelné	$38 \cdot 10^{-8} - 72 \cdot 10^{-8}$
Infračervené	$72 \cdot 10^{-8} - 3 \cdot 10^{-3}$
Mikrovlnné	$3 \cdot 10^{-3} - 3 \cdot 10^{-1}$
Radiové	$\geq 3 \cdot 10^{-1}$

Zdroj: Kolář, 2008; Campbell & Randolph, 2011

Dálkový průzkum nejčastěji užívá záření v rozmezí od ultrafialového až po mikrovlnné. Ultrafialové záření se využívá v geologických aplikacích díky specifickému chování určitých minerálů, k detekci ropných skvrn či ložisek kovů. V atmosféře však dochází k jeho rozptylu, proto je jeho užití omezené.

Viditelné záření, které pokrývá relativně úzkou část elektromagnetického spektra, je velmi významné ze dvou důvodů. Prvním je ten, že se v oblasti viditelného světla nachází maximum vyzařování Slunce, existuje tedy velmi silný přirozený zdroj záření. Zároveň záření z této oblasti elektromagnetického spektra dobře prostupuje zemskou atmosférou. Dobrá prostupnost atmosférou činí tuto oblast vhodnou i pro dálkový průzkum. Spektrum viditelného záření je spojité a jednotlivé intervaly vlnových délek vnímáme jako různé spektrální barvy (viz Tabulka 2).

Tabulka 2: Barvy viditelného záření

Barva	Vlnová délka [μm]
Fialová	0,400 - 0,446
Modrá	0,447 - 0,500
Zelená	0,501 - 0,578
Žlutá	0,579 - 0,592
Oranžová	0,593 - 0,620
Červená	0,621 - 0,700

Zdroj: Kolář, 1990

Základními spektrálními barvami jsou postupně od nejkratší vlnové délky modrá, zelená a červená. Jejich skládáním lze získat ostatní barvy spektra. Tohoto principu se využívá při digitální reprodukci obrazu – např. v barevných obrazovkách. Každý obrazový bod se skládá ze zářičů tří vlnových délek (R – červená, G – zelená, B – modrá), které současným vyzářováním o dané intenzitě tvoří barevný obraz. Vjem barev je stejný, přestože energeticky spektrum takového objektu není spojitě (na rozdíl od spektra ideálního zářiče, za který v tomto kontextu můžeme považovat Slunce). Stejný přístup z druhé strany je často využíván senzory dálkového průzkumu, které jsou citlivé na konkrétní intervaly vlnových délek. Data z těchto intervalů jsou mapována na barevný model RGB pro zpětnou reprodukci dat. Pokud měřené intervaly vlnových délek odpovídají barvám modelu RGB, mluvíme o zobrazení v *pravých barvách*. Pokud měření proběhlo v jiných intervalech, hovoříme o zobrazení v *nepravých barvách*.

Oblast infračerveného záření je poměrně široká a dělí se na pět podkategorií. Přestože se v tomto intervalu vlnových délek objevují absorpční pásy atmosféry, zemskou atmosférou prostupuje většina podkategorií poměrně dobře. Blízké infračervené záření (NIR, 0,72 μm – 1,3 μm) s nejkratší vlnovou délkou je důležité při studiu vegetace. Ta v této části spektra vykazuje různou odrazivost podle svého organického stavu. NIR je proto stěžejní pro aplikace v oblasti kvantifikace biomasy, klasifikace různých vegetačních typů a podobně. Záření s krátkou vlnovou délkou (SWIR, 1,3 μm – 3 μm) se nejčastěji používá pro detekci sněhu a vody. Infračervené záření střední vlnové délky (MWIR, 3 μm – 8 μm) a dlouhé vlnové délky (LWIR, 8 μm – 15 μm) nachází aplikace při sledování tepelných bilancí povrchů. Vzdálené infračervené záření (FIR, 15 μm – 3000 μm) zemskou atmosférou neprostupuje, proto se v DPZ obvykle neuplatňuje (CCRS, 2007).

Delších vlnových délek (mikrovlny) využívají v dálkovém průzkumu radary, které patří mezi aktivní senzory – tedy záření vysílají a následně zaznamenávají jeho odrazy.

2.1.1 Rozlišení dat DPZ

Veškerá data dálkového průzkumu mají určitou přesnost, kterou můžeme chápat jako rozpoznatelnou škálu hodnot určité vlastnosti. U dat dálkového průzkumu obvykle hovoříme o rozlišení dat. Základními typy rozlišení jsou prostorové, spektrální, časové a radiometrické.

Tato rozlišení jsou spolu svázána fyzikálními vlastnostmi senzoru, a proto je výsledné rozlišení senzoru v různých typech rozlišení výsledkem kompromisu.

Prostorové rozlišení udává velikost nejmenšího objektu, který lze v obraze rozpoznat. V případě digitálního obrazu se termín prostorové rozlišení používá pro velikost jednoho obrazového bodu (pixelu), přestože velikost pixelu nemusí odpovídat skutečnému prostorovému rozlišení. To bývá negativně ovlivněno úhlem pořízení scény a aktuálními atmosférickými podmínkami. Naopak některé kontrastní objekty reálně menších rozměrů než odpovídá jednomu pixelu lze v datech stále rozpoznat. Míra prostorového rozlišení senzoru je svázána nepřímou úměrou s velikostí scény. V obecném případě pak máme na výběr snímky z většího území s menším prostorovým rozlišením nebo snímky vysokého prostorového rozlišení z menšího území. Data DPZ se obvykle podle prostorového rozlišení dělí na data malého prostorového rozlišení (rozlišení řádově km), data středního prostorového rozlišení (řádově stovky metrů), data vysokého prostorového rozlišení (řádově desítky metrů) a data velmi vysokého prostorového rozlišení v řádu jednotek metrů (Gisat, 2013).

Spektrální rozlišení udává počet a šířku intervalů vlnových délek, které senzor zaznamenává. Větší šířka intervalu vlnových délek zvyšuje citlivost senzoru, zároveň však stírá rozdíly v chování povrchu v rámci daného intervalu. Pokud je měřicí aparatura schopna zaznamenat více intervalů vlnových délek, mluvíme o datech multispektrálních. Pokud počet intervalů dosahuje desítek, označují se data jako hyperspektrální.

Časové neboli temporální rozlišení udává, v jakém časovém rozestupu jsou opakovaně získávána data z jednoho území. Toto rozlišení je úzce navázáno na velikost snímané scény. Časové rozlišení se také může lišit podle zeměpisné šířky zájmového území a záleží na parametrech oběžné dráhy družice.

Radiometrické rozlišení je dáno senzitivitou senzoru a udává počet rozlišitelných úrovní elektromagnetického signálu na jednom prvku senzoru. Rozsah hodnot je udáván v mocninách dvou, přičemž každá hodnota odpovídá určitému stupni šedi. 8bitové rozlišení kanálu znamená, že daný kanál dokáže rozlišit 256 úrovní signálu.

2.2 Přístupy ke klasifikaci dat dálkového průzkumu

Klasifikací obrazu je rozuměno rozřazení jednotlivých obrazových prvků do informačních tříd. Původní hodnoty obrazových objektů jsou nahrazovány novými hodnotami, jež zachycují příslušnost k určité kategorii (Dobrovolný, 1998). Touto operací dojde k vytěžení dat a jejich přeměně na informace. Klasifikace je prováděna na základě hodnocení podobnosti jednotlivých prvků. Vlastnosti, které jsou pro rozhodování o míře podobnosti použity, se uvádějí jako *rozhodovací pravidla*. Samotný algoritmus rozřazení prvků na základě rozhodovacích pravidel do jednotlivých tříd se nazývá klasifikátor. Ten ze všech vstupů po vyhodnocení poskytne jeden výstup. Může jít o přiřazení prvku do konkrétní třídy či stanovení prvku jako neklasifikovaného (pokud to daný klasifikátor umožňuje).

Jako rozhodovací pravidla mohou sloužit různé vlastnosti prvků obrazu. Nejčastější je spektrální chování prvku, které je přímo zaneseno v hodnotách vstupních dat. Mezi odvozené spektrální vlastnosti patří různé spektrální indexy (poměry daných spektrálních tříd). V případě multitemporálních dat mohou být sledovány změny prvku v čase. K velmi významným charakteristikám patří prostorové chování prvků, např. vzájemná vzdálenost, texturní příznaky, velikost, tvar a kontext.

2.2.1 Pixelová klasifikace

Základním obrazovým prvkem je pixel. Ten je tradičně vstupem do klasifikátorů a k němu jsou vztahována jednotlivá rozhodovací pravidla. Tento přístup je starší a je tak nyní k dispozici více metod pixelové klasifikace s mnoha aplikacemi v různých oblastech výzkumu. V běžných algoritmech se používají téměř výhradně rozhodovací pravidla založená na spektrálních charakteristikách pixelu. V závislosti na okamžiku, kdy do klasifikace vstupuje výzkumník, rozdělujeme klasifikaci na neřízenou a řízenou.

2.2.1.1 Neřízená klasifikace

Tyto metody mají na vstupu obvykle přesný či alespoň přibližný počet cílových tříd v obraze. Následně je spuštěn matematický proces shlukové analýzy. Na základě statistického rozdělení pixelů v příznakovém prostoru algoritmus přiřadí pixely do jednotlivých tříd. Předpokladem je, že pixely odpovídající jedné třídě jsou ve vícerozměrném příznakovém prostoru blízko sebe. Interpretace těchto objektivně a statisticky rozlišitelných shluků je na výzkumníkovi. Výhodou těchto metod jsou nižší nároky na znalost informace na počátku procesu a rychlost jejich vyhodnocení. K běžně používaným a v softwarech dostupným algoritmům patří metoda *k-means clustering* a *ISODATA* (Repaka, Truax, State, Kolstad, & Manager, 2004).

K-means clustering patří k algoritmům, kde na začátku musí být pevně určen počet shluků. Může být vhodným algoritmem, pokud je dopředu znám počet tříd v obraze a tyto třídy jsou statisticky odlišitelné. Na počátku jsou náhodně zvoleny středy shluků a podle vzdálenosti jsou mezi ně prvky roztrženy. Následuje výpočet středů (těžišť) nových shluků a opakované roztržení prvků do shluků. Algoritmus je ukončen, pokud při výpočtu nových středů shluků nedojde k jejich změně, případně při překročení stanovených omezení běhu algoritmu (počet opakování, prahová hodnota pro změnu středu shluků).

ISODATA je komerční algoritmus, který je rozšířením metody *k-means clustering*. Algoritmus umožňuje v průběhu iterací měnit shluky – heterogenní shluky se rozpadnou a blízké shluky se sloučí. Shluky s malým počtem pixelů se rozpadnou a pixely jsou přiřazeny do ostatních shluků (Repaka et al., 2004).

2.2.1.2 Řízená klasifikace

V případě řízené klasifikace je nutný vstup výzkumníka ještě před samotným započítáním klasifikace, a to ve formě trénovacích ploch (vzorků), které tvoří tolik trénovacích množin,

kolik je požadovaných tříd. V principu nejprve výzkumník definuje třídy, mezi kterými daný klasifikátor rozdělí jednotlivé prvky obrazu. Vzorok se obvykle stanoví ze známých dat – terénního průzkumu, vizuální interpretace či z mapových podkladů. V případě pixelové klasifikace se jako příznaky obvykle používají spektrální charakteristiky pixelů. Řízená klasifikace je náročnější na vstup výzkumníka, ale obvykle přináší přesnější výsledky.

Minimum distance to means je jednoduchým klasifikátorem, který pro každou trénovací množinu vypočte v příznakovém prostoru těžiště a následně rozdělí všechny prvky obrazu k nejbližšímu těžišti.

Parallelepiped neboli klasifikační *metoda rovnoběžníků* je výpočetně velmi rychlá, ale dochází v ní často k nejednoznačným výsledkům. Principem metody je vytvoření (hyper)kvádrů v příznakovém prostoru, které obalují trénovací množiny. Prvky obrazu jsou přiřazeny do třídy podle toho, v kterém (hyper)kvádru se nachází. Běžně však dochází k tomu, že se (hyper)kvádry překrývají anebo se některé pixely nenachází v žádném z (hyper)kvádrů.

Maximum likelihood či česky *metoda maximální věrohodnosti* spočívá na odhadu neznámých veličin v závislosti na trénovacích datech. Předpokládá se, že pixely v jednotlivých třídách mají normální n-rozměrné rozdělení. Následně se vypočítá pravděpodobnost příslušnosti klasifikovaného pixelu do jednotlivých tříd a klasifikace je provedena na základě nejvyšší dosažené hodnoty.

Bayesův klasifikátor je rozšířením metody maximální věrohodnosti. Zavádí celkovou pravděpodobnost výskytu určité třídy v prostoru. Pravděpodobnost je určena na počátku výzkumníkem, ví-li například, že zalesněna je třetina zkoumaného území. Použitím Bayesovy věty z teorie pravděpodobnosti pak klasifikátor dopočítá konečnou pravděpodobnost příslušnosti pixelu do dané třídy.

2.2.2 Objektově orientovaná analýza obrazu

Objektově orientovaná analýza obrazu (neboli object based image analysis – OBIA) je poměrně nový přístup ke zpracování digitálního obrazu. Základní změnou oproti pixelovému přístupu je vytvoření objektů jako základních prvků obrazu. V objektovém přístupu se nevyhodnocují jednotlivé pixely uměle vytvořené senzorem. Podobně jako v lidském mozku dochází k vyhodnocování příbuzných skupin obrazových bodů společně. Tyto obrazové objekty mají další charakteristiky, které pixelům chybí. Jde především o velikost, tvar, texturu a další kontextuální informace (Gisat, 2013). Tento přístup získal popularitu díky dostupnosti dat velmi vysokého rozlišení. Dochází tak k situaci, ve které je jeden reálný objekt (ohrazení polygonu, strom, budova) tvořen více pixely, které mají obdobné spektrální charakteristiky. V dálkovém průzkumu dříve převládala situace, kdy jeden pixel byl často složen z působení několika objektů reálného světa (takové pixely byly někdy nazývané mixely).

Objektově orientované zpracování obrazu lze provádět i v 3D prostředí formou skládání jednotlivých řezů 3D objektů. Tato technologie se rozvíjí v lékařských vědách při vytváření digitálních 3D modelů lidského těla a jeho orgánů.

Obrázek 2: Obrazové objekty při zpracování rastrových dat



Zdroj: vlastní šetření autora

Předpokladem k OBIA je vytvoření homogenních objektů v procesu segmentace obrazu. Obrazové objekty tvoří vlastní vrstvu (úroveň) v obraze (image object level). Mezi těmito objekty jsou vyhodnocovány vztahy v horizontální úrovni vůči ostatním obrazovým objektům. Zároveň je ale možné tvořit více obrazových úrovní s odlišnou mírou generalizace (viz Obrázek 2). Při segmentaci platí, že hranice nadřazených objektů (super objects) jsou zděděny z úrovní nižších (sub objects). Díky tomu lze do analýzy přidat i další (vertikální) vztahy.

2.2.2.1 Segmentace obrazu


Prvním a klíčovým krokem při objektově orientované analýze obrazu je segmentace. Cílem je získat obrazové skupiny pixelů (obrazové objekty) reprezentující skutečné objekty. Limitními příklady segmentace je rozpad obrazu na jednotlivé pixely a na druhé straně celý obraz jako jediný obrazový objekt. Pro základní segmentaci platí pravidlo, že by objekty měly být tak malé, aby byly pro daný účel přijatelně homogenní a zároveň co největší, aby se s nimi lépe a efektivněji pracovalo a daly se zkoumat prostorové vztahy mezi objekty.

Při segmentaci se podle zvoleného algoritmu také přihlíží k prostorovým charakteristikám objektů (tvar, velikost) či texturálním příznakům. Všechny typy segmentace vedou k zobecnění informací o objektu – místo hodnot jednotlivých pixelů může být brána v potaz průměrná hodnota i např. medián, minimum apod.

Existuje několik segmentačních algoritmů, které můžeme rozdělit do kategorií podle jejich přístupů. Top-down algoritmy vycházejí z nejvyšší úrovně obrazu či právě segmentovaného objektu, který postupně dělí. Mezi takové algoritmy patří například Chessboard segmentace, Quadtree segmentace, Contrast filter segmentace či Contrast split segmentace (Trimble, 2012a)

Chessboard segmentace je nejjednodušší z algoritmů, který daný obraz či objekty určené k další segmentaci dělí podle zadaného parametru do sítě čtvercových segmentů o stejné velikosti (viz Obrázek 3). Vzhledem k jednoduchosti a rychlosti může být tento algoritmus využit zejména při sekundární segmentaci objektů dané třídy pro zajištění srovnatelné velikosti segmentů.


Obrázek 3: Chessboard segmentace



Zdroj: Trimble, 2012a

Quadtree segmentace je algoritmus, který dělí obraz či dané objekty do čtvercových elementů. Tyto elementy mohou mít ve výsledku různou velikost. Obraz se nejprve rozdělí na sadu čtverců (počet záleží na poměru stran obrazu a zadaném parametru segmentace). Ty jsou porovnávány s kritériem spektrální homogenity v rámci každého čtverce. Pokud toto kritérium není splněno (čtverec je příliš heterogenní), rozdělí se na čtyři menší čtverce. Tyto čtverce jsou opět porovnávány s kritériem homogenity. Algoritmus probíhá do té doby, než všechny čtverce splní kritérium homogenity (viz Obrázek 4).

Obrázek 4: Quadtree segmentace



Zdroj: Trimble, 2012a


Quadtree segmentace produkuje v homogenních oblastech obvykle větší objekty než v oblastech heterogenních. Z pohledu spektrální homogenity produkuje objekty podle zadaných parametrů, tedy zcela podle požadavků výzkumníka. Neřeší však tvar objektů (vždy jde o čtverce) a ani situaci, ve které je objekt reálného světa rozpůlen v předchozí iteraci, přestože by v rámci segmentace měl být ideálně reprezentován jedním výsledným obrazovým objektem.

Opačný přístup nabízejí *bottom-up* algoritmy, které vycházejí z nižší úrovně, tj. na počátku z jednotlivých pixelů. Ty jsou v rámci algoritmu posuzovány a za určitých podmínek dochází k jejich sloučení do elementů. Tento proces se opakuje s dočasnými obrazovými elementy, dokud není dosažena zadaná prahová hodnota. Dočasné elementy z poslední iterace se stávají výslednými obrazovými objekty. Uvedený přístup lze opakovaně použít i pro posuzování a další slučování obrazových objektů (ať již v rámci jedné obrazové vrstvy nebo jako nástroj pro vytvoření vrstvy nadřazené).

Multiresolution segmentation algoritmus je velmi úspěšným zástupcem bottom-up přístupů k segmentaci popsaným autory Baatz & Schäpe (2000). Algoritmus je optimalizační procedurou, která pro daný počet obrazových objektů minimalizuje průměrnou heterogenitu mezi objekty a maximalizuje homogenitu objektů samotných (Trimble, 2012b).

Segmentace testuje každý prvek (tj. na nejnižší úrovni pixel) a hledá, který ze sousedů je podle zadaných kritérií nejpodobnější. Pro tohoto nejpodobnějšího souseda je poté proveden stejný test. Takto proces pokračuje, dokud není nalezen prvek, který jako nejpodobnější označí prvek předcházející, neboli jsou si dva prvky vzájemně nejpodobnější. Princip je graficky znázorněn na Obrázek 5. Pokud je splněno kritérium homogenity vyplývající z parametrů segmentace, dojde ke spojení dvou vzájemně podobných prvků.

Obrázek 5: Princip multiresolution segmentace



Zdroj: Trimble, 2012b

Mezi parametry multiresolution segmentation patří měřítkový (scale) parametr, který omezuje maximální možnou velikost objektu vytvořeného segmentací. Parametr určuje maximální možnou směrodatnou odchylku vypočtené homogenity potenciálních objektů ke sloučení. Čím větší je hodnota tohoto parametru, tím spíše vznikají větší objekty.

Samotná homogenita je veličinou složenou ze tří složek, přičemž jejich váhy jsou stanoveny parametry segmentace.

Barva (colour) popisuje spektrální charakteristiku a homogenost objektů. V rámci algoritmu lze měnit váhy jednotlivých složek zpracovávaného obrazu (spektrálních pásem).

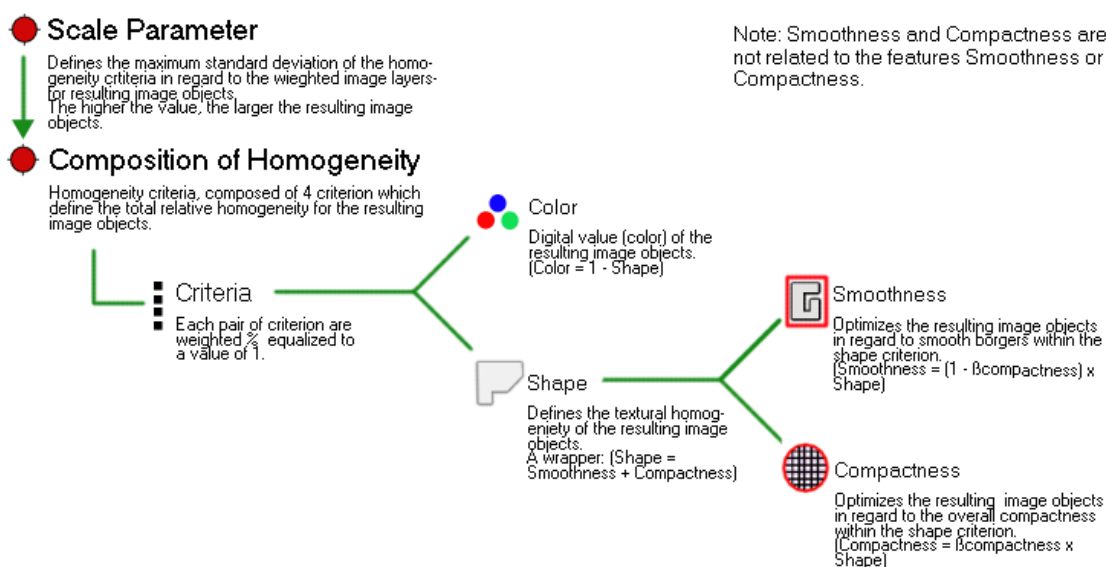
Doplňkovým parametrem k barvě je tvar (shape). Součet jejich vah je vždy 1, proto se v nastavení segmentace v softwaru eCognition zadává pouze hodnota parametru tvar. Tento parametr je sám tvořen dvěma podřízenými parametry – kompaktností a hladkostí.

Kompaktnost je odchylkou od kompaktního tvaru a je stanovena jako poměr obvodové délky hraniční linie objektu ku počtu pixelů tvořících objekt.

Hladkost je kritériem tvarové homogenity a jde o poměr obvodové délky hraniční linie objektu a nejkratší délky obvodu čtyřúhelníku opsaného obrazovému objektu paralelně k obrazovému rastru (Bromová, 2012).

Kompaktnost a hladkost opět dávají v součtu jedna. V nastavení segmentace se opět objevuje pouze položka kompaktnost. Nepoučený uživatel tak může nabýt dojmu, že nastavuje dva nezávislé parametry – tvar a kompaktnost. Ve skutečnosti je systém složitější. Grafický přehled použitých parametrů poskytuje Obrázek 6.

Obrázek 6: Parametry multiresolution segmentace



Zdroj: (Trimble, 2012b)

S libovolně zvolenou velikostí obrazových objektů dosahuje multiresolution segmentation dobrých výsledků jak v rámci generovaných tvarů, tak spektrální homogenity objektů. Multiresolution segmentation je však výrazně náročnější na paměť a výpočetní výkon než ostatní zde popsané algoritmy, proto nemusí být vždy nejlepší volbou (Trimble, 2012b).

2.2.2.2 Klasifikace obrazových objektů

Klasifikace v OBIA je zařazováním jednotlivých objektů do tříd, které popisují sémantický význam objektů (Horňáková, 2011). V rámci objektového přístupu implementovaného v softwaru eCognition mohou být třídy seskupeny hierarchicky (viz Obrázek 7 B). Jeden objekt může patřit do více tříd různé hierarchické úrovně. To umožňuje stanovování podmínek a zkoumání prostorových a kontextuálních vztahů mezi jednotlivými objekty v daných třídách.

„Jelikož je segmentace obdobná konstrukci databáze s informacemi o každém obrazovém objektu, může být klasifikace nahlížena jako výsledek určitého databázového dotazu“ (Tilton, 1999).

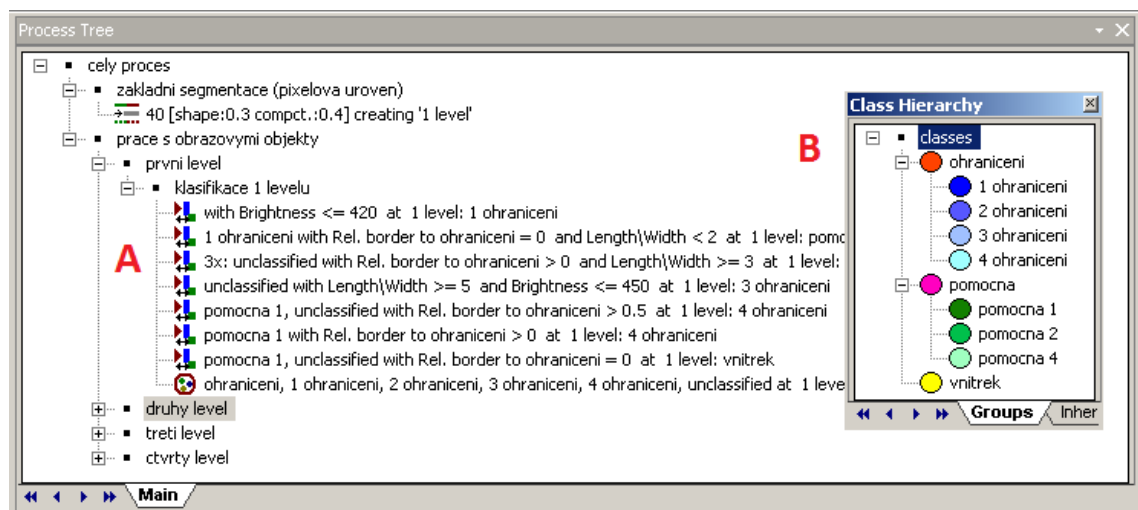
Klasifikaci lze aplikovat dvěma rozdílnými způsoby – fuzzy klasifikací a metodou rozhodovacího stromu.

Fuzzy klasifikace je svou podstatou měkkým klasifikátorem a vytváří hodnoty pro jednotlivé objekty s pomocí míry jejich shody s jednotlivými třídami podle zadaných vstupních informací. Vstupní informace jsou obvykle určeny na základě trénovací množiny objektů a stanovením kritérií, které se v rámci klasifikace použijí. V softwaru eCognition je implementována klasifikace Nearest Neighbour. U ní je třeba stanovit vstupní parametry – vlastnosti objektů, které jsou brány v potaz (tvoří příznakový prostor) a jejich váhy. Samotné hodnoty jsou kalkulovány z trénovací množiny. Fuzzy klasifikace je vhodná v případech více klasifikovaných tříd, kdy nejsou hranice jasně definované. V takových případech vede použití prahových hodnot k idealizaci reálného světa, což způsobuje problémy při klasifikaci (Benz, Hofmann, Willhauck, Lingenfelder, & Heynen, 2004).

V popisu tříd lze kombinovat různé podmínky pro přiřazení objektů do dané třídy vedle klasifikátorů jako Nearest Neighbour.

Metoda rozhodovacího stromu využívá konkrétní hodnoty přiřazené objektům (spektrální, prostorové, kontextuální atp.) jako prahové hodnoty pro zařazení do tříd. Prahové hodnoty lze různě kombinovat a v rámci vykonávaných procesů stanovovat podmínky (IF-ELSE). Lze také využívat iterační postupy a jednotlivé třídy dále dělit či překlasifikovávat (viz Obrázek 7 A). Největší výhodou této klasifikace je nezávislost na rozložení dat a rychlé zpracování multidimenzionálních datových sad obsahujících vyšší počet příznaků (Ke, Quackenbush, & Im, 2010).

Obrázek 7: Ukázka aplikace klasifikačních pravidel



Zdroj: vlastní šetření autora, software eCognition

2.3 Využití dat DPZ při geomorfologickém výzkumu

Výzkum v oblasti DPZ je úzce spjat s rozpoznáváním vzorů v získaných datech. Obecná problematika rozpoznávání vzorů a výzkumná témata DPZ se překrývají, jak dokládá speciální

číslo časopisu *Pattern Recognition Letters* (Aksoy, Younan, & Bruzzone, 2010). Mezi častá vědecká témata patří klasifikace lidského osídlení. Výzkumů zabývajících se polygonálními strukturami v periglaciálním prostředí je podstatně méně.

V současnosti se výzkum této problematiky ubírá dvěma hlavními směry. V souvislosti s globálními klimatickými změnami se zvýšená pozornost věnuje procesům v tundře, zejména dynamice vývoje permafrostu ve vztahu k toku energie a látek. Ve výzkumu se využívá pozemních měření dat DPZ. Ty umožňují zhodnotit výsledky experimentu v širším rozsahu.

Ulrich et al. (2011) porovnávali polygonální struktury Marsu a Špicberků. Využili snímky s vysokým rozlišením (HiRISE, resp. HRSC-AX) a měli k dispozici stereosnímky, což jim umožnilo vytvořit digitální model reliéfu (DEM). Polygony byly následně manuálně digitalizovány a podrobeny prostorové analýze v softwaru ArcGIS a autoři následně prováděli numerickou analýzu (Ulrich et al., 2011).

Obdobný problém s rozpoznáváním a klasifikací polygonů v obraze řeší různé aplikační obory využívající dat DPZ. Myint et al. (2011) ukázal, že při zpracování dat vysokého a velmi vysokého rozlišení lze dosáhnout lepších výsledků na základě objektového přístupu ke klasifikaci obrazových dat než klasickým přístupem po pixelech (Myint et al., 2011). Tento závěr činí nad daty městské zástavby, ze kterých jsou jasně patrné tvary/polygony a kde podle jeho tvrzení nese více informací prostorová než spektrální složka dat.

Využití objektového přístupu k identifikaci polygonů v obraze je v popředí zájmu výzkumníků několik posledních let (Blaschke, 2010). Tyto metody se aplikují na zkoumání zástavby ze snímků vysokého prostorového, ale omezeného spektrálního rozlišení. Například na snímcích z družice SPOT5 byla objektovou klasifikací zkoumána sídelní kaše (urban sprawl) na ostrově Reunion (Durieux, Lagabrielle, & Nelson, 2008). Objevují se i práce se zaměřením na identifikaci polygonů objektovým přístupem v lesním porostu na snímcích z družice Quickbird (Mallinis et al., 2008) či práce zaměřené na identifikaci zelené a usychající vegetace z lokálně pořízených fotografií (Lalibertet et al., 2007).

Poměrně nově se metodika objektové klasifikace objevuje ve vyhodnocování DEM vysokého rozlišení pro archeologické (Verhagen & Drăguț, 2012) a geomorfologické mapování (Drăguț et al., 2011).

Díky pokroku v kosmických technologiích a dostupnosti snímků s vysokým rozlišením lze studovat struktury na povrchu Marsu a jejich analogie na Zemi. Polygony jsou vhodným indikátorem probíhajících i minulých procesů v prostředí – zejména klimatu a hydrologie. Možnost snadné detekce metodami DPZ přináší rozvoj tohoto tématu, protože jiné než distanční zkoumání není v případě Marsu možné.

2.3.1 Polygonální struktury mrazových klínů na Zemi

Metody DPZ se pro výzkum polygonů začaly využívat s rozšiřováním možností snímkování s dostatečným prostorovým rozlišením. Vzhledem k tomu, že oblasti rozšíření aktivních polygonů jsou obvykle vzdálené od osídlených oblastí, dostupnost přesných dat z leteckého

snímkování je nižší. Boike popisuje zkušenosti s vlastním snímáním pomocí balónu (Boike & Yoshikawa, 2003). S družicovými daty DPZ se již dlouho provádí výzkum v oblasti změn krajinného pokryvu tundry. Stow et al. použil data ze senzorů NOAA Advanced Very High Resolution Radiometer (AVHRR) pro studii, která ukazuje změny v NDVI za 20 let a dokazuje nárůst primární produkce ekosystémů (Stow et al., 2004). Přímou polygonálními strukturami se zabýval Hjort a Luoto při výzkumu možnosti modelování rozšíření polygonů v Laponsku. Z kontrolních dat získaných leteckým snímáním definují dva typy polygonů podle homogenity substrátu (netříděné – polygon je vytvářen vegetací; a tříděné – polygon se mimo jiné vyznačuje vytříděním substrátu podle velikosti částic) a následně porovnávají modely rozšíření vytvořené na základě topografických dat a na základě dat z Landsatu 7 ETM. Ukazují, že nejlepší modely vznikají kombinací obou datasetů, přičemž přínos dat DPZ je vyšší v případě netříděných polygonů (Hjort & Luoto, 2006).

Langer et al. zkoumal vliv prostorové heterogenity polygonální tundry na měření průměrné teploty povrchu senzory s nižším prostorovým rozlišením (MODIS) pomocí termálního snímání v terénu. Autoři popisují vývoj povrchových teplot v polygonech v oblasti delty Leny na Sibiři a ukazují, že pro průměrování v delším období než jsou denní cykly, jsou dostupná data DPZ dostatečná. Problém je s častým výskytem oblačnosti a v případě přítomnosti většího počtu malých otevřených vodních ploch (Langer et al., 2010). Stejný výzkumný tým se zabýval možnostmi přesného určování krajinného pokryvu v polygonální tundře. Došel k závěru, že je třeba prostorové rozlišení minimálně 4 m pro identifikaci plošek přítomných v polygonální tundře. Proto konstatuje, že snímání pomocí senzorů CHRIS/PROBA a LANDSAT není dostatečné pro postihnutí těchto polygonů. Spolu s provedenými terénními měřeními navrhuje způsoby odhadu poměrů těchto elementů v mixelech, konstatují však, že jsou velmi závislé na specifických spektrálních charakteristikách povrchu plošek menších než je rozlišení senzoru (Muster et al., 2012)

2.3.2 Polygonální struktury na Marsu

Ve vysokých zeměpisných šířkách Marsu byly polygonální struktury popsány a klasifikovány ze snímků senzoru vysokého rozlišení Mars Orbiter Camera (MOC) – typicky 1,5 – 12 m/pixel – z let 1997 až 2006. Byly identifikovány na mnoha snímcích ze senzoru HiRISE. Přehled známých lokalit podává Levy et al., identifikující snímky od 30° zeměpisné šířky výše (J. Levy, Head, & Marchant, 2009).

Různí autoři se věnovali popisu polygonů a jejich srovnání s polygonálními útvary na Zemi (J. S. Levy, Marchant, & Head, 2010; Mangold, 2005).

Vybrané snímky z MOC byly použity k prozkoumání možnosti prostorové analýzy bodů (průsečíků polygonů) metodou nejbližšího souseda. Prostorové vztahy popsané touto metodou mohou odrážet vliv klimatu, za kterého polygony vznikají nebo substrát ve kterém vznikají (Dutilleul, Haltigin, & Pollard, 2009). Tyto metody byly dále rozpracovány jako spatial point pattern analysis a byla zkoumána míra chyby při použití dat z různých senzorů. V oblasti

polygonálních struktur v Kanadě bylo kombinací dat z terénního měření diferenciální GPS, leteckého snímkování a družicových dat ukázáno, že pro tento druh analýzy jsou vhodná data s rozlišením lepším než 1 m (Haltigin, Pollard, & Dutilleul, 2010), což v současnosti splňují pouze snímky ze sensoru HiRISE. Ve stejné práci byla porovnávána data marsovského povrchu ze sensoru MOC a HiRISE (senzor s prostorovým rozlišením 0,25 – 0,32 m/pixel) a bylo navrženo, aby se pro výzkum na Marsu používaly pokud možno jen data ze sensoru HiRISE.

Levy et al. zkoumal reliéf marsovských polygonů za různého oslunění a zejména data získaná při bočním oslunění s malým úhlem dopadajících paprsků odhalila morfometrickou závislost polygonů na zeměpisné šířce. S ní také souvisí odhadované stáří polygonů, které se s rostoucí zeměpisnou šířkou snižuje (J. S. Levy et al., 2010). Marsovskému prostředí se na Zemi nejvíce blíží suchá mrazová poušť v Antarktidě. Díky možnosti terénního výzkumu mohl Hallet et al. ověřovat možnost numerických modelů pro vývin mrazových klínů tvořících polygony v suché mrazové poušti (Hallet, Sletten, & Whilden, 2011).

3 Metodika

Tato práce navazuje na výzkumy v oblasti geomorfologie, fyzické geografie, které pracují s daty dálkového průzkumu.

Pro otestování automatizace tvorby podkladů je nutné zvolit reprezentativní data, která jsou bohužel omezena svou dostupností. Vzhledem k obtížné dostupnosti pozemských dat především kvůli finančním omezením se tato práce zaměřuje na zpracování dat z volně dostupných snímků Marsu. Na něm byly zvoleny tři reprezentativní scény, které byly dále zpracovávány. Nejprve došlo na úrovni snímků ke klasifikaci jednotlivých polygonů vybranými metodami. V dalším kroku byla z klasifikace vytvořena polygonální síť v GIS, v rámci které byly zjišťovány statistické informace o polygonech obdobně jako v běžném geomorfologickém výzkumu.

3.1 Použitá data

Pro identifikaci polygonů mrazových klínů je nejzásadnější prostorové rozlišení. Geomorfologický výzkum se v souvislosti s daty DPZ soustředí především na morfometrické charakteristiky polygonů a jejich vzájemné vztahy. Průměrná velikost polygonů je různá. Pro rozpoznání polygonové sítě je důležité především ohraničení polygonů. To může mít různý fyzický charakter podle typu polygonu (příkopy s vodou, vyzdvižené násypy s hrubším či naopak jemnějším substrátem, jiný typ vegetace spojený především s jiným vodním režimem vnitřku polygonu a ohraničení). Šířka ohraničení bývá řádově menší, než je samotná velikost polygonu. To znamená, že i pro polygony v řádech desítek metrů je pro úspěšnou klasifikaci potřeba dat velmi vysokého rozlišení. Jako primární zdroj dat v této práci byl zvolen senzor HiRISE (High Resolution Image Science Experiment) na palubě družice MRO (Mars Reconnaissance Orbiter), který nabízí dostatečné rozlišení a širokou dostupnost dat.

3.1.1 Data na Marsu - HiRISE

HiRISE navazuje na sensor předcházející generace – MOC (Mars Orbiter Camera). Ten poskytoval panchromatické snímky s prostorovým rozlišením 1,4 m/pixel a snímky v pásmech modré a červené barvy, které ale s prostorovým rozlišením začínaly na 230 m/pixel (Malin et al., 2010). Pro výzkum polygonálních struktur na Marsu byly použitelné pouze panchromatické snímky, které posloužili například pro první srovnání polygonů s pozemskými analogiemi (Mangold, 2005). Dané rozlišení však v mnoha případech nebylo zcela dostatečné.

Senzor HiRISE poskytuje rozlišení 30 cm/pixel, přičemž snímá povrch Marsu z výšky přibližně 300 km. Přesná vzdálenost se liší podle výškového profilu snímaného území na Marsu. Senzor je složen z 14 CCD zaznamenávající signál soustředěný ze zrcadla s průměrem 50 cm. 10 CCD je opatřeno červeným filtrem a poskytují data v červeném pásmu vlnových délek. Po dvou CCD je opatřeno filtrem 1) na pomezí modré a zelené barvy a 2) v oblasti blízkého infračerveného záření. Aparatura je sestavena tak, že povrch Marsu snímá v pruhu zhruba 6 km

širokém, přičemž prostřední 1,2 km je snímáno ve třech popsanych spektrálních pásmech (Eliason, Castalia, Leis, & Becker, 2007). Základní charakteristiky senzorů HiRISE jsou uvedeny v Tabulka 3.

Tabulka 3: Parametry sensoru HiRISE

Parametr	Hodnota	Poznámka
Výška orbity	300 km	
Prostorové rozlišení	30 cm/pixel	při snímání z výšky 300 km
Aparatura teleskopu	0.5 m, f/24	
Spektrální pásma	400 - 600 nm	modro-zelené (BG)
	550 - 850 nm	červené (RED)
	800 - 1000 nm	blízké infračervené (NIR)
Odstup od šumu (signal to noise ratio)	typicky 100:1	modro-zelené pásmo
	typicky 200:1	červené pásmo
	typicky 100:1	blízké infračervené pásmo
Šířka scény	>6 km	červené pásmo
	>1.2 km	modro-zelené a infračervené pásmo
Délka scény	>2x šířka scény	ve směru letu
Radiometrické rozlišení	14 bit	12 - 13 bit efektivně
Datové úložiště	28 Gbits	sdílené pro všechny pásma
Šířka scény v pixelech	20264	červené pásmo
	4048	modro-zelené a infračervené pásmo
Zorné pole (FOV)	1.14° x 0.18°	
Nejmenší měřitelný objekt (IFOV)	1 x 1 μrad	

Zdroj: NASA/JPL/University of Arizona

Data ze senzoru jsou volně dostupná z webového archivu na adrese <http://www.uahirise.org/>. Archiv nabízí široké spektrum dostupných dat. Je možné získat zcela nezpracovaná originální data, v terminologii archivu „Experimental data records“ nebo scény s určitým stupněm úprav a korekcí neboli „Reduced data records“. Pro tuto práci byla použita data po provedené radiometrické korekci, která má za cíl odstranit artefakty, vliv senzoru a především konvertuje naměřené hodnoty zisku senzoru na odrazivost. Procedura radiometrické korekce je podrobně popsána v technické specifikaci programu HiRISE (Eliason et al., 2011).

Z archivu je možné získat snímky georeferencované. Pro snímky z polárních oblastí je použito polární stereografické zobrazení („Polar stereographic“) a pro snímky v nižších zeměpisných šířkách je použita ekvidistantní válcová projekce („Equirectangular“) s variabilními parametry zobrazení pro minimalizaci zkreslení obrazu. Přesné parametry jsou vždy uvedeny pro jednotlivé snímky.

Snímky jsou dostupné v bezztrátové verzi formátu jpeg2000, který byl schválen jako standard pro výměnu dat NASA v rámci Planetary Data System (PDS), který zajišťuje archivaci dat získaných při misích v Sluneční soustavě (Eliason et al., 2011). Stažené snímky v tomto formátu byly importovány do softwaru ENVI, který ho podporuje. Následně byla data exportována ve formátu img, který byl použit pro provedení všech dalších operací.

3.1.2 Data na Zemi

Aktivní polygony jsou zkoumány na Sibiři a v Kanadě, kde se výzkumu účastní i Katedra fyzické geografie a geoekologie. Polygony v arktické oblasti Kanady jsou rozměrově větší, dosahují desítek metrů. Jde o v současnosti stále aktivní struktury v prostředí s dostatkem vody, v létě v kapalném stavu. Obsah vody se liší v jednotlivých částech polygonu. Pro geomorfologický výzkum na Katedře fyzické geografie a geoekologie byla doposud získávána prostorová data manuálním sběrem dat nad podklady z Google Earth.

Pro zpracování dat metodami DPZ je ve vyšších zeměpisných šířkách (60° - 80° severní z. š.) málo dostupných dat zdarma. Oblasti sběru dat s polygony zkoumanými v pracích na Katedře fyzické geografie a geoekologie nejsou pokryty vhodnými družicovými snímky. V katalogu ESA jsou dostupné pouze snímky z družice KOMSAT 2 jihokorejské kosmické agentury, které mají dostatečné prostorové rozlišení (4 m spektrální pásma, 1 m panchromaticky) a standardní spektrální rozlišení (B, G, R, IR), ale nepokrývají výběrové plochy geomorfologického výzkumu

V Česku lze nalézt fosilní polygony z pleistocénu, kdy na některých částech našeho území panovalo podnebí, které umožňovalo jejich vznik. V současnosti jsou polygony skryty pod zemským povrchem. Vzhledem k poloze v nižších nadmořských výškách jsou obvykle rozorány a nejsou lehce identifikovatelné. V některých případech však jsou patrné polygonální struktury díky odlišným vlastnostem vegetace (resp. spektrálních charakteristik vegetace) kopírující dané struktury pod povrchem. Dochází tak k jevu, který se využívá v archeologii při průzkumu pomocí leteckého snímkování. Rozměry fosilních polygonů jsou menší, v řádech jednotek až několik málo desítek metrů. Pro zpracování metodami DPZ je tedy třeba využít leteckých ortorektifikovaných snímků.

3.2 Použitý software

Pro získání dat byl použit volně šiřitelný nástroj HiView 1.3.2 poskytovaný University of Arizona jako nativní prohlížeč dat ze sensoru HiRISE. V tomto software byly prozkoumány kandidátské snímky a lokalizovány oblasti s polygony na Marsu. Stažené scény ve formátu jpeg2000 (jp2) byly zpracovány v softwaru ENVI 5.0 licencovaném PŘF UK. V něm byly vytvořeny pokusné části scén zpracovávané v této diplomové práci a uloženy do formátu img. V softwaru ENVI byly dále provedeny veškeré operace na pixelové úrovni (filtrace obrazu, pixelová klasifikace, morfologické operace).

Pro objektovou klasifikaci a následné zpracování byl použit software eCognition Developer ve verzi 8.7.2 od společnosti Trimble licencovaném na PřF UK. Výsledky klasifikací byly nahrány do softwaru ArcMap 10.1 z rodiny ArcGIS, taktéž s licenci PřF UK. V něm byla provedena manuální vektorizace pro vytvoření referenčních dat a vyhotoveny konečné mapové výstupy (viz přílohy 3 – 5). Pro automatizaci procesů v rámci ArcGIS byl použit doplněk Model builder. Kombinací předdefinovaných nástrojů ArcGIS a volně šiřitelných skriptů v jazyce Python z knihoven ESRI byly sestrojeny čtyři nástroje, které jsou přílohou této diplomové práce.

Závěrečné zpracování dat proběhlo v softwarech MS Office (Word, Excel) a grafickém programu Inkspace.

3.3 Výběr území

Polygonální struktury se na Marsu vyskytují v zeměpisných šířkách vyšších než 30° poměrně často. Jejich variabilita je dosti široká a to jak do tvaru, tak do velikosti polygonů, rozsahu pokrytého území i jejich vnitřní struktury. Snímky HiRISE jsou dostupné z webového katalogu, kde jsou snímky popsány a označeny výzkumnými tématy, k nimž jsou navrženy. Při výběru snímků byly sledovány především kategorie glaciálních/periglaciálních procesů a klimatické změny. V katalogu je u každého snímku náhled reprezentativní části území, podle kterého se dá provést první orientační výběr.


Vzhledem k cílům této práce bylo snahou vybrat lokality s navzájem rozdílnými charakteristikami polygonů. Po podrobnějším prozkoumání dostupných snímků v programu HiView byly vybrány tři lokality, jejichž rozmístění na planetě je zobrazeno na Obrázek 8.

Lokalita A na snímku ESP_016641_2500 (69,79° s. š. a 64,92° v. d.) zobrazuje dno kráteru, ve kterém se utvořily polygony o rozměrech cca 100 m. Ohraničení polygonů je velmi kontrastní, protože je tvořeno ledem, který uvnitř polygonů chybí. Vnitřní plocha polygonů je tvořena polygonálními strukturami nižšího řádu, jejichž velikost dosahuje jednotek metrů. Toto vnitřní, podstatně menší ohraničení je často nekompletní, tj. netvoří uzavřené polygony. Proto se práce zaměřuje na rozpoznání a klasifikaci pouze polygonů prvního řádu, které jsou jasně rozpoznatelné. Snímek má rozlišení 25 cm/pixel

Lokalita B na snímku ESP_032060_0970 (83,01° j. š. a 14,34° z. d.) se nachází nedaleko jižní polární čepičky a polygony také svými rozměry dosahují také cca 100 m. Hranice polygonů se jeví tmavé, oproti vnitřku, který je naplněn především zmrzlým CO₂ (Mellon, Feldman, & Prettyman, 2004). Vnitřek polygonů vykazuje poměrně vysoký efekt „pepř a sůl“. Snímek byl pořízen v období marsovského jižního léta. Rozlišení je poloviční oproti maximálnímu, tedy 50 cm/pixel.

Lokalita C na snímku PSP_007674_2240 (43,51 s. š. a 87,13° v. d.) se nachází na kraji plošiny Utopia a reprezentuje třetí vizuálně identifikovaný typ polygonů. Rozměrově jsou polygony srovnatelné s předchozími snímky, jejich ohraničení je však užší a více nepravidelné. Kontury se jeví oproti vnitřkům polygonů tmavší. Snímek má rozlišení 25 cm/pixel.

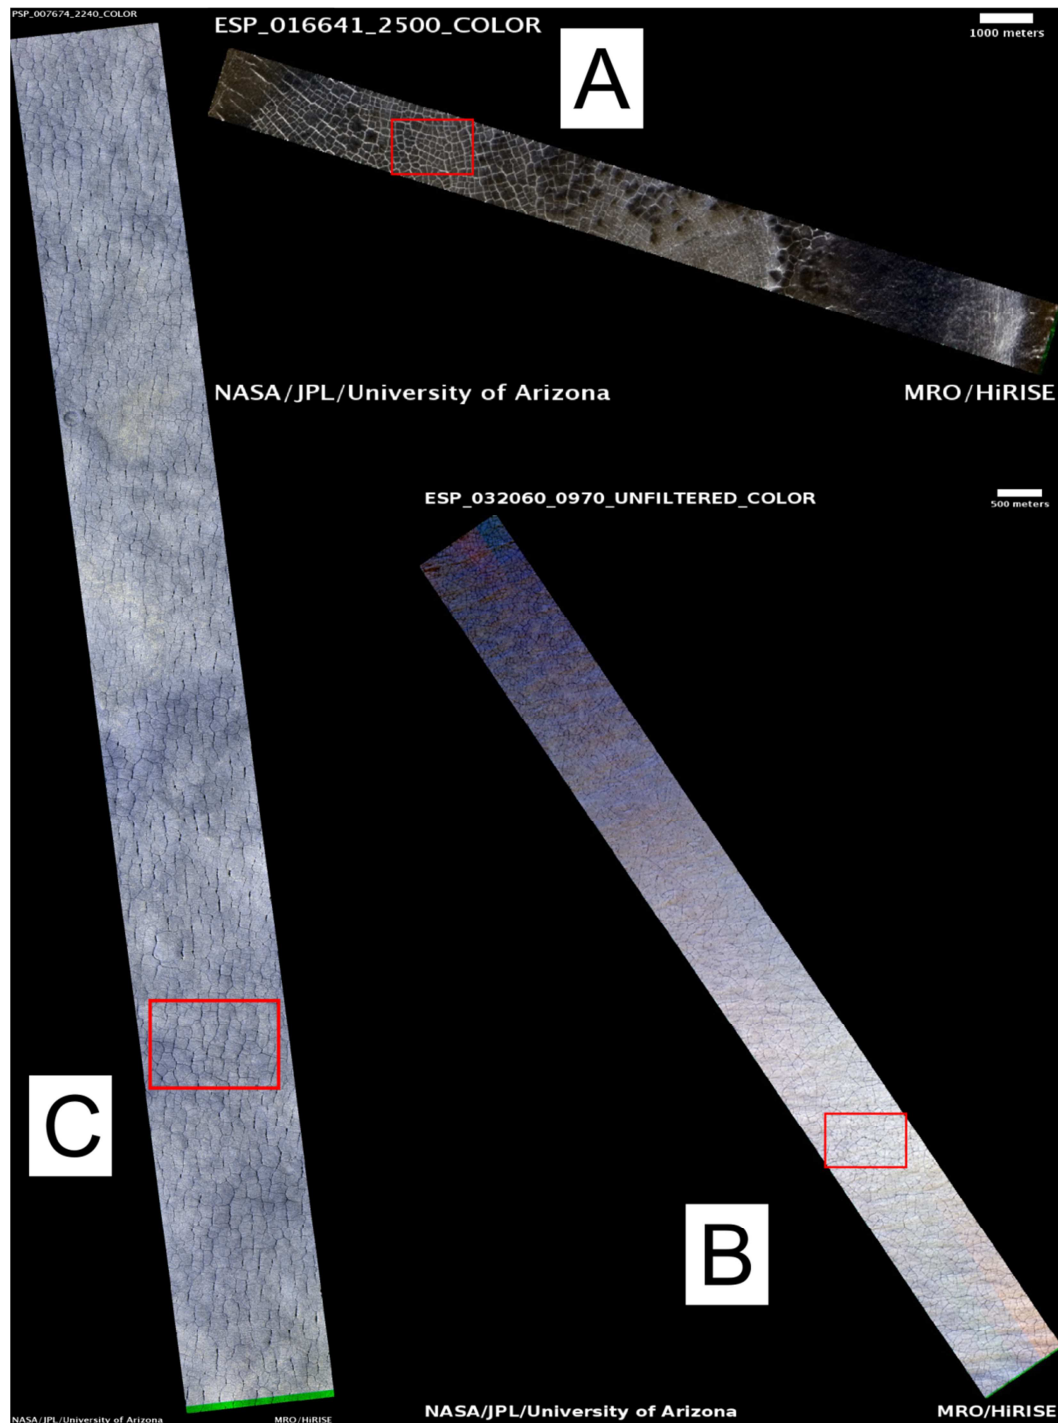
Obrázek 8: Umístění zpracovávaných snímků na povrchu Marsu



Umístění lokalita A (A), lokality B (B) a lokality C (C) na podkladu barevné hypsometrie Marsu
Zdroj: NASA / JPL / GSFC / Arizona State University

Z dostupných dat byly použity georeferencované snímky obsahující všechna tři spektrální pásma. Pro jejich zobrazení a veškeré výstupy byla spektrální pásma mapována posunem jednotlivých pásem do modelu RGB. Červeně se na výstupech v této práci zobrazuje infračervené pásmo obrazu, zeleně se zobrazují hodnoty naměřené v oblasti vlnové délky červeného světla a modře se zobrazují hodnoty naměřené v oblastech modro-zelené vlnové délky. Podle počátečních písmen měřených pásem (infra red, red a blue-green) je takovéto zobrazení uváděno jako IRB. Všechny snímky jsou tedy v nepravých barvách. Na zobrazovaná data bylo aplikováno lineární roztažení histogramu při ořezu 1% nejvíce a nejméně jasných pixelů pro vyšší kontrast a lepší čitelnost výstupů.

Obrázek 9: Scény HiRISE s vyznačenými pokusnými plochami



Kompletní scény nasnímané senzorem HiRISE s vyznačenými pokusnými plochami v lokalitě A (A), lokalitě B (B) a lokalitě C (C)
Zdroj: NASA/JPL/University of Arizona

Stažené scény byly velmi rozsáhlé pro pokusné zpracování (datově nejobsáhlejší scéna s lokalitou C dosahovala velikosti přes 500 MB v komprimované podobě formátu jpg2000). Vizualním posouzením byly vybrány oblasti scén s přítomností polygonů, protože zvláště scéna

s lokalitou A byla polygony pokryta pouze z části. Ve scéně s lokalitou B se projeví obrazové artefakty, způsobující nepřírodní zbarvení obrazu v počáteční a koncové části scény.

Vybrané části scén byly v softwaru ENVI exportovány s přesnými souřadnicemi, které jsou uvedeny v Tabulka 4. Soubory použité pro další analýzy jsou přiloženy na DVD, které je součástí této práce.

Tabulka 4: Zpracovávané pokusné plochy

Zdroj	Exportovaná část				Výsledná velikost				Výsledný soubor
	sloupce		řádky		sloupce		řádky		
	od [px]	do [px]	od [px]	do [px]	[px]	[m]	[px]	[m]	
PSP_007674_2240_COLOR.jp2	4800	9300	34300	37300	4500	1125	3000	750	PSP_007674_2240_COLOR_subset.img
ESP_016641_2500_COLOR.jp2	15500	20000	6700	9700	4500	1125	3000	750	ESP_016641_2500_COLOR_subset.img
ESP_032060_0970_COLOR.jp2	7400	8900	11000	12000	1500	750	1000	500	ESP_032060_0970_COLOR_subset.img

Zdroj: vlastní šetření autora

3.4 Zpracování obrazu

Vybrané snímky s polygonálními strukturami byly dále zpracovávány s cílem extrahovat informace o jednotlivých polygonech. Pro získání požadované informace je třeba polygony identifikovat, tj. klasifikovat v obrazu jednotlivé polygony a následně získat polygonální síť. Aby toho mohlo být dosaženo, je třeba nejenom rozpoznat plochu, která náleží vnitřku polygonu, a plochu, která přísluší ohraničení polygonu; také je třeba oddělit vnitřní plochy jednotlivých polygonů od sebe. Na vnitřky polygonů se tak můžeme dívat jako na objekty, které mají obvykle podobné spektrální vlastnosti a řádově stejnou velikost.

Pokud by ohraničení polygonu bylo v celé své délce dostatečně výrazné a dostatečně odlišné od vnitřku polygonů, byla by klasifikace a následná extrakce polygonu snadným úkolem. Za běžných podmínek však ohraničení často není dostatečně výrazné a minimálně lokálně splyvá s vnitřky polygonů. Zároveň do polygonů někdy vybíhají zárodečné mrazové klíny, či polygony vyššího řádu obsahují polygony menší, řádu sekundárního. Takovéto polygony nebývají plně vyvinuty a je obtížné je klasifikovat a identifikovat. Proto je práce zaměřena na klasifikaci a identifikaci zřetelných polygonů prvního řádu.

Sledovaný cíl v sobě nese požadavek na zahrnutí prostorových vztahů jednotlivých objektů (polygonů). To vede k logické úvaze, že pro zmíněnou úlohu je vhodná objektová analýza obrazu. Přesto byl obraz zpracováván i pixelovou metodou, která může být v kombinaci s následným zpracováním v GIS také použitelná.


3.4.1 Filtrace obrazu

Před započítím klasifikace obrazu může být účelné jeho předzpracování. Na snímcích se často vyskytují elementy, které efektivně tvoří ve vztahu k velikosti vnitřku polygonu a jeho

ohraničení efekt „sůl a pepř“. Tento efekt může mít negativní dopad především na pixelovou klasifikaci. Proto byl v práci zkoumán dopad předzpracování dat na konečný výsledek.

Pro odstranění vysokofrekvenčních efektů typu „sůl a pepř“ se používají nízkofrekvenční filtry (low frequency, neboli low pass filters – v této práci je užíváno termínu low pass, který je použit v softwaru ENVI). Principy fungování obrazových filtrů přehledně popisuje například Pikora (2008) ve své práci.

Obrázek 10: Porovnání originálního a filtrovaného obrazu



A – originální data, B-E – data po provedení filtrace funkcí medián s maskami různých velikostí (B – 9; C – 15; D – 23 a E – 27)

Zdroj: vlastní šetření autora, NASA/JPL/University of Arizona

Pro redukci efektu „sůl a pepř“ se používá funkce medián. Ta se pro tyto účely hodí mnohem více, než např. obyčejné průměrování (Pikora, 2008). Při aplikaci tohoto filtru jsou hodnoty pixelů pokrytých maskou seřazeny a výsledkem je prostřední hodnota.

Výsledky použití tohoto filtru jsou patrné na Obrázek 10, kde je znázorněn originální obraz (A) a postupně obraz po aplikaci filtru s čtvercovou maskou o rozměrech 9 (B), 15 (C), 23 (D) a 27 (E) pixelů.

Nad zkoumanými snímky byly provedeny filtrace s různým nastavením konvoluční masky. Následně byly orientačně provedeny další úkony navržené metodiky a vybrány nejnadějnější úrovně filtrovaných dat. Nastavení pro konkrétní snímky shrnuje Tabulka 5.


Tabulka 5: Zvolené parametry low pass medián filtrace pro jednotlivé snímky

Snímek	Parametry filtrace
Lokalita A	27
Lokalita B	9
Lokalita C	15

Zdroj: vlastní šetření autora, software MS Excel

S filtrovanými daty těchto vybraných parametrů pak byly provedeny všechny úkony společně s originálními daty. Vstupních obrazů do následných kroků metodiky bylo 6, jak je znázorněno na Obrázek 11 – originální data z lokality a (A) a jejich filtrovaný obraz (D); originální data z lokality B (B) a jejich filtrovaný obraz (E); originální data z lokality C (C) a jejich filtrovaný obraz (F).

Obrázek 11: Porovnání originálních a filtrovaných vstupních dat



A – originální data z lokality A, B – originální data z lokality B, C – originální data z lokality C,
D – filtrovaná data z lokality A, E – filtrovaná data z lokality B, F – filtrovaná data z lokality C
Zdroj: vlastní šetření autora, NASA/JPL/University of Arizona

Vzhledem k tomu, že po filtraci se efektivně nový obraz zmenší na každé straně o polovinu rozměru konvoluční matice (resp. v tomto pásu ohraničujícím celý obraz zůstanou nefiltrovaná data), pro všechny další kroky byl vstupní obraz o tyto pixely zmenšen.

3.4.2 Klasifikace k-means


Ke stěžejním částem metodiky patří klasifikace, tedy odlišení vnitřku polygonů od jejich ohraničení. Na rozdíl od klasifikace např. land use není nejdůležitější přesnost samotné klasifikace ve smyslu správně klasifikovaných pixelů. Cílem je získat polygony, které budou tvořit polygonální síť, tzn. půjde o oddělené a jednoznačně identifikované objekty, které sdílejí hranice (ohraničení polygonů) a u kterých se dají zkoumat další vlastnosti (tvar, velikost).

V případě pixelové klasifikace to znamená, že je třeba spojitě klasifikovat především ohraničení polygonů. Pokud v rámci klasifikace dostaneme nespojitě útvary třídy „vnitřek polygonu“, které svojí velikostí a tvarem budou odpovídat skutečnosti, pak po zpracování výsledné klasifikace v GIS a automatické vektorizaci lze dostat *de facto* jednotlivé objekty (polygony).

Vzhledem k relativně kontrastním obrazům a faktu, že výsledkem mají být pouze dvě třídy, byla použita klasifikační metoda k-means. V softwaru ENVI byly vyzkoušeny i jiné metody (maximum likelihood), ale výsledek byl pro účely dalšího zpracování obdobný. Proto byla generálně zvolena jednoduchá metoda k-means, která nevyžaduje sběr trénovacích ploch. V odůvodněných případech by řízená klasifikace pravděpodobně mohla výsledky zlepšit, zejména pokud by byly k dispozici další spektrální informace (např. snímky na Zemi s vegetací a vegetačními indexy).

Výsledky klasifikace v případě nefiltrovaných dat nebyly pro další zpracování v rámci navržené metodiky použitelné (viz Obrázek 12 A). Zejména z důvodu, že na pixelové úrovni zpracování dat nelze jednoduše pracovat s prostorovou informací a okolím pixelu (na rozdíl od obrazových objektů). Nelze tedy provést další kroky k získání jednotlivých polygonů jako samostatných objektů odpovídajících rozměrů a tvaru.

Obrázek 12: Výstupy pixelové klasifikace – lokalita A



A – klasifikace nad nefiltrovanými daty, B – klasifikace nad filtrovanými daty, C – klasifikace nad filtrovanými daty po provedení morfologické operace uzavření

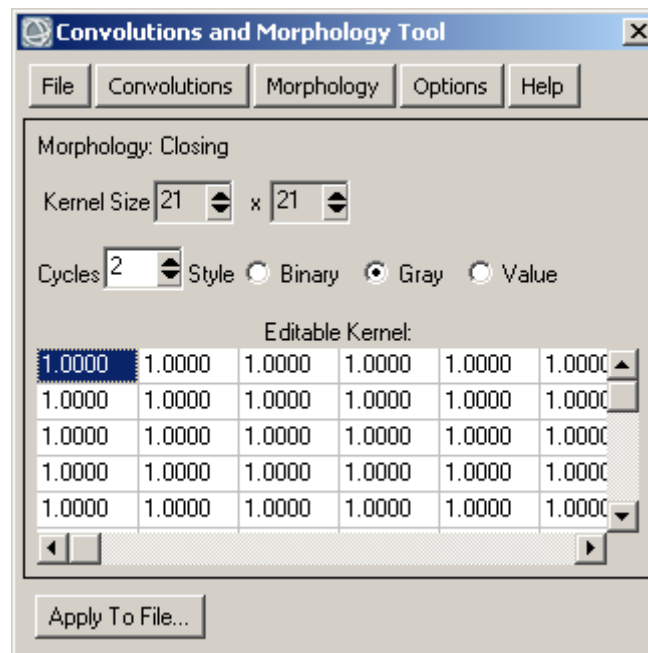
Zdroj: vlastní šetření autora

V případě filtrovaných dat z lokality A došlo k vyčištění vnitřku polygonů. Přetrval však problém s neuzavřením jednotlivých polygonů (viz Obrázek 12 B), což je v případě pixelového zpracování překážkou, protože při exportu a zpracování v GIS se více polygonů sloučí do jednoho objektu.

Řešením mohou být morfologické filtry. Ty se v principu aplikují na binární obraz (složený z jedniček a nul), což může v praxi být např. jedna třída klasifikace. Pro účely odstranění mezer je vhodná morfologická operace uzavření (closing). Ta se skládá nejprve z nárůstu (dilatace), kdy plocha dané třídy naroste v závislosti s nastavením velikosti konvoluční masky. V této fázi

tak může dojít k uzavření mezer. Následuje operace eroze, kdy je naopak z této třídy ukrajováno od hranic. Protože však v místech, kde došlo ke spojení v kroku jedna, se hranice vytvořily nově pouze vně, zůstanou takováto spojení zachována. Druhá část uzavření pouze zajišťuje, aby nedošlo k (přílišné) změně v celkové ploše vstupní třídy; aby v případě ohraničení polygonů zůstala zachována jeho šířka. Na Obrázek 12 C vidíme výsledek operace uzavření.


Obrázek 13: Nastavení morfologického filtru



Zdroj: vlastní šetření autora, software ENVI

Tento postup je použitelný pouze za předpokladu, že je ohraničení klasifikováno pouze s drobnými mezerami a zároveň, že vnitřek polygonů neobsahuje klasifikovanou třídu ohraničení. V opačném případě (viz Obrázek 12 A a Obrázek 14 A) by při fázi dilatace mohlo vzniknout další alternativní ohraničení polygonu.

Obrázek 14: Pixelová klasifikace – lokalita B



A – klasifikace nad nefiltrovanými daty, B – klasifikace nad filtrovanými daty, C – filtrovaný výstup klasifikace z první položky (A)

Zdroj: vlastní šetření autora

V případě výraznějšího efektu „pepř a sůl“ je postup s morfologickými filtry nefunkční. Do určité míry může pomoci filtrace; pokud však je odstup od šumu příliš malý, tak ani po filtraci neposkytne pixelová klasifikace vhodný základ k této operaci. Na Obrázek 14 B je pixelová klasifikace provedená nad filtrovanými daty. Je zřejmé, že by nad nimi operace uzavření nevedla k požadovanému výsledku. Stejně tak není řešením provést filtraci až nad klasifikovanými daty (na Obrázek 14 C je filtrovaný obraz z dat zobrazených na Obrázek 14 A).

3.4.3 Objektová klasifikace

Pro naplnění cíle klasifikace, tedy identifikaci samostatných polygonů, je principiálně mnohem vhodnější objektový přístup. V jejích intencích je cílem stvořit obrazové objekty (ve smyslu objektů OBIA), odpovídající vždy jednomu polygonu. Nevadí ani případný dotyk těchto objektů, neboť obrazové objekty jsou samostatné a jdou vyexportovat do vektorového formátu každý zvlášť.

V rámci objektového zpracování zkoumaných snímků byla zvolena metoda postupné klasifikace formou rozhodovacího stromu. Ta byla využita především z toho důvodu, že umožňuje jednoduše iterovat procesy a řetězit nástroje založené na poloze jednotlivých objektů (typu relative-border-to), a také pro snazší interpretaci a vyhodnocení vlivu jednotlivých kroků v procesu a jejich nastavení na výsledný proces klasifikace.

Kompletní klasifikační báze se všemi patrnými procesy jsou uvedeny v příloze 1 této práce a také uloženy v elektronické podobě ve formátu spustitelném v softwaru eCognition na DVD, které je přílohou této práce.

Pro všechny obrazy byla jako základní segmentační metoda zvolena multiresolution segmentation s vlivem spektrálních vlastností ke tvarovým v poměru 7:3 (tj. parametr shape nastaven na 0,3). Tento poměr byl zvolen po prověření alternativních nastavení (shape 0,1; 0,2; 0,3; 0,4; 0,5) s předpokladem, že pro počáteční segmentaci je důležitější spektrální informace.

Tvar a prostorové vztahy jsou v procesu klasifikace využity především později, kdy jsou naopak nejdůležitější. Změna váhy parametru tvar při prvotní segmentaci nehraje příliš důležitou roli, bez problémů se jako použitelné ukázaly na všech zpracovávaných snímcích hodnoty 0,2 – 0,4.

Jako podstatnější parametr se ukázalo být nastavení velikosti (scale parametr). Pro jednotlivé snímky byly po testování zvoleny pro prvotní segmentaci hodnoty v rozmezí 20 – 50. Hodnota tohoto parametru je spojena s tím, z kolika pixelů se skládá maximální dovolená velikost objektu (číslo však neznamena počet pixelů, podrobněji vysvětleno v kapitole 2.2.2.1), a tedy bude v principu rozdílná pro různé rozlišení při snímání téhož území. Hodnota byla stanovena jako taková, při které vznikají co největší základní objekty, které ale svým tvarem a rozsahem nepřekračují rozsah zamýšlených tříd (především ohraničení).

Po provedení základní segmentace byly zkoumány hodnoty jednotlivých objektů pomocí feature view. Tak lze přehledně vizuálně zobrazit rozdělení hodnot určité vlastnosti objektu, ať již jde o spektrální charakteristiku (např. průměrnou hodnotu pixelů daného objektu v daném spektrálním kanálu) nebo o prostorovou informaci (např. hodnotu poměru délky a šířky objektu, jak je zobrazeno na Obrázek 15 B).

Základní principy navržené metodiky se dají shrnout do následujících kroků:


1. úvodní segmentace,
2. klasifikace ohraničení s pomocí vhodných vlastností objektů,
 - a. využití spektrálních charakteristik nesporného ohraničení (takové, které nesou pouze objekty v rámci ohraničení),
 - b. klasifikace pomocí tvarových a kontextuálních informací (např. objekty sdílející hranici s primárním ohraničením a zároveň určité spektrální charakteristiky),
3. vytvoření obalových zón kolem klasifikovaného ohraničení,
4. klasifikace vnitřků polygonů; díky obalovým zónám dojde většinou k oddělení jednotlivých oblastí s klasifikovaným vnitřkem polygonu.

Situaci po těchto proběhlých krocích zobrazuje Obrázek 15 C.

5. V nadřazené obrazové úrovni provést další segmentaci pouze nad vrstvou vnitřků polygonů se zvětšeným parametrem velikosti a s důrazem na tvar objektu (viz Obrázek 15 D),
6. Dokončit klasifikaci vnitřku polygonu i z objektů, které tvořily obalovou zónu ohraničení v kroku 3 (viz Obrázek 15 E),
7. V další nadřazené obrazové úrovni opět provést segmentaci nad klasifikovanou vrstvou vnitřku s takovým parametrem velikosti, aby došlo ke sloučení malých objektů z dřívější obalové zóny s hlavním objektem reprezentujícím vnitřek polygonu z bodu 5 (červeně označen na Obrázek 15 E; výsledný stav po provedení bodu 7 je zobrazen na Obrázek 15 F).

Tento postup je navržen s vědomím toho, že je důležité pro další zpracování získat objekty tvarem odpovídající vnitřku polygonů.

Obrázek 15: Průběh objektové klasifikace



A – originální obraz, B – objekty první obrazové úrovně se zobrazenou hodnotou poměru délky a šířky objektu, C – klasifikace první úrovně mezi ohraničení a vnitřek polygonu, D – objekty druhé obrazové úrovně po dodatečné segmentaci vnitřků polygonů, E – přiřazení okrajových ploch k vnitřkům polygonů, F – výsledný obrazový objekt

Zdroj: vlastní šetření autora, NASA/JPL/University of Arizona

Kromě kroků popsanych v bodech výše se ve výsledných klasifikačních bázích objevují korekční mechanismy. Jde především o opakované použití nástroje *shape split*, který dělí obrazové objekty v případě, že mají nějaké úzké hrdlo. To se obvykle stává v případech, kdy je jeden obrazový objekt „přeteče“ do dvou skutečných polygonů skrze nedostatečně klasifikovanou část ohraničení. Tento efekt je podstatou objektové klasifikace s důrazem na tvar potlačen, přesto se v menší míře vyskytuje.

Druhým procesem, který patří mezi korekční, je identifikace „sirotků“ – objektů uvnitř plochy vnitřku polygonu, které na základě svých spektrálních charakteristik byly klasifikovány jako příslušející ohraničení. Pomocí nástrojů *enclosed by feature class* a *enclose by image object* jsou takoví sirotci identifikováni a správně klasifikováni.

Po dokončení klasifikace a konečné segmentaci byla třída „vnitřek polygonů“ v softwaru eCognition vyexportována ve formě shapefile jako zhlazené polygony při zachování jednotlivých obrazových objektů jako separátních vektorových objektů v rámci souboru.

3.4.4 Manuální vektorizace

Dosavadní výzkumy polygonálních struktur mrazových klínů byly prováděny na základě manuálně zpracovaných dat (viz např. Kysilka, 2009; Mangold, 2005). Obecně se ve výzkumech uplatňují dva přístupy. Jeden identifikuje pouze průsečíky ohraničení polygonů, tj. dále pracuje pouze s body. Druhým přístupem je vektorizace polygonů samotných a vytvoření polygonové sítě.

V této práci byly manuálně vektorizovány polygony všech tří pokusných ploch. Jejich vektorizace odpovídala standardům dosavadního geomorfologického výzkumu. Byly vektorizovány v plném rozlišení obrazu a byla vytvořena vektorová polygonová vrstva odpovídající vnitřkům polygonů. Manuálně vytvořené polygony tvoří vzor, kterému by ideálně měly odpovídat výstupy z automatických klasifikací.

Obrázek 16: Ukázka manuálně vektorizovaných polygonů



Zdroj: vlastní šetření autora, NASA/JPL/University of Arizona

Obrázek 16 znázorňuje manuální klasifikaci lokality A, tak, jak byla provedena v softwaru ArcGIS.

3.4.5 Hodnocení přesnosti

Pro jakoukoli automatickou klasifikaci obrazu je stěžejní stanovení přesnosti klasifikace. Při klasifikaci land use (land cover) je cílem získání jednotlivých ploch (tříd land use). Od toho se odvíjejí metody hodnocení přesnosti. Obvykle se využívá chybová matice a z ní odvozené indexy (celková přesnost, kappa index). Tyto metody však nejsou použitelné při klasifikaci, při níž není cílem samotné rozdělení do tříd, ale v konečném důsledku získání polygonální sítě s polygony o určitém tvaru a velikosti s dalšími vlastnostmi. Zvláště u objektové klasifikace může nastat situace, kdy objekty polygonů vyplňují prakticky celou plochu obrazu (dojde k efektivní klasifikaci pouze v jedné třídě) a přesto o kvalitě výstupu rozhodne správný tvar a velikost objektů.

Klasifikace – jak pixelová, tak objektová, musí být hodnoceny na základě výstupů, které poskytnou pro další vektorové zpracování a morfometrickou klasifikaci polygonů. Po vzoru geomorfologických studií jsou hodnoceny vlastnosti vzniklých polygonálních sítí jako celku. Jako referenční polygonální síť jsou použity sítě vzniklé na základě manuální vektorizace polygonálních struktur. V kapitole 4 jsou srovnávány vlastnosti těchto sítí (rozdělení počtu polygonů mezi jednotlivé kategorie – například relativní počet čtverhranných polygonů). Přesnost klasifikace znamená míru shody vlastností klasifikované polygonové sítě se sítí referenční.

3.5 Klasifikace polygonálních struktur mrazových klínů

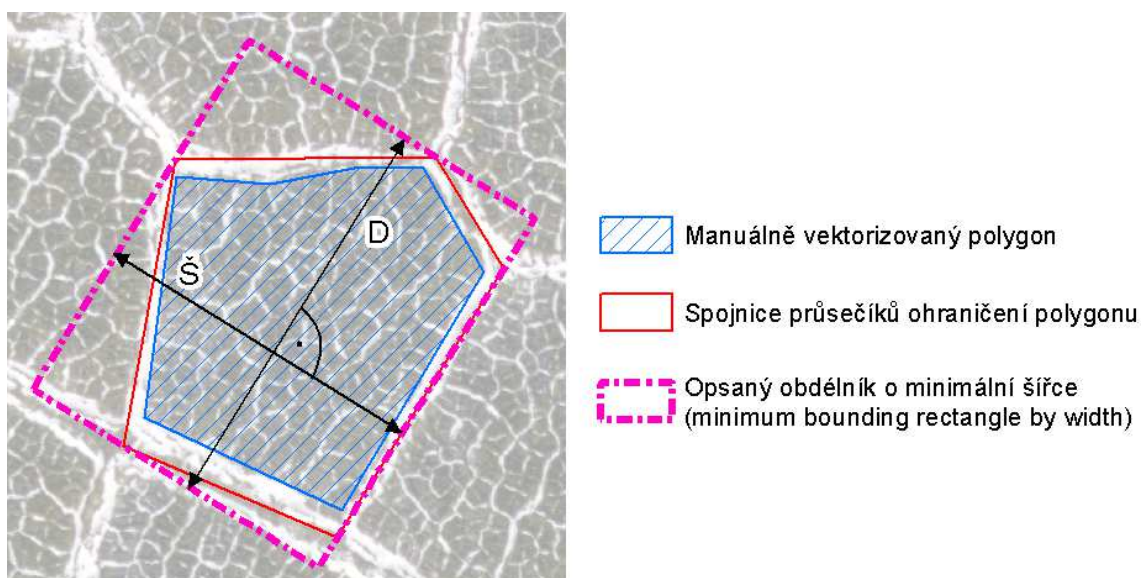
Pro klasifikaci polygonálních struktur se na Zemi používá několik přístupů. Polygony lze členit podle jejich fyzické podstaty (kamenité – tříděné a netříděné), přítomnosti vody (suché, s vodou v ohraničení polygonu či s vodou uprostřed polygonu) či tvaru reliéfu (ploché polygony, s vyvýšenými okraji nebo naopak s vyvýšeným vnitřkem polygonu). Tyto charakteristiky se vztahují obvykle na jednotlivé lokality, na nichž se vyskytuje jeden daný typ polygonu. Charakteristiky lze v mnoha ohledech zjistit z dat dálkového průzkumu pomocí různých metod (stereosnímky a tvorba DTM, detekce vody). Detekce těchto vlastností však není cílem této práce.

Polygony lze také klasifikovat podle jejich morfometrických charakteristik. Ty nabývají určitých hodnot pro každý jeden polygon a tvoří statistický soubor, který lze porovnávat mezi jednotlivými lokalitami. Není cílem práce provádět srovnání klasifikace polygonů či vyvozovat jakékoli geomorfologické, klimatické či jiné závěry. V souladu s cíli této práce mohou morfometrické charakteristiky polygonů na jednotlivých lokalitách pomoci zhodnotit úspěšnost automatizovaného postupu a metodiky klasifikace navržené v této práci. Cílů této práce bude dosaženo, pokud klasifikace polygonálních struktur podle morfometrických charakteristik na základě automatických procesů a navržené metodiky klasifikace poskytne výsledky srovnatelné se získanými na základě manuálně vektorizovaných dat.

3.5.1 Morfometrické charakteristiky polygonů

Mezi základní morfometrické charakteristiky polygonu patří jeho velikost, vyjádřená plochou polygonu. Další základní charakteristikou je počet stran. Za stranu polygonu se obecně považuje spojnice dvou křižovatek (průsečíků ohraničení) tří ledových klínů (Kysilka, 2009). Takto definované strany zároveň odpovídají počtu vrcholů polygonu (vertexů v GIS). To usnadňuje tvorbu polygonální sítě a jednoznačné rozhodování o počtu stran. Na druhou stranu to polygony tvarově zjednodušuje, především v místech, kde spojnice dvou průsečíků ohraničení polygonů ve skutečnosti není přímá. Rozdíl mezi skutečným detekovaným polygonem (modré šrafování) a tvarem polygonu podle uvedené definice (červené kontury) je zobrazen na Obrázek 17.

Obrázek 17: Morfometrické charakteristiky polygonu



Zdroj: vlastní šetření autora, NASA/JPL/University of Arizona

Rozměry polygonu byly stanoveny stejným způsobem jako v případě práce Kysilky (2009). Kolem polygonu je opsán minimální čtyřúhelník (podle minimální možné šířky). Z něj je zjištěna délka neboli hlavní osa (D) a šířka neboli vedlejší osa (Š) polygonu (kde $D > Š$), jak je znázorněno na Obrázek 17.

Azimut délky pak určuje orientaci polygonu (jako odchylku od severu v intervalu $-90^\circ - 90^\circ$).

Poměr šířky a délky pak udává míru pravidelnosti polygonu. Míra pravidelnosti nabývá hodnot od 0 (teoretický polygon – úsečka) až po 1 (opsaný pravoúhlý čtyřúhelník je čtverec).

3.5.2 Automatické nalezení průsečíků ohraničení polygonů

Stěžejním krokem pro vytvoření polygonové sítě a následnou klasifikaci polygonů je identifikace průsečíků ohraničení polygonálních struktur. Vrcholy polygonů v polygonové síti při správném umístění odpovídají právě identifikovaným průsečíkům polygonálních struktur.

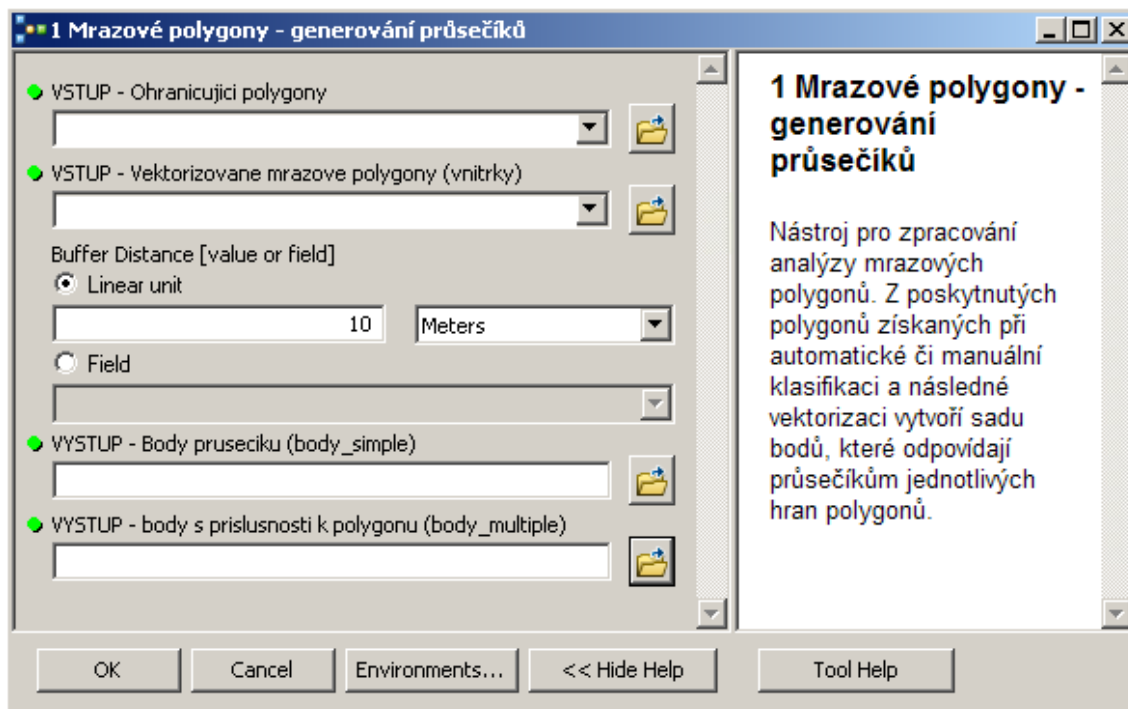
Prvním krokem je prostorová identifikace průsečíků polygonálních struktur. Podkladem pro ni je vstupní vrstva s jednotlivými polygony získaná automatickou klasifikací a následnou vektorizací či přímo manuální vektorizací. Takovéto vrstvy se vyznačují tím, že se polygony (reprezentující vnitřky polygonálních struktur) nepřekrývají. Obvykle mají mezi sebou topologickou mezeru, tj. plochu, která přísluší ohraničení, protože v realitě ohraničení není pouhý liniový prvek ale má i svou plochu (přestože se pro navržené hodnocení pro geomorfologické účely zanedbává).

Pro identifikaci polygonů byl navržen postup, zakládající se na vytvoření bufferů (obalových zón) každého polygonu. Ty fakticky zvětší polygony, takže překryjí veškeré mezery. Na hranicích polygonů vzniknou oblasti, kde se buffery překrývají. Při vytváření bufferů v softwaru ArcGIS bylo zvoleno nastavení Side Type = full, což znamená, že výsledný zvětšený polygon zahrnuje jak oblast rozšíření, tak oblast původního polygonu. Díky tomuto nastavení funguje řešení i v případě, že se vstupní polygony dotýkají a nemají mezi sebou žádnou mezeru. Dalším nutným nastavením nástroje je hodnota parametru Dissolve type = none.

Základní ideou postupu je fakt, že v místě průsečíků tří a více ohraničení polygonálních struktur se budou překrývat tři a více zvětšených polygonů. V místě stran polygonálních struktur se budou překrývat právě dva zvětšené polygony. Toho lze využít a takovéto překryvy identifikovat.

Pro identifikaci polygonů je třeba řetězce několika geoprocessingových operací, které byly provedeny v softwaru ArcGIS. Vzhledem k cílům této práce, mezi kterými je také automatizace celého procesu byl vytvořen v modulu Model builder samostatný nástroj, který těchto 15 kroků (některé sériové, jiné paralelní vůči sobě navzájem) shrnuje do jednoho nástroje (viz Obrázek 18). Nástroj poskytuje interface pro zadání všech nutných vstupů a specifikaci požadovaných výstupů (do nových souborů/záznamů v geodatabázi).

Obrázek 18: Nástroj pro automatizovaný zisk průsečíků ohraničení polygonů



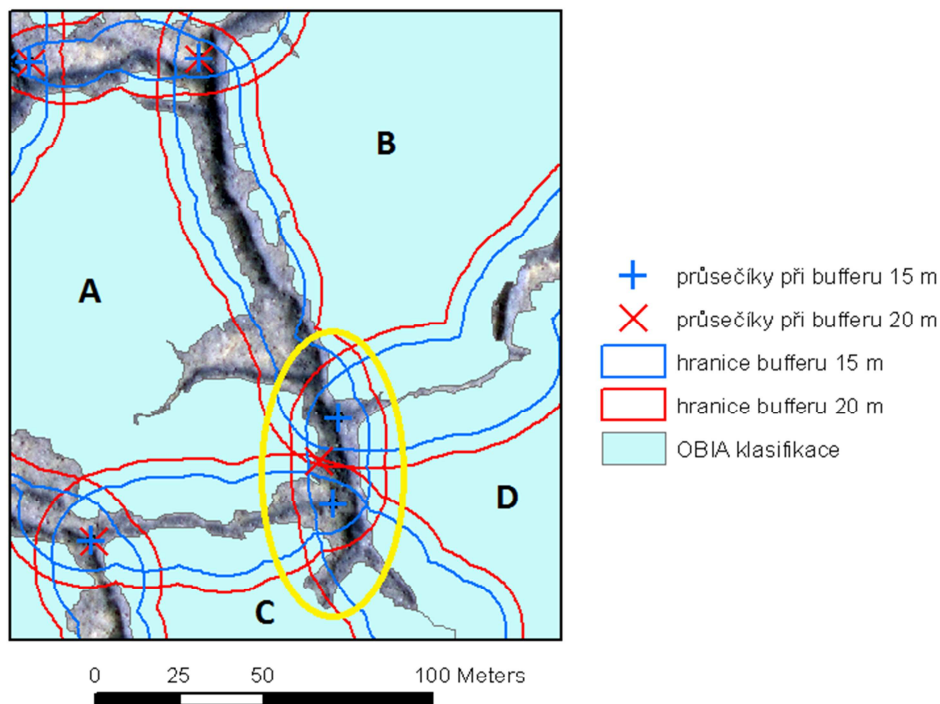
Zdroj: vlastní šetření autora, software ArcGIS

Nový nástroj pro generování průsečíků využívá zabudované algoritmy v toolboxu v softwaru ArcGIS typu buffer, select by attribute/location, merge, spatial join, feature to point. Mimo to využívá script SuperRegionPoly v93 publikovaného pod Public Domain v adresáři scriptů pro ArcGIS (Snyder, 2009). Podrobné schéma nástroje je přílohou 2.1 této práce. Ve spustitelné podobě je přiložen na DVD, které je součástí této práce.

Pro správnou prostorovou identifikaci průsečíků je stěžejní nastavení parametru operace buffer. Jeho hodnota je spojená s šířkou mezery mezi polygony – musí být taková, aby zajistila, že se nově vzniklé větší polygony překryjí. Pokud by byla hodnota příliš malá, tak na mnoha místech nemusí dojít vůbec k překrytí a průsečík tedy nemusí být identifikován. Naopak, pokud by byla hodnota příliš velká, mohlo by docházet k překrývání více polygonů a tím by se snižovala přesnost identifikované polohy průsečíku.

Implementovaný postup počítá s tím, že existují průsečíky, kde se sbíhají 4 ohraničení polygonálních struktur. V takových místech pak vzniká překryv 4 zvětšených polygonů a v jejím okolí překryv tří zvětšených polygonů. Proto je v těchto případech identifikován jen jeden průsečík (těžiště oblasti překryvu 4 zvětšených polygonů) a ostatní trojitě překryvy nejsou dále uvažovány. To v obecné rovině řeší fungování metody, přináší však další nebezpečí při nastavení vyšší hodnoty bufferu.

Obrázek 19: Princip fungování algoritmu pro hledání průsečíků

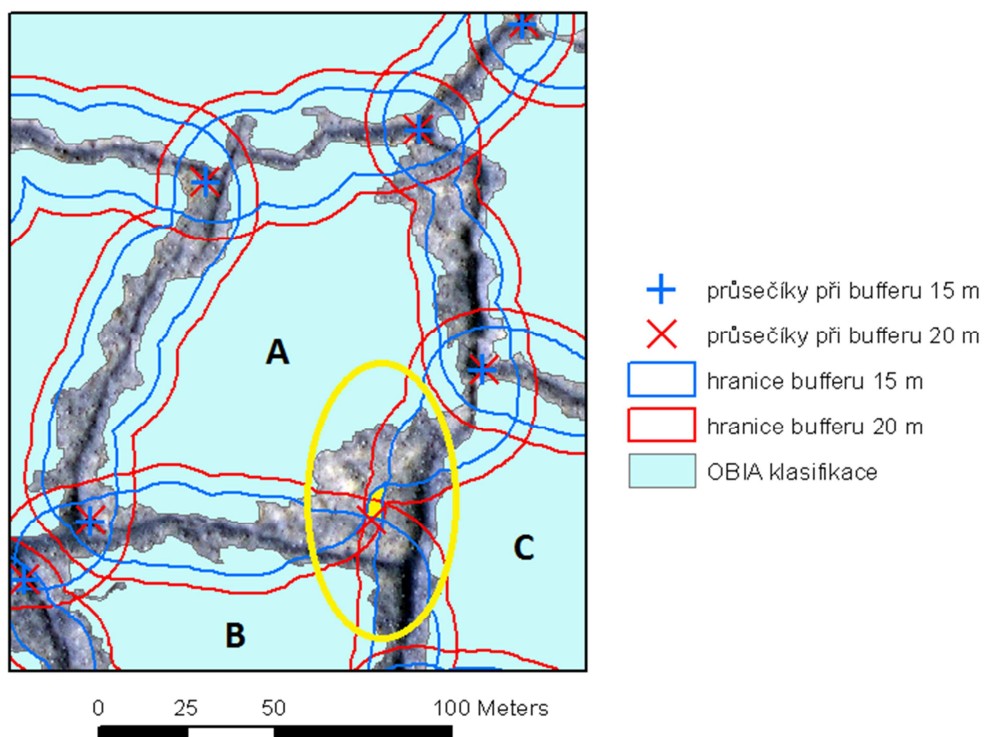


Zdroj: vlastní šetření autora NASA/JPL/University of Arizona

Jak je znázorněno na Obrázek 19, při blízkém (nikoli však totožném) napojení 4 polygonů (na obrázku označeny jako A, B, C a D) ve skutečnosti existují 2 průsečíky, které je žádoucí identifikovat. Při použití většího bufferu (na obrázku znázorněn červeně) však dojde k situaci, kdy se protnou všechny 4 polygony a je identifikován pouze jeden průsečík. Proto je z tohoto důvodu vhodnější nastavit velikost bufferu spíše na menší hodnotu.

Při klasifikaci polygonálních struktur dochází z různých důvodů k tomu, že výsledné polygony (objekty z klasifikace) neobsahují celou plochu vnitřku polygonální struktury, jak je zobrazeno na Obrázek 20 u polygonu A. V takovém případě efektivně vzrůstá mezera mezi sousedními polygony (A, B a C). V takovém případě menší hodnota velikosti bufferu zapříčiní to, že se 3 zvětšené polygony nepřekryjí nikdy (viz žlutě vyznačená oblast na Obrázek 20, kam nedosahuje žádný ze zvětšených polygonů s menší hodnotou parametru buffer). V tomto případě je vhodnější větší hodnota bufferu, která průsečík identifikuje. Vzhledem k principu implementované metody je průsečík umístěn do středu mezery mezi polygony. Průsečík je identifikován s posunutím směrem do středu polygonální struktury, která v rámci objektové klasifikace nebyla klasifikována dostatečně.

Obrázek 20: Problematická místa při určování průsečíků

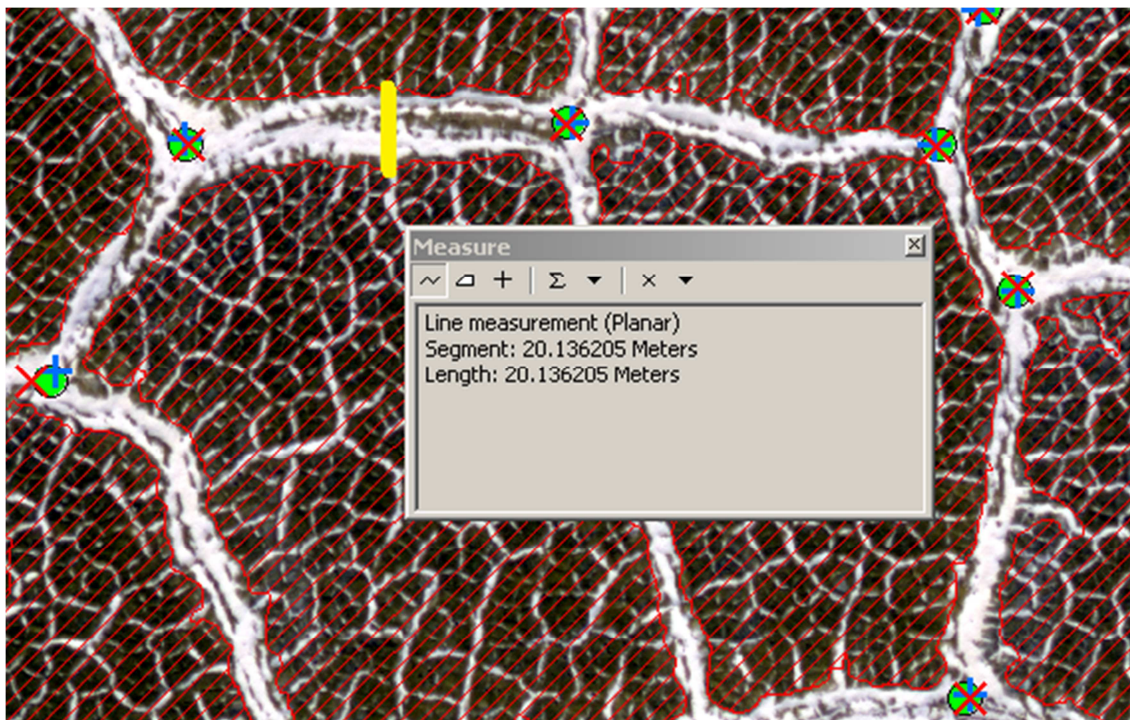


Zdroj: vlastní šetření autora, NASA/JPL/University of Arizona

Pro zkoumané snímky byly hodnoceny různé hodnoty nastavení velikosti bufferu. Ty se nutně musejí odvíjet od vlastností klasifikovaných polygonů, které jsou vstupem do samotného procesu identifikace průsečíků.

Na Obrázek 21 je znázorněna šířka ohraničení zobrazených polygonů. Tato hodnota je vlastností, ze které vychází stanovení hodnoty velikosti bufferu pro navržený postup.

Obrázek 21: Šířka ohraničení polygonu



Zdroj: vlastní šetření autora, NASA/JPL/University of Arizona

Po otestování různých hodnot nastavení velikosti bufferu na zpracovávaných snímcích vykazovala nejlepší výsledky hodnota odpovídající šířce běžného reálného ohraničení v místech, kde je toto ohraničení v obrazu nejširší. Tomuto pravidlu odpovídají i hodnoty aplikované na zpracovávané snímky, které jsou uvedeny v Tabulka 6.

Tabulka 6: Přehled parametrů pro automatické nalezení průsečíků polygonů

Zdroj vektorových polygonů		Použitý buffer [m]
Lokalita A	manuální vektorizace	20
	OBIA - originální data	20
	OBIA - filtrovaná data	20
	pixelová klasifikace	20
Lokalita B	manuální vektorizace	10
	OBIA - originální data	10
	OBIA - filtrovaná data	10
Lokalita C	manuální vektorizace	10
	OBIA - originální data	15
	OBIA - filtrovaná data	15

Zdroj: vlastní šetření autora, software MS Excel

Pro účely této práce bylo za průsečík polygonálních struktur považováno i setkání ohraničení s okrajem zpracovávaného obdélníkového území. Za tohoto předpokladu byly body vytvořeny i na krajích zpracovávaného území. To by nemohlo být provedeno při skutečném morfometrickém hodnocení sady polygonů, nicméně pro účely hodnocení navržené metody je účelné hodnotit i okrajové případy. Metoda byla prověřena v širším kontextu a neubírá nic na informační hodnotě výstupu, neboť okrajové body (polygony) lze kdykoli jednoduchou geoprocessingovou operací ze sady odstranit.

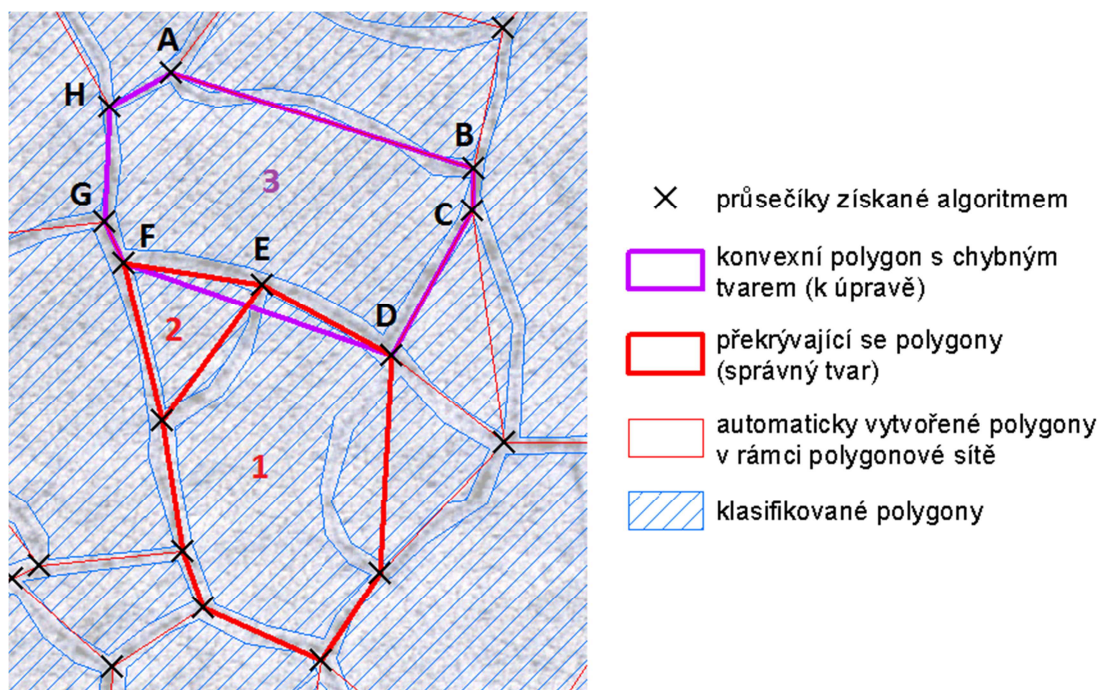
3.5.3 Automatická tvorba polygonové sítě

Z identifikovaných bodů – průsečíků ohraničení polygonálních struktur – byla v software ArcGIS vygenerována polygonová síť. V ní jsou polygonální struktury reprezentovány polygony, které mají počet stran (vrcholů) odpovídající definici sledovaných morfometrických charakteristik, nepřekrývají se a pokud nedošlo k chybné identifikaci bodů v předcházejícím kroku, tak na sebe navazují.

Aby bylo možno tuto síť zkonstruovat, bylo nutné v rámci tvorby podkladové bodové vrstvy v předcházejícím kroku jednotlivým bodům přiřadit jejich příslušnost ke konkrétním polygonům., Požadovaný výstup nástroj ukládá do vrstvy body_multiple (viz Obrázek 18). Bodům je sice přiřazena příslušnost k danému polygonu, ale nebyl nalezen způsob, jak zajistit seřazení jednotlivých bodů jednoho polygonu tak, aby byla zajištěna jejich posloupnost (viz Obrázek 22 – posloupnost vrcholů polygonu 3: a – H). Při pouhém vytváření polygonu či polylinie byly vrcholy jednotlivých polygonů v nevhodném pořadí, podle toho, které body byly kdy zpracovávány v předcházejících nástrojích.

Proto bylo zvoleno řešení, při kterém iteračně probíhala operace tvořící minimální konvexní obálku sady bodů náležejících jednomu polygonu. Polygonální síť byla vytvořena poté, co tato operace postupně proběhne přes všechny sady bodů. Tato iterační metoda byla zpracována do samostatného nástroje, jehož schéma je v příloze 2.2 a jehož spustitelná elektronická verze je přiložena na DVD. Výsledek této operace ukazuje Obrázek 22.

Obrázek 22: Automaticky vytvořená polygonální síť




Zdroj: vlastní šetření autora, NASA/JPL/University of Arizona

Problémem, vyplývajícím ze zvolené funkce (minimum bounding geometry – konvex hull) je nekonzistence u polygonů, které nejsou konvexní. Dochází k překryvu polygonů a k vynechání bodu(ů) u těch polygonů, které by měly být nekonvexní.

Proto byl připraven opravný mechanismus, který tyto situace řeší. Je založen na identifikaci takových polygonů, uvnitř kterých (tedy nejen na jeho okraji) se nachází nějaký z jeho bodů. Takový bod je pak pomocí několika geoprocessingových nástrojů zmenšen o požadované části okolních polygonů. Tento nástroj je opět k dispozici – schéma v příloze 2.3 a jako soubor na DVD.

Výsledky z tohoto nástroje jsou konečné geometrické výstupy navržené metodiky. Ukázka je na Obrázek 23.

Obrázek 23: Opravená geometrie polygonální sítě



Zdroj: vlastní šetření autora, NASA/JPL/University of Arizona

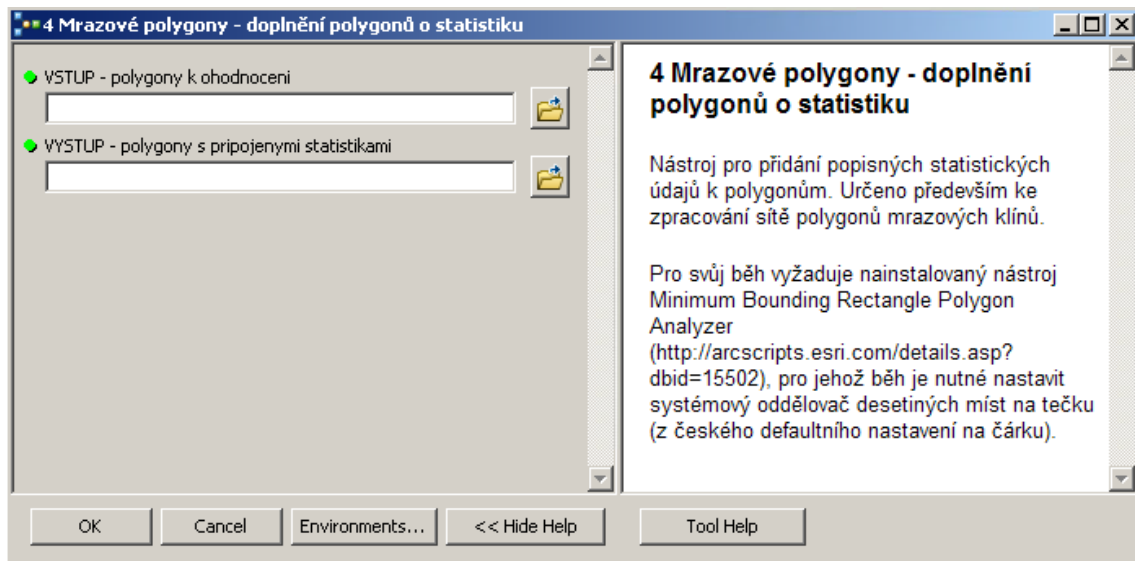
3.5.4 Vypočet statistik polygonové sítě

Pro klasifikaci získaných polygonů v polygonové síti a vyhodnocení navržené metodiky byly k výsledným polygonům vypočteny a do atributové tabulky vloženy morfometrické charakteristiky každého jednoho polygonu. Zvoleny byly charakteristiky, které pro porovnávání jednotlivých lokalit polygonálních struktur používá Kysilka (2012) ve své práci. Pro tyto účely byl sestaven 4. nástroj pro automatické zpracování v softwaru ArcGIS (viz Obrázek 24, schéma viz příloha 2.4).

Pro analýzu byly použity interní nástroje z Arc toolbox a pythonovský skript Minimum Bounding Rectangle Analysis tools (Frye, 2008) z knihovny scriptů ESRI. Je nutné poznamenat, že správné fungování tohoto skriptu, který je zakomponován do připraveného nástroje, vyžaduje nastavení oddělovače desetinných míst v lokálním prostředí MS Windows na tečku (způsob užívaný ve Spojených státech amerických).

Statistiky každého jednoho polygonu zahrnují jeho plochu. Jde o základní vlastnost používanou k popisu a porovnávání polygonů. Jde také o jedinou z vlastností, pro jejíž zjištění není třeba vytvořený nástroj. Software ArcGIS pro polygonové vrstvy dokáže zkalkulovat plochu prvku bez dalších rozšiřujících nástrojů (příkaz „Calculate Geometry“ v atributové tabulce polygonové vrstvy).

Obrázek 24: Nástroj pro automatické doplnění statistik polygonové sítě



Zdroj: vlastní šetření autora, software ArcGIS

Druhou podstatnou charakteristikou každého polygonu je počet jeho hran neboli počet vrcholů polygonu. Tato charakteristika je v geomorfologickém výzkumu často používána. Díky tomu, že lze celkem snadno zjistit i za použití analogových metod bez složitějších konstrukcí či výpočtů, je používána v mnoha výzkumech v rozsahu celých polygonálních sítí, nejenom k charakteristice jednotlivého zkoumaného polygonu. Vzhledem k definici uvedené v kapitole 3.5.1 a algoritmu vytváření polygonů, tak jak je popsán v kapitolách 3.5.2 a 3.5.3, počet hran polygonu odpovídá počtu jeho vertexů zmenšenému o 1. Výsledné hodnoty jsou v rámci připraveného nástroje pomocí jednoduchého pythonovského příkazu zapsány do atributové tabulky.

Pro další skupinu charakteristik byl pro každý polygon vytvořen opsaný obdélník o minimální šířce. Z něho byly získány údaje o šířce a délce, jak je to znázorněno na Obrázek 17. Do atributové tabulky byl zapsán i poměr šířky ku délce (jako atribut pravidelnost) a poměr plochy polygonu ku ploše opsaného obdélníku (MBR_Area).

Získaná data byla následně zpracována v softwaru Microsoft Excel pro interpretaci provedené v následující kapitole. Získané vrstvy polygonálních sítí byly zpracovány do mapových výstupů, které jsou přílohou 3 až 5 této práce.

4 Výsledky

V této práci byla navržená metodika aplikována na tři snímky z různých lokalit na Marsu. Všechny snímky byly pořízeny senzorem HiRISE z družice MRO a znázorňují vzájemně vizuálně odlišné polygonové struktury. Stěžejní částí práce je zpracování obrazových dat a interpretace získaných informací z klasifikovaných polygonů.

Všechny tři snímky byly filtrovány a navržená metodika tak byla aplikována na filtrované i nefiltrované snímky s cílem rozhodnout, zda je tato úprava snímků pro výsledek prospěšná.

Výstupem práce je metodika klasifikace a získání informací o polygonech, sestávající se z následujících kroků:

1. Příprava obrazu (případná filtrace)
2. Objektová klasifikace vnitřků polygonů v několika postupných krocích, jak je popsáno v kapitole 3.4.3
 - a. Za specifických podmínek možno použít pixelovou klasifikaci
3. Export klasifikovaných polygonů ze softwaru eCognition a jejich import do softwaru ArcGIS
4. Aplikace 4 nástrojů (toolboxů) připravených v rámci vypracování této práce na importovaná data

Pro zhodnocení navržené metodiky je stěžejní vizuální porovnání výstupů, které je možné provést nad mapovými výstupy v přílohách 3-5 této práce. Dalším neméně důležitým krokem při zhodnocení metodiky je porovnání výstupů klasifikací polygonů pomocí statistických souborů polygonů, u kterých je sledováno rozložení morfometrických charakteristik jednotlivých polygonů. Následuje popis dílčích i konečných výstupů metodiky po jednotlivých lokalitách.

4.1 Lokalita A

V lokalitě A existují jako v jediné ze tří zkoumaných lokalit polygony dvojí úrovně. Veškeré pokusy automaticky klasifikovat nižší úroveň selhaly. Vzhledem k rozdrobenosti a časté neuzavřenosti polygonů první úrovně je obtížné polygony přesně identifikovat i vizuálně, tedy postupem zatím běžným v geomorfologických výzkumech. Naopak vyšší úroveň polygonů je ze zpracovávaných tří lokalit nejlépe vyvinutá. Pro klasifikaci bylo jasnou výhodou, že je ohraničení polygonů poměrně široké.

Tato lokalita byla jediná, kde smysluplné výsledky poskytla pixelová klasifikace spolu s morfologickými filtry a je tedy zahrnuta do výstupů (jak mapových, tak v grafech 1 – 3). Základní informaci o tom, jak navržená metodika automatického rozpoznání polygonů funguje, poskytuje počet identifikovaných polygonů. Referenční zpracování manuálně vektorizovaných dat vedlo v této lokalitě k rozpoznání 72 polygonů. Navržená metodika pro originální


(nefiltrovaná) data po OBIA zpracování identifikovala také 72 polygonů, pro filtrovaná data po OBIA zpracování 79 polygonů a metoda pixelové klasifikace (pouze s filtrovanými daty) 60 polygonů. Z vizuálního hodnocení (viz příloha 3) je patrné, že 72 polygonů identifikovaných při OBIA originálních dat není totožných s polygony referenčními. Ve 3 případech byly polygony identifikovány odlišně (rozděleny navíc, nebo nerozděleny).

Při OBIA filtrovaných dat se objevily polygony navíc. Ty vznikly rozdělením některých větších polygonů v místě silného sekundárního ohraničení. Jde tedy o polygony, které mají určitý reálný základ.

Obě objektová řešení poskytují dobrý prostorový popis skutečnosti. Pixelová klasifikace identifikovala podstatně menší počet polygonů i přes zapojení morfologických filtrů. To je spjato s neexistencí obrazových objektů. Jakmile byla plocha klasifikovaná jako vnitřek polygonové struktury spojena s plochou vnitřku jiné polygonové struktury, došlo k vytvoření jediného polygonu, právě protože chyběly mechanismy zapojující prostorové vztahy do výsledné klasifikace.

Polygonovou síť lze hodnotit na základě zastoupení polygonů s určitým morfometrickým znakem. Nejjednoznačnějším a také široce používaným znakem je počet hran (vrcholů) polygonů. Rozdělení četností v polygonové síti je znázorněno na Graf 1.

Graf 1: Lokalita A – histogram polygonů podle počtu hran




Zdroj: vlastní šetření autora, software MS Excel

Nejvyšší podobnosti dosahuje klasifikace OBIA nad filtrovanými daty – kdy vzhledem k absolutnímu počtu polygonů nabývá vyšších hodnot v porovnávaných sloupcích, celkové rozdělení je však nejbližší referenčním datům.

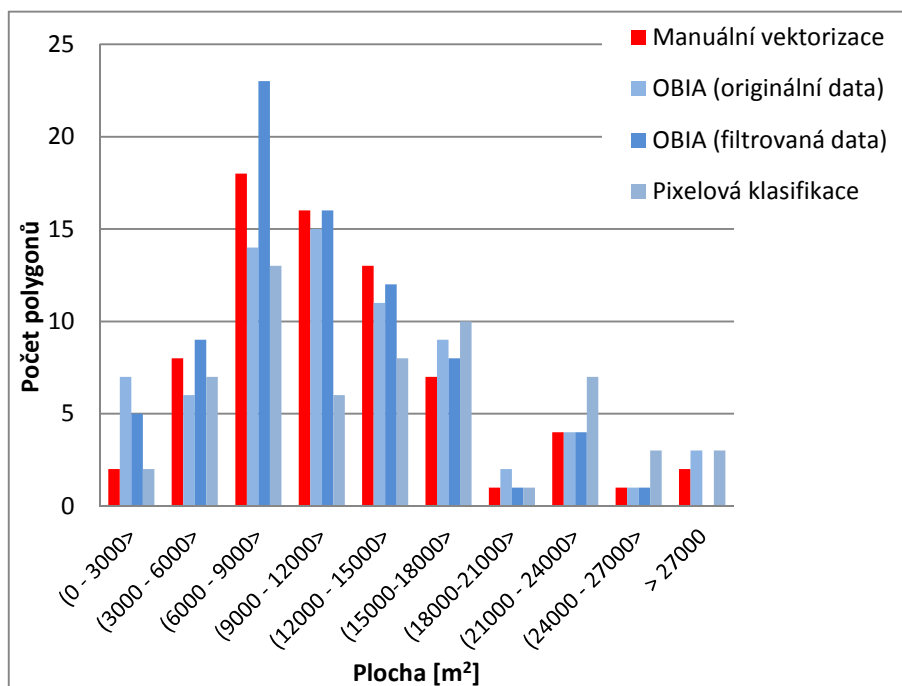
Následují obdobné grafy popisující míru pravidelnosti (Graf 2) a plochu polygonů (Graf 3).

Graf 2: Lokalita A – histogram polygonů podle míry pravidelnosti



Zdroj: vlastní šetření autora, software MS Excel

Graf 3: Lokalita A – histogram polygonů podle plochy



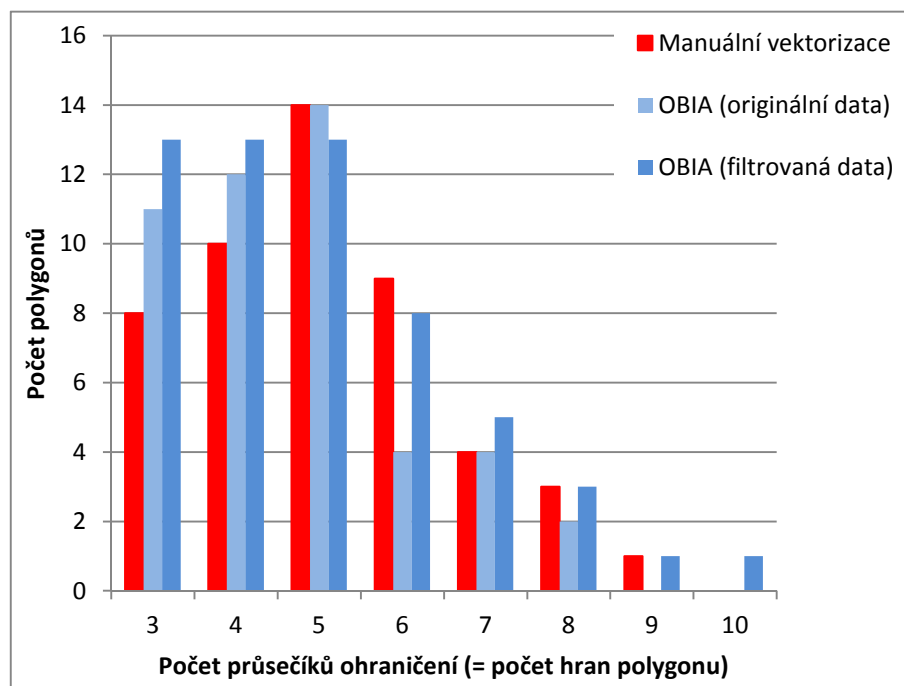
Zdroj: vlastní šetření autora, software MS Excel

Z uvedených grafů je vidět, že výsledky pixelové klasifikace se s referenčními daty rozcházejí nejvíce (u většiny intervalů jsou hodnoty pixelové klasifikace nejvzdálenější hodnotám referenční klasifikace). Vzhledem k tomu, že grafy ukazují absolutní počty polygonů, je toto částečně způsobeno již diskutovaným menším celkovým počtem polygonů v případě pixelové klasifikace. To ale není případ odlišného rozložení polygonů podle plochy, ve kterém referenční data a obě OBIA klasifikace v intervalech mezi 6 000 a 21 000 klesají (až na originální data v prvním intervalu, kde je mírný nárůst). Rozložení polygonů pixelové klasifikace má lokální minimum v intervalu 9 000 – 12 000 a následující dva intervaly roste (když překonává dokonce i referenční data, i přes nižší absolutní počet všech polygonů).

4.2 Lokalita B

V lokalitě B byla situace komplikovanější, protože ohraničení polygonálních struktur není vyvinuto v takovém rozsahu, jako u lokality A. Zároveň se ve snímku vyskytuje efekt „sůl a pepř“. To způsobilo, že pokusy o klasifikaci pixelovou metodou i při zahrnutí různých parametrů nízkofrekvenčního filtru obrazu či použití morfologických filtrů nevedla k výsledkům, které by bylo možné hodnotit.


Graf 4: Lokalita B – histogram polygonů podle počtu hran



Zdroj: vlastní šetření autora, software MS Excel

Také vzhledem k nižšímu prostorovému rozlišení snímku vykazují i výsledky objektové klasifikace nižší přesnost. Vizuálním porovnáním referenčních a klasifikovaných dat lze zjistit, že především v části obrazu s výraznou texturou spektrálně odpovídající ohraničení (severozápadní část zpracovávané plochy) klasifikace nebyla přesná. U klasifikace aplikované na originální (nefiltrovaná) data to vedlo k vytvoření mezer mezi polygony. Výsledný počet klasifikovaných polygonů byl 48 oproti 49 z referenčních dat. Naopak klasifikace nad filtrovanými daty v této oblasti vykazovala vznik více menších polygonů, které neodpovídaly skutečným polygonálním strukturám. Konečný počet polygonů za celou testovací plochu při klasifikaci filtrovaných dat byl 57. To je také patrné z Graf 4 – klasifikované polygony (zvláště u filtrovaných dat) se častěji vyskytují s počtem tří hran. Jde o odraz malých polygonů vzniklých v této oblasti – malé polygony mají tendenci mít spíše méně hran, jak lze ověřit v příloze 4 této práce.

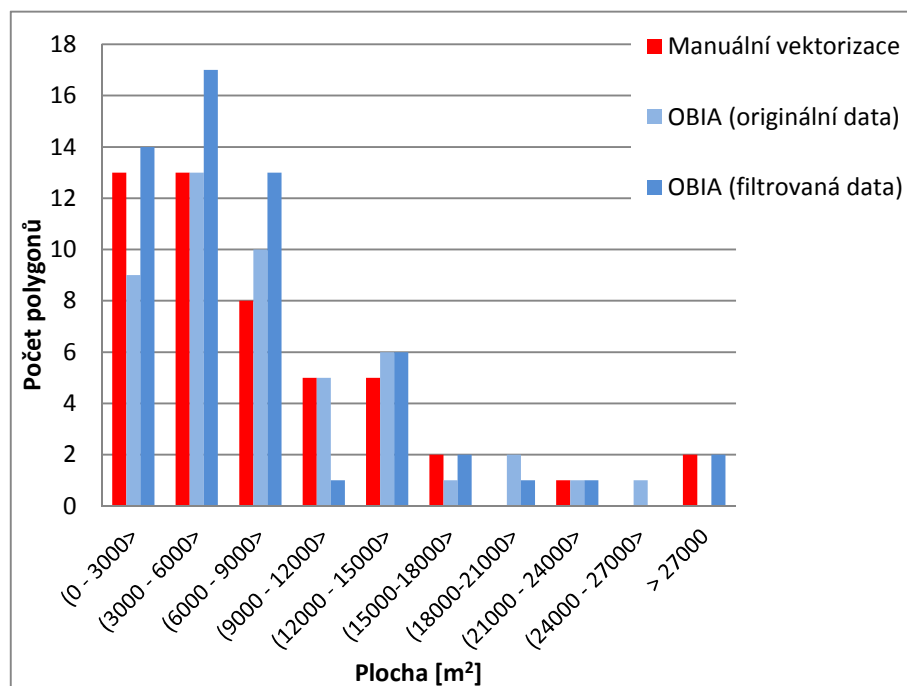
Graf 5: Lokalita B – histogram polygonů podle míry pravidelnosti



Zdroj: vlastní šetření autora, software MS Excel

Další ukazatele – tj. rozložení hodnot pravidelnosti (viz Graf 5) a plochy (viz Graf 6) – v porovnání referenčních a klasifikovaných dat odhalují odchylky, které jsou dosti patrné; např. v případě obou klasifikací je nejčastější mírou pravidelnosti interval $(0,5 - 0,6>$, zatímco v referenčních datech je to až interval $(0,7 - 0,8>$.

Graf 6: Lokalita B – histogram polygonů podle plochy



Zdroj: vlastní šetření autora, software MS Excel


4.3 Lokalita C

Lokalita C zastupuje třetí identifikovaný vizuálně odlišný typ polygonálních struktur na Marsu. Zpracovávaný snímek měl vyšší prostorové rozlišení (stejně jako lokalita A – 0,25 m/pixel), ale vzhledem k vyššímu celkovému počtu polygonů je jejich identifikace obtížnější než v případě lokality A. Specifikem této lokality je přítomnost mrzavých klínů, které se opět nepodařilo klasifikovat pixelovou klasifikací; porovnávají jsou tedy opět objektové klasifikace nad originálními a filtrovanými daty.

U referenčního vzorku manuální vektorizace bylo identifikováno 107 polygonů, u OBIA klasifikace originálních dat 103 a filtrovaných dat 108.

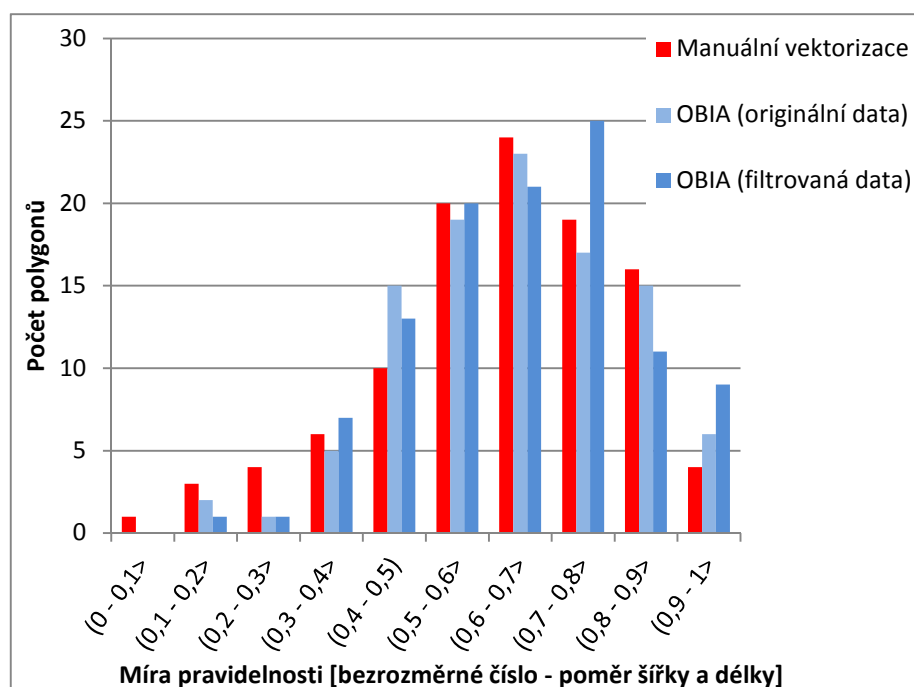
U statistického zastoupení polygonů s daným počtem hran se jako podobnější referenčnímu vzorku ukazuje zpracování originálních dat (viz Graf 7). Filtrovaná data mají nejvíce polygonů s 6 hranami, přičemž výrazně převyšují jak referenční vzorek, tak klasifikaci nad originálními daty.

Graf 7: Lokalita C – histogram polygonů podle počtu hran




Zdroj: vlastní šetření autora, software MS Excel

Graf 8: Lokalita C – histogram polygonů podle míry pravidelnosti



Zdroj: vlastní šetření autora, software MS Excel

Graf 9: Lokalita C – histogram polygonů podle plochy



Zdroj: vlastní šetření autora, software MS Excel

V případě míry pravidelnosti (viz Graf 8) má sada polygonů vzniklá klasifikací filtrovaných dat nejčastěji hodnotu posunutou vůči referenčnímu vzorku k vyšším hodnotám, tedy více polygonů je pravidelnějších.

Graf 9 byl oproti předcházejícím grafům (3 a 6) zobrazujícím plochu polygonů upraven, co se hodnot na ose x týká. Vzhledem k většímu počtu menších polygonů byl první sloupec histogramu v předcházejících grafech rozdělen na tři menší intervaly. Není dodrženo měřítko, což je naznačeno přímo v grafu.

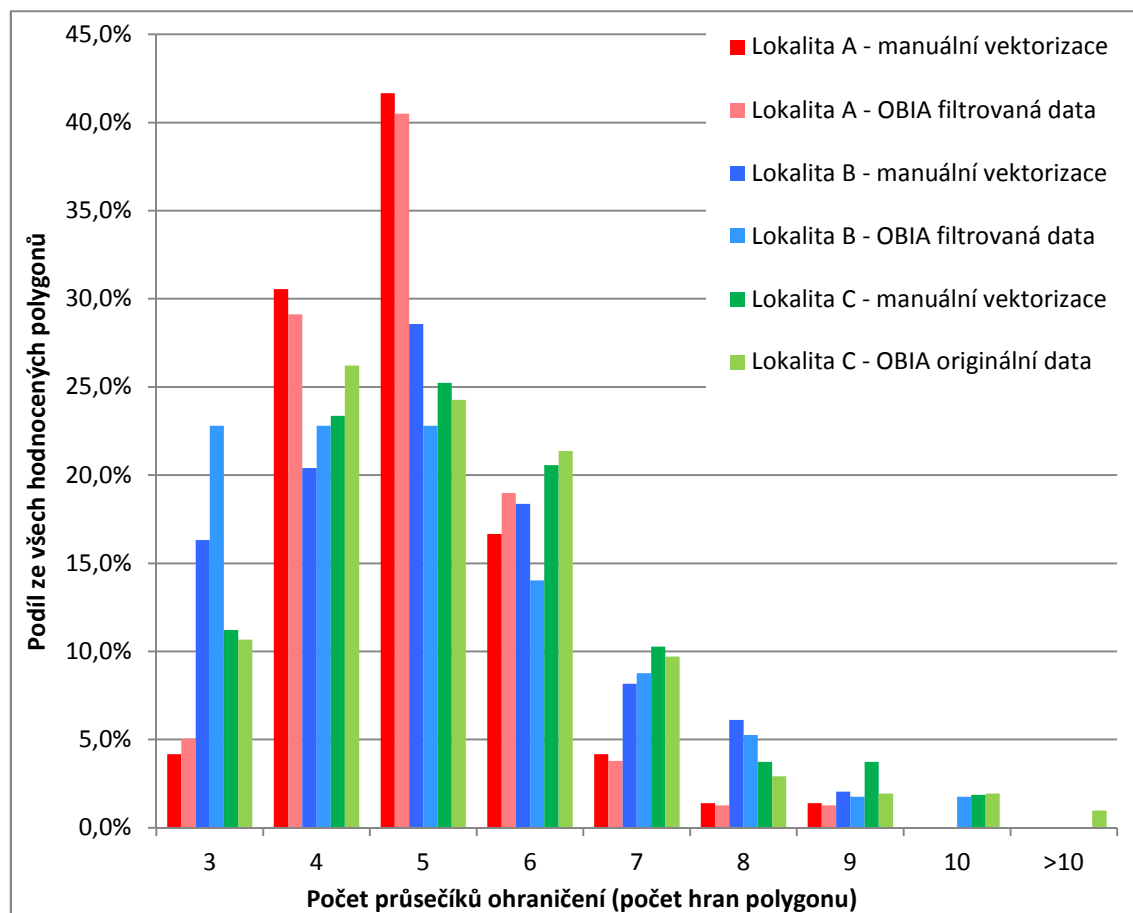
4.4 Souhrnné výsledky

Pro samotné rozhodnutí o možnostech přínosu automatizovaného zpracování dat je nejdůležitější, jestli takto vzniklé sady dat dokážou charakterizovat jednotlivé skupiny polygonů.

K zodpovězení této otázky byl sestaven graf, který reprezentuje jednotlivé lokality a zobrazuje všechny provedené klasifikace. Graf je pro svou velikost přílohou 6 této práce. Zobrazenou veličinou je rozdělení polygonů podle počtu hran (vrcholů), což je nejzásadnější ze zjišťovaných morfometrických charakteristik. Pro možnost porovnání dat jde o relativní rozdělení polygonů mezi jednotlivé třídy (procentuální vyjádření počtu polygonů, které mají daný počet hran). Na základě co největší shody s referenční klasifikací manuálně

vektORIZOVANÝCH DAT BYL VYTVOŘEN GRAF 10. TEN ZOBRAZUJE ZA DANOU LOKALITU REFERENČNÍ KLASIFIKACI A ZÁROVEŇ KLASIFIKACI JÍ NEJPODOBŇJŠÍ.

Graf 10: Porovnání relativního zastoupení n-hranných polygonů mezi lokalitami



Zdroj: vlastní šetření autora, software MS Excel

V obecné rovině je důležité, aby rozdíly mezi referenční klasifikací a klasifikací automatickou z téže lokality byly podstatně menší, než jsou mezi referenčními klasifikacemi jednotlivých lokalit. Tak zůstane zachován i charakter morfometrického popisu dané lokality.

Jak je vidět na Graf 10, podařilo se to u lokality A, která je jak v případě referenční klasifikace, tak v případě objektové klasifikace charakterem rozdělení polygonů odlišná od zbylých lokalit.

U lokalit B a C jsou hodnoty velmi podobné a nelze ze získaných dat vyvodit závěr, že by tyto lokality šly odlišit.

5 Diskuse

Existence polygonálních struktur a jejich konkrétní podoba jsou závislé na prostředí, ve kterém vznikají, a na době, po kterou se vyvíjejí (Kysilka, 2009). V geomorfologickém a klimatologickém výzkumu se kombinuje výzkum *in situ* (dynamika vývoje mrazových polygonů, vliv prostředí) s prostředky distančními, které dokáží získávat data z mnohem širšího vzorku míst a o mnohem více polygonech. Práce Kysilky je zaměřena na nalézání souvislostí mezi vlastnostmi polygonálních sítí, tedy definovaných statistických souborů, s podmínkami klimatickými a dalšími (např. stáří, vzdálenost od pobřeží moře). Prokázání závislosti v současnosti umožňuje předpokládat, že fosilní polygony či polygony bez možnosti výzkumu *in situ* (např. na Marsu) vznikaly za obdobných podmínek.

Pro takovéto aplikace je podstatné mít statistické soubory dostatečně přesně popisující polygonální síť. Důraz není kladen na přesnou klasifikaci jednoho polygonu.

Prostorová identifikace polygonu je tradičně v geomorfologickém výzkumu prováděna manuálně (manuální vektorizace). Přesnost výsledků manuálního postupu je pro návazný výzkum uspokojivá, pokud se použije dostatečné prostorové rozlišení dat (Haltigin et al., 2010).

5.1 Automatizace klasifikace půdních polygonů

V této práci bylo testováno, zda lze získat statistické soubory dostatečně přesně popisující polygonální síť co možná nejvíce automatizovaným procesem, který by umožnil jejich rozšíření co do počtu souborů i jejich velikosti.

Navržený automatizovaný proces lze rozdělit do dvou hlavních částí. První je rozpoznávání polygonálních struktur v obrazu. Ze vstupních rastrových dat se pokouší vytvořit reprezentativní vektorovou vrstvu obsahující jako polygon jednotlivé polygonální struktury, popř. vnitřní části těchto struktur. Druhá část procesu z těchto vektorových dat vytváří polygonální síť daných parametrů, které vycházejí z metodiky geomorfologického výzkumu. Díky této polygonové síti lze následně získat požadovaná data morfometrických charakteristik polygonálních struktur.

Při zpracování rastrových dat byl testován jak pixelový přístup, tak objektová analýza obrazu. Pixelový přístup přinesl uspokojivé výsledky pouze v jednom z několika testovaných případů. Předpokladem úspěchu jsou dvě podmínky – dostatečný odstup obrazu od šumu a dostatečná konzistence ohraničení polygonálních struktur, resp. jejich rastrové reprezentace. Konzistentností je myšlena souvislá návaznost a dostatečná šířka (při vyjádření v pixelech). První podmínka – odstup od šumu – lze v některých případech odstranit použitím vhodného filtru. Ten ale ještě zdůrazňuje potřebu výrazného ohraničení. Z těchto důvodů byl jediný uspokojivě klasifikovaný snímek z lokality A po provedené nízkofrekvenční filtraci (viz Obrázek 12). Při nedostatečné výraznosti ohraničení (ať již prostorové nebo spektrální) jednak nelze efektivně filtraci obrazu použít a především – vznikají větší regiony klasifikovaných vnitřků polygonálních struktur. Přes použití morfologických filtrů jsou tyto regiony často spojené

přes několik reálných polygonálních struktur. Při následujícím kroku – automatické vektorizaci – je pak vytvořen pouze jeden polygon. To lze ilustrovat výsledkem popsaném v oddílu 4.1, kdy je výsledkem použití pixelové klasifikace podstatně nižší počet polygonů (60 oproti referenčním 72). V lokalitě A poskytla použitelné výsledky pixelová klasifikace pouze při zpracování filtrovaných obrazových dat. V lokalitách B a C vzhledem k výše uvedeným problémům výsledky nebyly použitelné. Proto lze konstatovat, že navržený postup pro pixelovou klasifikaci není použitelný pro naplnění vytyčených cílů automatického rozpoznávání polygonálních struktur.

Objektová klasifikace těží z principu objektového zpracování dat. Ty pomáhají překonat oba problémy popsané u pixelové klasifikace. Nedostatečnou výraznost ohraničení lze do určité míry kompenzovat použitím prostorových příznaků u obrazových objektů. Problém spojování několika polygonálních struktur v jeden výsledný polygon lze do velké míry řešit omezením maximální velikosti obrazového objektu v rámci procesu segmentace.

Pro vytváření klasifikační báze OBIA byl v této práci po testování navržen obecný postup obsahující konkrétní procesy a úkony. Obecný postup je popsán v kapitole 3.4.3. Jak ukazují konkrétní parametry procesů bází připravených pro testované snímky (viz příloha 1), nelze tento postup doplnit o obecně platné parametry. Při použití OBIA pro identifikaci polygonálních struktur je nutné, aby výzkumník tyto parametry zjistil postupným testováním a aplikací v rámci popsaného postupu. Stěžejním parametrem jsou spektrální charakteristiky ohraničení a vnitřku polygonálních struktur. Ty se na zkoumaných lokalitách liší a nelze je tedy *a priori* stanovit.

Použití filtrovaných obrazových dat pro objektovou klasifikaci neovlivňuje platnost popsaného obecného postupu, vede však k odlišnému nastavení jeho parametrů, jak je patrné z přílohy 1. Jak ukazují výsledky v kapitole 4, nelze jednoznačně rozhodnout, zda se výstupy automatického procesu blíží referenčnímu vzorku více v případě filtrovaných dat nebo v případě dat originálních. Graf 10 (a příloha č. 6) ukazuje, že v případě relativního zastoupení *n*-hranných polygonů se referenčnímu vzorku ve 2 případech (lokalitách a a B) více blíží výstupy založené na filtrovaných datech oproti jednomu případu (lokalita C) kdy je bližší výstup založený na originálních datech. Další sledované ukazatele (pravidelnost, plocha) v kapitole 4 poskytují nejednoznačné výsledky. Lze prohlásit, že pro získ relevantních dat je podstatnější přesné stanovení parametrů klasifikační báze OBIA.

Druhá část procesu – tedy zpracování vektorového výstupu rozpoznávání polygonálních struktur na polygonální síť je prováděna nástroji GIS softwaru. Nástrahy procesu se dají rozdělit na formální – softwarové, kam patří např. závislost použitých nástrojů na nastavení prostředí systému Windows (tečka jako desetinný oddělovač). Tyto nástrahy jsou popsány v metodice postupu (kapitola 3). Samotný proces využívající mnoho geoprocessingových nástrojů softwaru ArcGIS byl v rámci této práce zjednodušen vytvořením nástrojů, které lze použít a lze je přenést při dodržení popsaného postupu na libovolný počítač vybavený aktuálním software ArcGIS a příslušnými skripty, tak jak je popsáno v příslušné kapitole 3.5.

Při dobré identifikaci polygonálních struktur v první části procesu (neboli vzorově v případě manuální vektorizace polygonálních struktur) je výše zmíněný postup bezproblémový a poskytuje polygonovou síť s parametry, které vycházejí z definice používané pro geomorfologický výzkum polygonálních struktur. V případě automatické klasifikace, která je vždy do určité míry nepřesná, výše zmíněný postup velmi záleží na zvoleném parametru velikost bufferu (parametr popsán v kapitole 3.5.2). Přesněji řečeno, na kvalitě výstupu se velmi podepisují artefakty, vzniklé špatným rozpoznáním polygonových struktur v první fázi procesu. Zejména vznik většího množství menších polygonů nebo vznik příliš velkých mezer mezi polygony způsobuje pokles kvality výstupu. Je proto účelné, v případě menších území s důrazem na kvalitu výstupu, takovéto plochy případně manuálně opravit ještě před započítáním druhé části procesu. V této práci však pro možnost porovnání nebyly žádné manuální úpravy prováděny.

V souhrnu je pro navržený proces automatické nutný vstup výzkumníka především při konkretizování parametrů klasifikační báze OBIA. Následně také při kontrole výstupu této klasifikace a při jeho případných úpravách. Určitým pracovním zatížením je též provádění úkonů v softwaru ArcGIS, přestože díky vytvořeným nástrojům se objem práce velmi zredukoval. Vzhledem k fixní povaze náročnosti mnohých uvedených kroků lze prohlásit, že pro malá území s několika (desítkami) polygonů je pravděpodobně pro výzkumníka časově výhodnější provést manuální zpracování dat. Tvorba a ověřování klasifikační báze OBIA a následné kroky se mohou vyplatit pouze při větších objemech zpracovávaných dat z dané lokality. Posuzování hranice, kdy je který způsob pro výzkumníka výhodnější, nebylo provedeno. Principiálně však ani nelze dospět k jednomu obecnému pravidlu, protože náročnost vyhotovení báze OBIA se může lišit podle charakteru zpracovávaných obrazových dat. Nelze ani vyloučit, že takové hledání bude zcela neúspěšné.

5.2 Přenositelnost navržené metodiky

Lokality, které byly testovány v této práci, byly snímány jedním senzorem a všechny se nachází na Marsu. Již po vizuálním ohodnocení však lze konstatovat, že jde o lokality s různým charakterem polygonálních struktur. Jak je diskutováno v předcházející kapitole, pro všechny snímky lze použít obecný postup pro realizaci OBIA klasifikace, který byl v této práci navržen a testován. V tomto ohledu je metodika přenositelná. Naopak parametry klasifikační báze a jednotlivých procesů se nutně liší mezi jednotlivými lokalitami i mezi různými snímky. Je zřejmé, že parametry by se lišily i pro snímky z jiných senzorů. Díky obecné podstatě metodiky je pravděpodobné, že bude poskytovat relevantní výstupy i při použití dat z jiných senzorů, za předpokladu použití dostatečných parametrů snímků. Použití na datech z jiných senzorů však nebylo provedeno. Dále je diskutována možnost využití u snímků polygonálních struktur na Zemi.

5.2.1 Pozemská data aktivních polygonálních struktur mrazových klínů

Polygonální struktury na Zemi se vyskytují v různých formách. Nejbližší paralelou podmínkám na Marsu jsou polygony v mrazových pouštích. Nejběžnější a nejvíce zkoumané struktury se však nalézají v oblasti permafrostu s aktivním vodním režimem. Právě fakt, že se alespoň po určitou část roku v polygonálních strukturách nachází kapalná voda – a to různou měrou v různých částech polygonálních struktur, přináší další potenciální informace pro rozpoznání struktur v obraze. Stejně, jako lze spektrálně rozpoznat obsah vody (zvláště v případě volné vodní hladiny v příkopech ohraničení polygonů či v jejich střezech, jak lze nalézt u některých polygonálních struktur), lze využít spektrálních vlastností vegetace. Ta se u takovýchto polygonálních struktur často vyskytuje v odlišném druhovém složení či v různém objemu v různých částech polygonu. Jedním z vhodných kandidátů pro vstupní parametry postupu pro OBIA klasifikaci navrženého v této práci tak mohou být různé vegetační indexy – např. nejčastěji používaný NDVI.

5.2.2 Fosilní polygonové struktury v Česku

Na území Česka se nalézají fosilní polygonové struktury z doby dřívějšího studeného klimatu. Jedna z lokalit se nachází jižně od Kostomlat pod Řípem (viz Obrázek 25).


Obrázek 25: Fosilní polygonální struktury u Kostomlat pod Řípem



Snímek z roku 2006 s polygonálními strukturami patrnými ve vegetaci jižně od Kostomlat pod Řípem
Zdroj: Geodis s.r.o., Google Maps

Lokality fosilních polygonů v Česku se nacházejí v nižších nadmořských výškách. Proto jsou v mnoha případech rozorány a vrchní vrstva půdy je tak bez zjevných polygonálních struktur. K jejich identifikaci a zvýraznění může docházet díky jevům známým z archeologických průzkumů. Pohřbený substrát a jeho složení ovlivňuje růst vegetace. Za vhodných podmínek tak lze ze snímků daného území dané struktury pozorovat. Obvykle je to však možné pouze za určitých podmínek (viz srovnání Obrázek 25 a Obrázek 26 zobrazujícího stejné území).

Obrázek 26: Území s prokázanými fosilními polygonálními strukturami



Snímek území s prokázanými polygonálními strukturami (odpovídá území na obrázku 25) z roku 2010
Zdroj: Geodis s.r.o., Mapy.cz

Pro aplikaci metodiky navržené v této práci by tak bylo potřeba především nasnímat dané území za vhodných podmínek. Nebyl však proveden výzkum, který by tyto podmínky definoval. Také vzhledem k menším rozměrům fosilních polygonů v Česku je třeba velmi vysokého prostorového rozlišení, které lze v praxi získat pouze leteckým snímkováním. Z důvodu vegetační povahy spektrálních vlastností umožňujících v konkrétních případech struktury rozpoznat, se jako velmi vhodné parametry do metodiky navržené v této práci jeví vegetační indexy. Ty jsou založeny na snímání v pásmu NIR, které se na území Česka provádí teprve v posledních několika letech. Pořizování speciálních snímků pro možnost automatického rozpoznávání polygonálních struktur je zcela jasně finančně nerentabilní. V tomto ohledu je jednoznačnou volbou manuální vektorizace polygonů. V případě dat relevantních pro

identifikaci polygonálních struktur dostupných bez podstatných finančních nákladů by ale jejich zpracování mohlo proběhnout v souladu s navrženou metodikou.

6 Závěr

Výsledky práce prokázaly, že pro identifikaci a klasifikaci polygonálních struktur mrazových polygonů je vhodné použití objektového přístupu zpracování dat dálkového průzkumu. Klasický pixelový přístup poskytuje použitelné výsledky pouze za velmi úzce vymezených podmínek. V práci byla navržena obecná metodika objektové klasifikace obrazových dat polygonálních struktur. Důležitou složkou navržené metodiky je použití prostorových příznaků, zejména tvaru objektů, a možnost efektivně limitovat maximální velikost objektu v obraze. Testovaný vliv předzpracování obrazu nízkofrekvenčními filtry na výslednou klasifikaci neposkytl jednoznačný výsledek a jako nejdůležitější aspekt bylo identifikováno přesné nastavení parametrů klasifikační báze OBIA. Navržená metodika byla otestována na třech lokalitách na Marsu. Pro tyto tři lokality byly také stanoveny konkrétní parametry metodiky.

Jak ukazují jednotlivé výsledky, parametry je nutné stanovit pro každou zpracovávanou lokalitu separátně. Vzhledem k časové náročnosti tohoto úkonu se navržená metodika hodí pro plánované zpracování většího množství polygonálních struktur mrazových klínů. Při zpracovávání menšího objemu dat je pro výzkumníka komfortnější provést manuální zpracování dat, které se nyní v geomorfologickém výzkumu používá.

V rámci práce byly dále připraveny nástroje určené pro software ArcGIS, které do velké míry automatizují zpracování klasifikovaných dat. Pro vytvoření polygonové sítě byl připraven algoritmus a otestovány jeho parametry s doporučením jejich hodnoty při běžném použití těchto nástrojů. Pro správnou funkčnost připravených nástrojů je důležitá kvalita vstupních dat. V některých případech může být pro dosažení dobrého výsledku účelné provést kontrolu a případnou manuální úpravu klasifikovaných dat před automatickým vytvořením polygonové sítě.

Dalším výstupem práce je nástroj pro automatické doplnění statistických dat v rámci polygonové sítě. Všechny tyto nástroje pro ArcGIS jsou přílohou této práce pro další využití v geomorfologickém výzkumu.

Navržená metodika se osvědčila na testovaných lokalitách na Marsu. Vzhledem k obecné povaze metodiky lze předpokládat, že při stanovení vhodných parametrů je možné výsledky této práce použít i pro výzkum polygonálních struktur na Zemi.

SEZNAM ZDROJŮ INFORMACÍ

- Aksoy, S., Younan, N. H., & Bruzzone, L. (2010). Pattern Recognition in Remote Sensing. *Pattern Recognition Letters*, 31(10), 1069–1070. doi:10.1016/j.patrec.2010.04.014
- Baatz, M., & Schäpe, A. (2000). Multiresolution Segmentation : an optimization approach for high quality multi-scale image segmentation. Retrieved from http://www.ecognition.com/sites/default/files/405_baatz_fp_12.pdf
- Ballantyne, C. K. (2007). Patterned Ground. In S. A. Elias (Ed.), *Encyclopedia of Quaternary Science* (pp. 2182–2191). Elsevier. doi:10.1016/B0-44-452747-8/00107-1
- Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I., & Heynen, M. (2004). Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3-4), 239–258. doi:10.1016/j.isprsjprs.2003.10.002
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2–16. doi:10.1016/j.isprsjprs.2009.06.004
- Boike, J., & Yoshikawa, K. (2003). Mapping of periglacial geomorphology using kite/balloon aerial photography. *Permafrost and Periglacial Processes*, 14(1), 81–85. doi:10.1002/ppp.437
- Bromová, B. P. (2012). *Analýza hustoty lesních porostů s využitím texturálních příznaků snímků vysokého prostorového rozlišení a dat leteckého laserového skenování*. Univerzita Karlova v Praze, Přírodovědecká fakulta.
- Campbell, J. B., & Randolph, H. W. (2011). *Introduction to remote sensing* (5th editio., p. 687). New York: The Guilford Press.
- CCRS. (n.d.). Tutorial: Fundamental of Remote Sensing. *Canada Centre for Remote Sensing*. Retrieved July 15, 2013, from <http://www.nrcan.gc.ca/earth-sciences/geography-boundary/remote-sensing/fundamentals/1430>
- Dobrovolný, P. (1998). *Dálkový průzkum Země: Digitální zpracování obrazu* (1. ed., p. 208). Brno: Masarykova univerzita.
- Drăguț, L., Eisank, C., & Strasser, T. (2011). Local variance for multi-scale analysis in geomorphometry. *Geomorphology (Amsterdam, Netherlands)*, 130(3-4), 162–172. doi:10.1016/j.geomorph.2011.03.011
- Durieux, L., Lagabrielle, E., & Nelson, A. (2008). a method for monitoring building construction in urban sprawl areas using object-based analysis of Spot 5 images and existing GIS data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(4), 399–408. doi:10.1016/j.isprsjprs.2008.01.005
- Dutilleul, P., Haltigin, T. W., & Pollard, W. H. (2009). Analysis of polygonal terrain landforms on Earth and Mars through spatial point patterns. *Environmetrics*, 20(2), 206–220. doi:10.1002/env.924

- Eliason, E., Castalia, B., Leis, R., & Becker, K. (2007). Software Interface Specification for HiRISE Experimental Data Record Products. University of Arizona and the United States Geological Survey. Retrieved from http://www.uahirise.org/pdf/HiRISE_EDR_SIS_2007_03_15.pdf
- Eliason, E., Castalia, B., Mattson, S., Heyd, R., Becker, K., Anderson, J., & Sides, S. (2011). Software Interface Specification for HiRISE Reduced Data Record Products. Retrieved from http://www.uahirise.org/pdf/HiRISE_RDR_v13_DTM.pdf
- Frye, C. (2008). Minimum Bounding Rectangle (MBR) Analysis tools. Retrieved from <http://arcscrips.esri.com/details.asp?dbid=15502>
- Gisat. (2013). Družicová data. Retrieved July 15, 2013, from <http://www.gisat.cz/content/cz/druzicova-data>
- Grosse, G., Schirrmeister, L., Siegert, C., Kunitsky, V. V., Slagoda, E. A., Andreev, A. A., & Dereviagn, A. Y. (2007). Geological and geomorphological evolution of a sedimentary periglacial landscape in Northeast Siberia during the Late Quaternary. *Geomorphology*, 86(1-2), 25–51. doi:10.1016/j.geomorph.2006.08.005
- Hallet, B., Sletten, R., & Whilden, K. (2011). Micro-relief development in polygonal patterned ground in the Dry Valleys of Antarctica. *Quaternary Research*, 75(2), 347–355. doi:10.1016/j.yqres.2010.12.009
- Haltigin, T., Pollard, W., & Dutilleul, P. (2010). Comparison of ground- and aerial-based approaches for quantifying polygonal terrain network geometry on Earth and Mars via spatial point pattern analysis. *Planetary and Space Science*, 58(12), 1636–1649. doi:10.1016/j.pss.2010.08.008
- Hjort, J., & Luoto, M. (2006). Modelling patterned ground distribution in Finnish Lapland: an integration of topographical, ground and remote sensing information. *Geografiska Annaler, Series A: Physical Geography*, 88(1), 19–29. doi:10.1111/j.0435-3676.2006.00280.x
- Hornáková, M. (2011). *Automatická extrakce budov a zpevněných ploch z dat velmi vysokého rozlišení v suburbánní zóně Prahy*. Univerzita Karlova v Praze, Přírodovědecká fakulta.
- Ke, Y., Quackenbush, L. J., & Im, J. (2010). Synergistic use of QuickBird multispectral imagery and LIDAR data for object-based forest species classification. *Remote Sensing of Environment*, 114(6), 1141–1154. doi:10.1016/j.rse.2010.01.002
- Kolář, J. (1990). *Dálkový průzkum Země* (p. 170). Praha: SNTL - Nakladatelství technické literatury.
- Kolář, J. (2008). *Principy fungování a využívání pozorovacích satelitů* (Studie., p. 62). Praha.
- Kysilka, T. (2009). *Morfologické charakteristiky polygonů ledových klínů arktické zóny*. Karlova Univerzita v Praze.
- Laliberte, a. S., Rango, a., Herrick, J. E., Fredrickson, E. L., & Burkett, L. (2007). An object-based image analysis approach for determining fractional cover of senescent and green

- vegetation with digital plot photography. *Journal of Arid Environments*, 69(1), 1–14. doi:10.1016/j.jaridenv.2006.08.016
- Langer, M., Westermann, S., & Boike, J. (2010). Spatial and temporal variations of summer surface temperatures of wet polygonal tundra in Siberia - implications for MODIS LST based permafrost monitoring. *Remote Sensing of Environment*, 114(9), 2059–2069. doi:10.1016/j.rse.2010.04.012
- Levy, J., Head, J., & Marchant, D. (2009). Thermal contraction crack polygons on Mars: Classification, distribution, and climate implications from HiRISE observations. *Journal of Geophysical Research*, 114(E1), 1–19. doi:10.1029/2008JE003273
- Levy, J. S., Marchant, D. R., & Head, J. W. (2010). Thermal contraction crack polygons on Mars: a synthesis from HiRISE, Phoenix, and terrestrial analog studies. *Icarus*, 206(1), 229–252. doi:10.1016/j.icarus.2009.09.005
- Lillesand, T. M., & Kiefer, R. W. (1994). *Remote sensing and image interpretation. Distribution* (3. ed., Vol. 3rd, p. 750). New York: John Wiley & Son, Inc. Retrieved from http://www.osti.gov/energycitations/product.biblio.jsp?osti_id=6028047
- Malin, M. C., Edgett, K. S., Cantor, B. A., Caplinger, M. A., Danielson, G. E., Jensen, E. H., ... Supulver, K. D. (2010). An overview of the 1985 – 2006 Mars Orbiter Camera science investigation. *Mars - The International Journal of Mars Science and Exploration*, 5, 1–60. doi:10.1555/mars.2010.0001
- Mallinis, G., Koutsias, N., Tsakiri-Strati, M., & Karteris, M. (2008). Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(2), 237–250. doi:10.1016/j.isprsjprs.2007.08.007
- Mangold, N. (2005). High latitude patterned grounds on Mars: Classification, distribution and climatic control. *Icarus*, 174(2), 336–359. doi:10.1016/j.icarus.2004.07.030
- Mellon, M. T., Feldman, W. C., & Prettyman, T. H. (2004). The presence and stability of ground ice in the southern hemisphere of Mars. *International Journal of Solar System Studies*, 169(2), 324–340. doi:10.1016/j.icarus.2003.10.022
- Murton, J. (2007). Ice Wedges and Ice Wedge Casts. In S. A. Elias (Ed.), *Encyclopedia of Quaternary Science* (pp. 2153–2170). Elsevier. doi:10.1016/B0-44-452747-8/00108-3
- Muster, S., Langer, M., Heim, B., Westermann, S., & Boike, J. (2012). Subpixel heterogeneity of ice-wedge polygonal tundra: a multi-scale analysis of land cover and evapotranspiration in the Lena River Delta, Siberia. *Tellus B*, 64, 1–19. doi:10.3402/tellusb.v64i0.17301
- Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S., & Weng, Q. (2011). Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, 115(5), 1145–1161. doi:10.1016/j.rse.2010.12.017
- Pikora, J. (2008). *Implementace grafických filtrů pro zpracování rastrového obrazu*. Masarykova Univerzita.

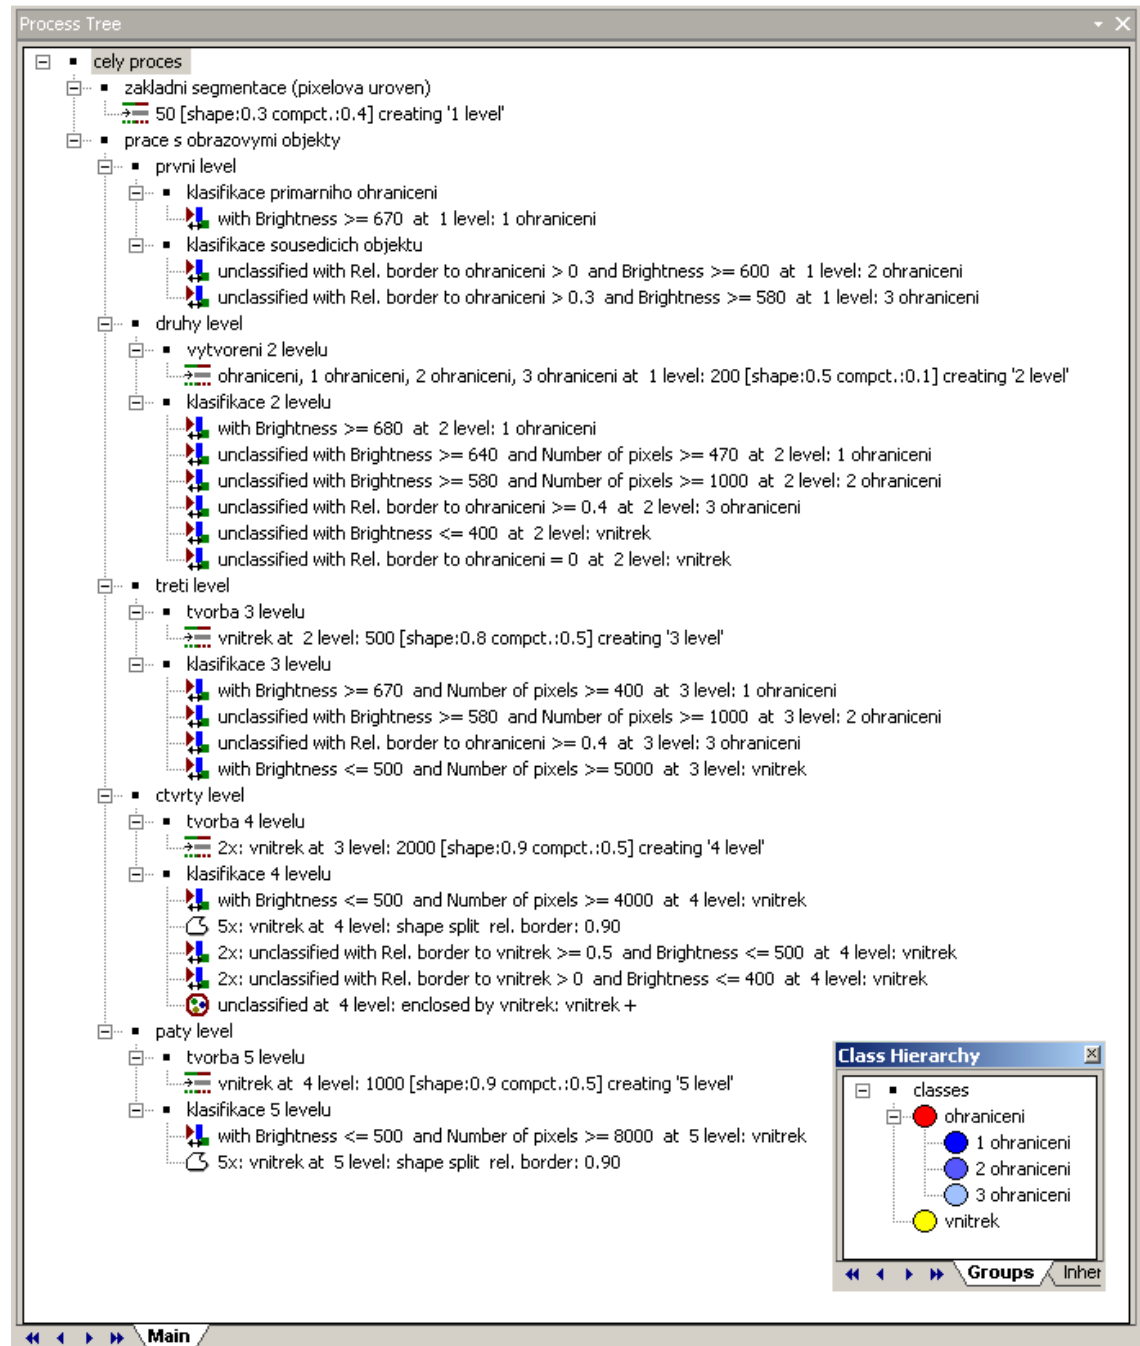
- Repaka, S. R., Truax, D. D., State, M., Kolstad, E., & Manager, C. (2004). Comparing spectral and object based approaches for classification and transportation feature extraction from high resolution multispectral imagery. In *ASPRS Annual Conference Proceedings*. Retrieved from http://www.ecognition.com/sites/default/files/312_asprs_2004_0204.pdf
- Snyder, C. (2009). SuperRegionPoly v93. ArcSript Library. Retrieved from <http://arcscripts.esri.com/details.asp?dbid=16700>
- Stow, D., Hope, A., McGuire, D., Verbyla, D., Gamon, J., Huemrich, F., ... Myneni, R. (2004). Remote sensing of vegetation and land-cover change in Arctic Tundra Ecosystems. *Remote Sensing of Environment*, 89(3), 281–308. doi:10.1016/j.rse.2003.10.018
- Tilton, J. C. (1999). Utilization of New Data Products based on Hierarchical Segmentation of Remotely Sensed Imagery Data in Earth Science Enterprise Applications. Retrieved July 20, 2013, from http://science.gsfc.nasa.gov/606.3/TILTON/publications/white_paper/index.html
- Trimble. (2012a). eCognition User Guide.
- Trimble. (2012b). eCognition Reference book.
- Ulrich, M., Hauber, E., Herzsuh, U., Härtel, S., & Schirrmeister, L. (2011). Polygon pattern geomorphometry on Svalbard (Norway) and western Utopia Planitia (Mars) using high-resolution stereo remote-sensing data. *Geomorphology*, 134(3-4), 197–216. doi:10.1016/j.geomorph.2011.07.002
- Verhagen, P., & Drăguț, L. (2012). Object-based landform delineation and classification from DEMs for archaeological predictive mapping. *Journal of Archaeological Science*, 39(3), 698–703. doi:10.1016/j.jas.2011.11.001

SEZNAM PŘÍLOH

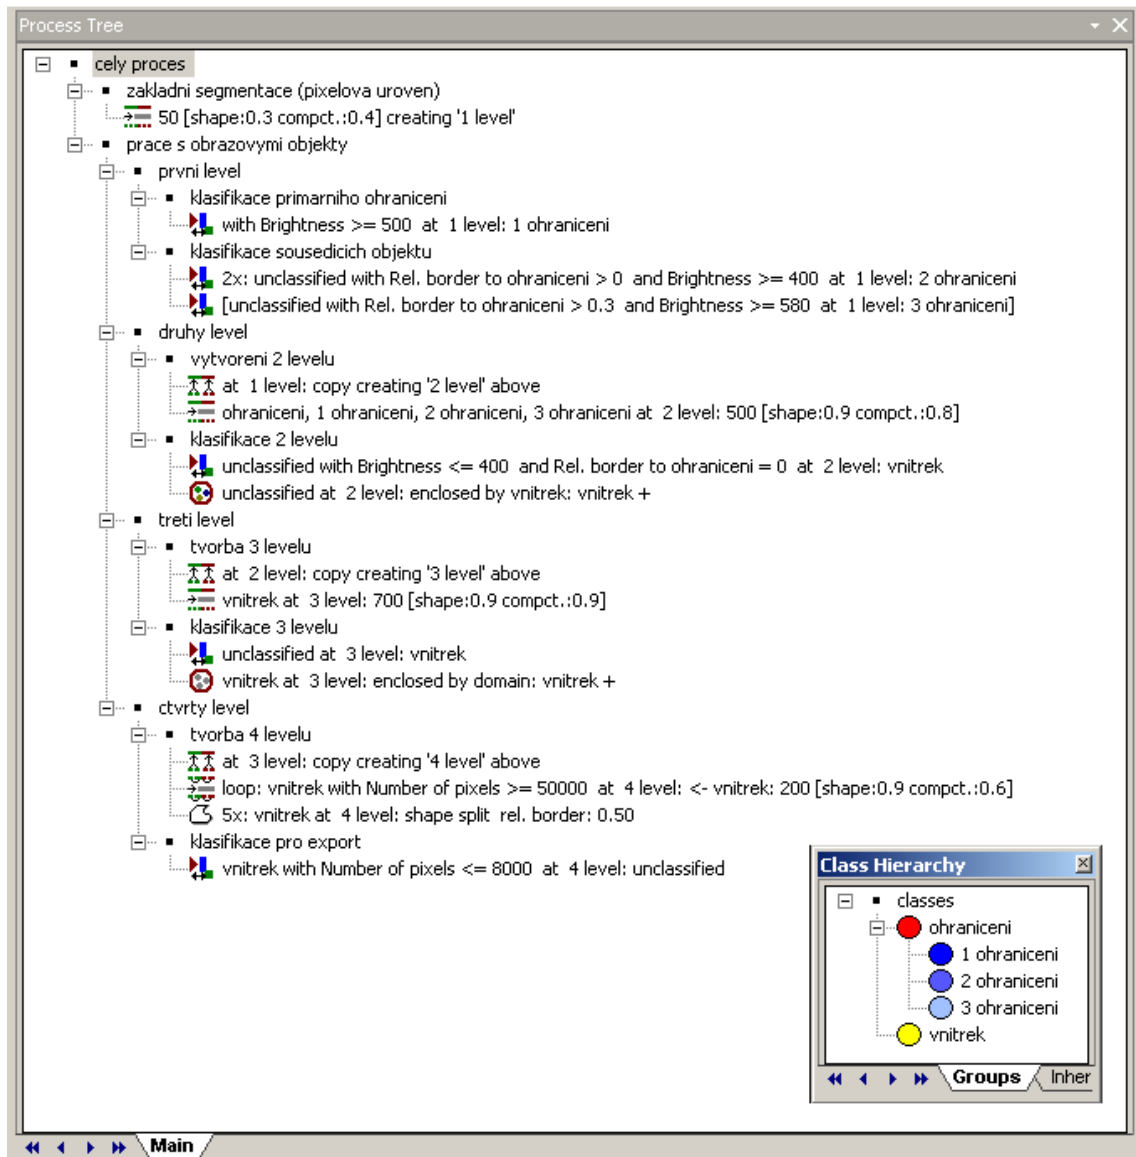
Příloha 1	Klasifikační báze OBIA	73
Příloha 1.1	Klasifikační báze pro zpracovávanou část snímku ESP_016641_2500 při použití originálních dat	73
Příloha 1.2	Klasifikační báze pro zpracovávanou část snímku ESP_016641_2500 při použití filtrovaných dat (low pass median filtr 27)	74
Příloha 1.3	Klasifikační báze pro zpracovávanou část snímku ESP_032060_0970 při použití originálních dat	75
Příloha 1.4	Klasifikační báze pro zpracovávanou část snímku ESP_032060_0970 při použití filtrovaných dat (low pass median filtr 9)	76
Příloha 1.5	Klasifikační báze pro zpracovávanou část snímku PSP_007674_2240 při použití originálních dat	77
Příloha 1.6	Klasifikační báze pro zpracovávanou část snímku PSP_007674_2240 při použití filtrovaných dat (low pass median filtr 15)	78
Příloha 2	Algoritmy použité ke zpracování výsledků klasifikace v prostředí ArcGIS	79
Příloha 2.1	Algoritmus k vygenerování průsečíků ohraničení vstupních polygonů	79
Příloha 2.2	Algoritmus k vygenerování zjednodušených polygonů z průsečíků ohraničení	80
Příloha 2.3	Algoritmus pro úpravu zjednodušených polygonů (odstranění překrytí)	81
Příloha 2.4	Algoritmus pro výpočet a připojení statistik polygonů do atributové tabulky	82
Příloha 3	Mapy výsledné klasifikace (lokalita A)	83
Příloha 3.1	Zpracovávaná data s vyznačenými průsečíky ohraničení vstupních polygonů	83
Příloha 3.2	Vyhodnocení na základě manuální vektorizace	84
Příloha 3.3	Vyhodnocení na základě klasifikace OBIA nad originálními daty	85
Příloha 3.4	Vyhodnocení na základě klasifikace OBIA nad filtrovanými daty	86
Příloha 4	Mapy výsledné klasifikace (lokalita B)	87
Příloha 4.1	Zpracovávaná data s vyznačenými průsečíky ohraničení vstupních polygonů	87
Příloha 4.2	Vyhodnocení na základě manuální vektorizace	88
Příloha 4.3	Vyhodnocení na základě klasifikace OBIA nad originálními daty	89
Příloha 4.4	Vyhodnocení na základě klasifikace OBIA nad filtrovanými daty	90
Příloha 4.5	Vyhodnocení na základě pixelové klasifikace nad filtrovanými daty	91
Příloha 5	Mapy výsledné klasifikace (lokalita C)	92
Příloha 5.1	Zpracovávaná data s vyznačenými průsečíky ohraničení vstupních polygonů	92
Příloha 5.2	Vyhodnocení na základě manuální vektorizace	93
Příloha 5.3	Vyhodnocení na základě klasifikace OBIA nad originálními daty	94
Příloha 5.4	Vyhodnocení na základě klasifikace OBIA nad filtrovanými daty	95
Příloha 6	Souhrnné porovnání výsledků klasifikace polygonů	96

Příloha 1 Klasifikační báze OBIA

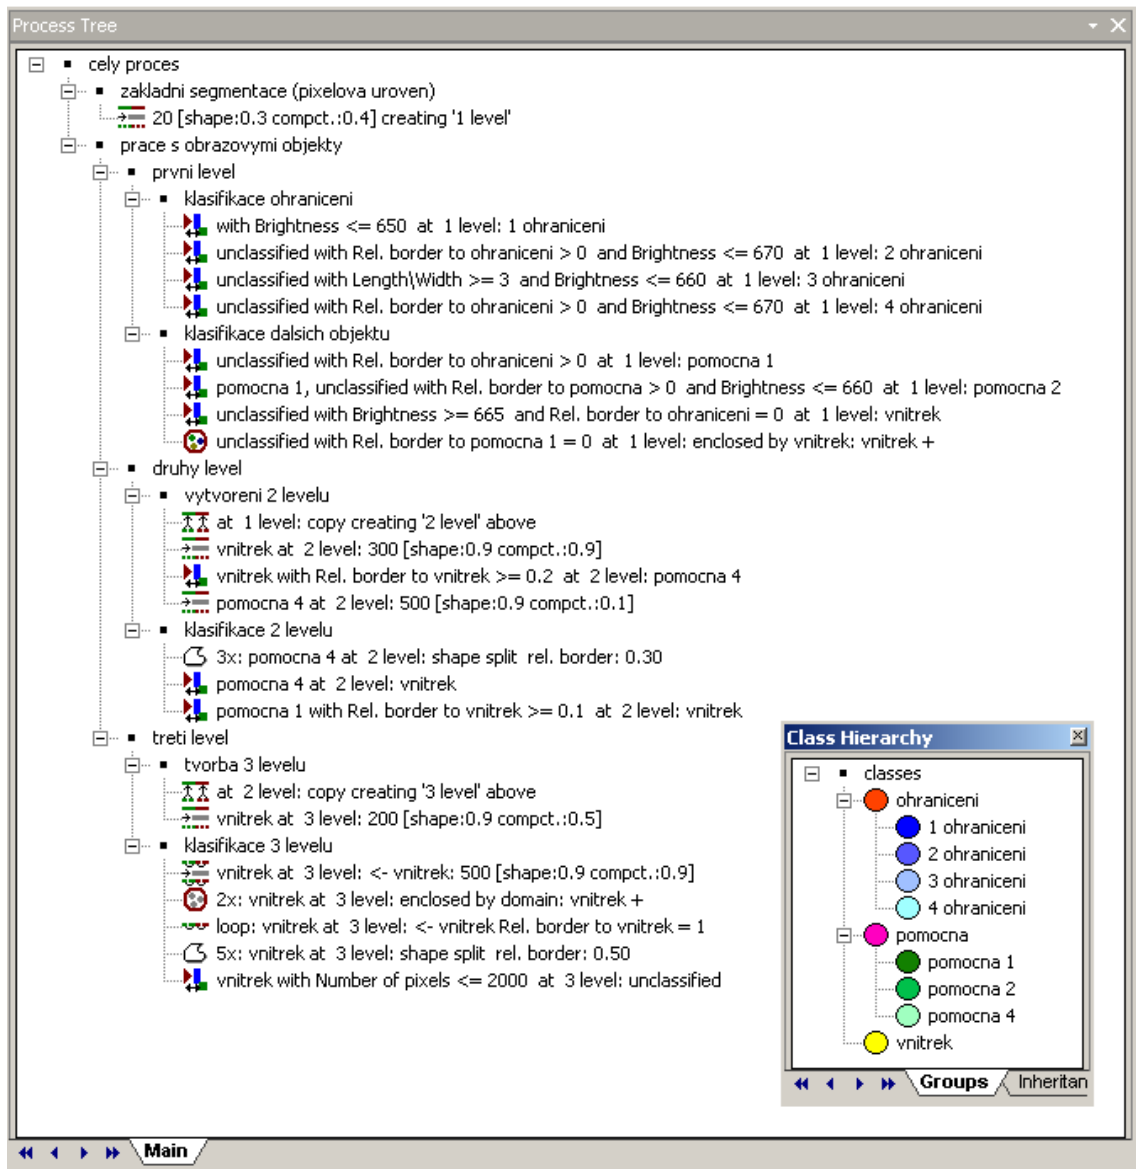
Příloha 1.1 Klasifikační báze pro zpracovávanou část snímku ESP_016641_2500 při použití originálních dat



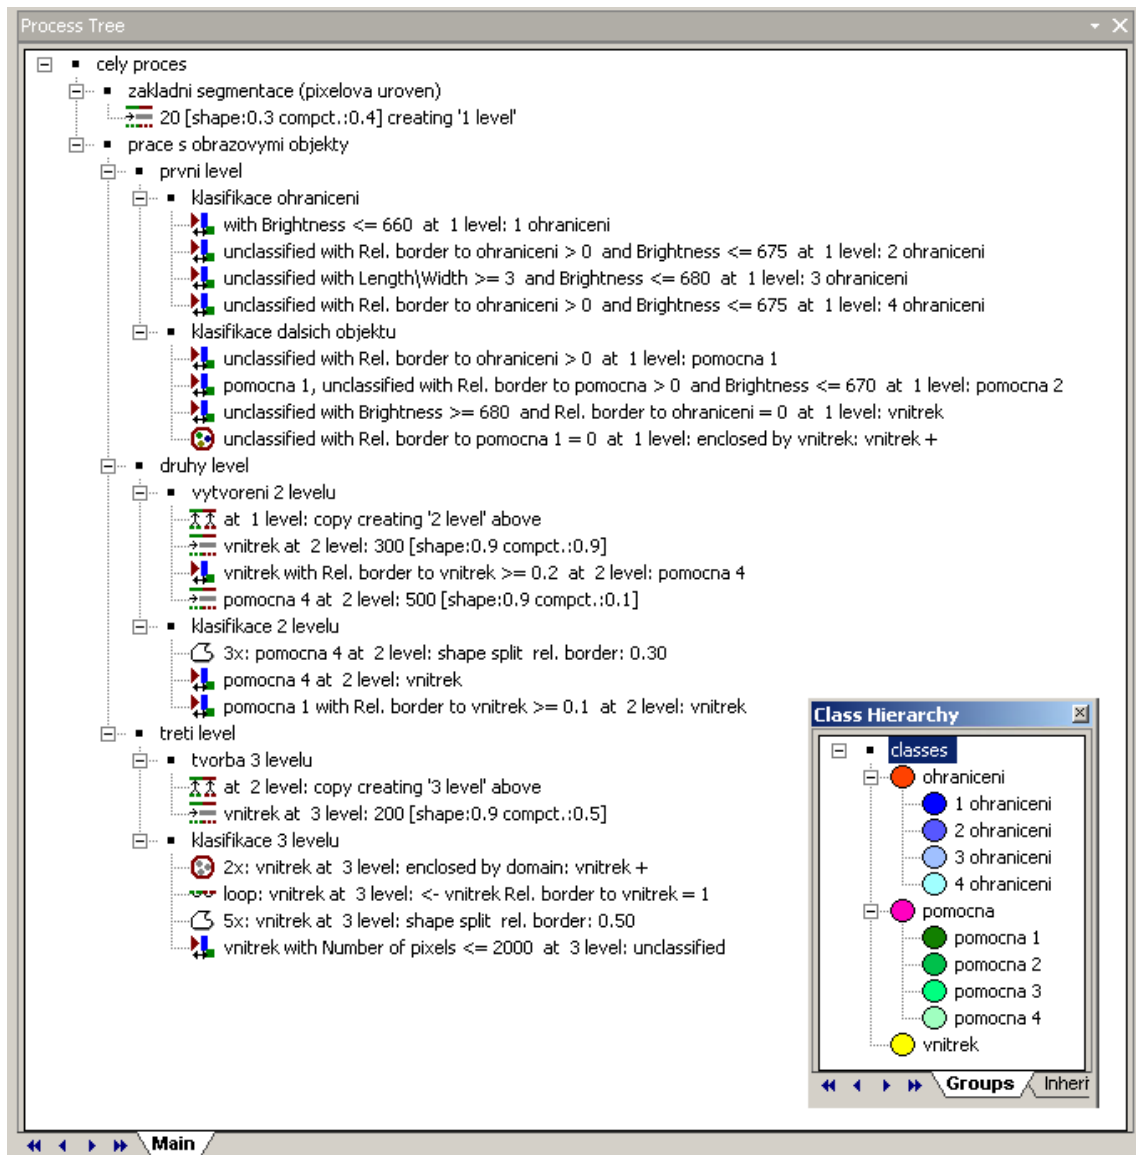
Příloha 1.2 Klasifikační báze pro zpracovávanou část snímku ESP_016641_2500 při použití filtrovaných dat (low pass median filtr 27)



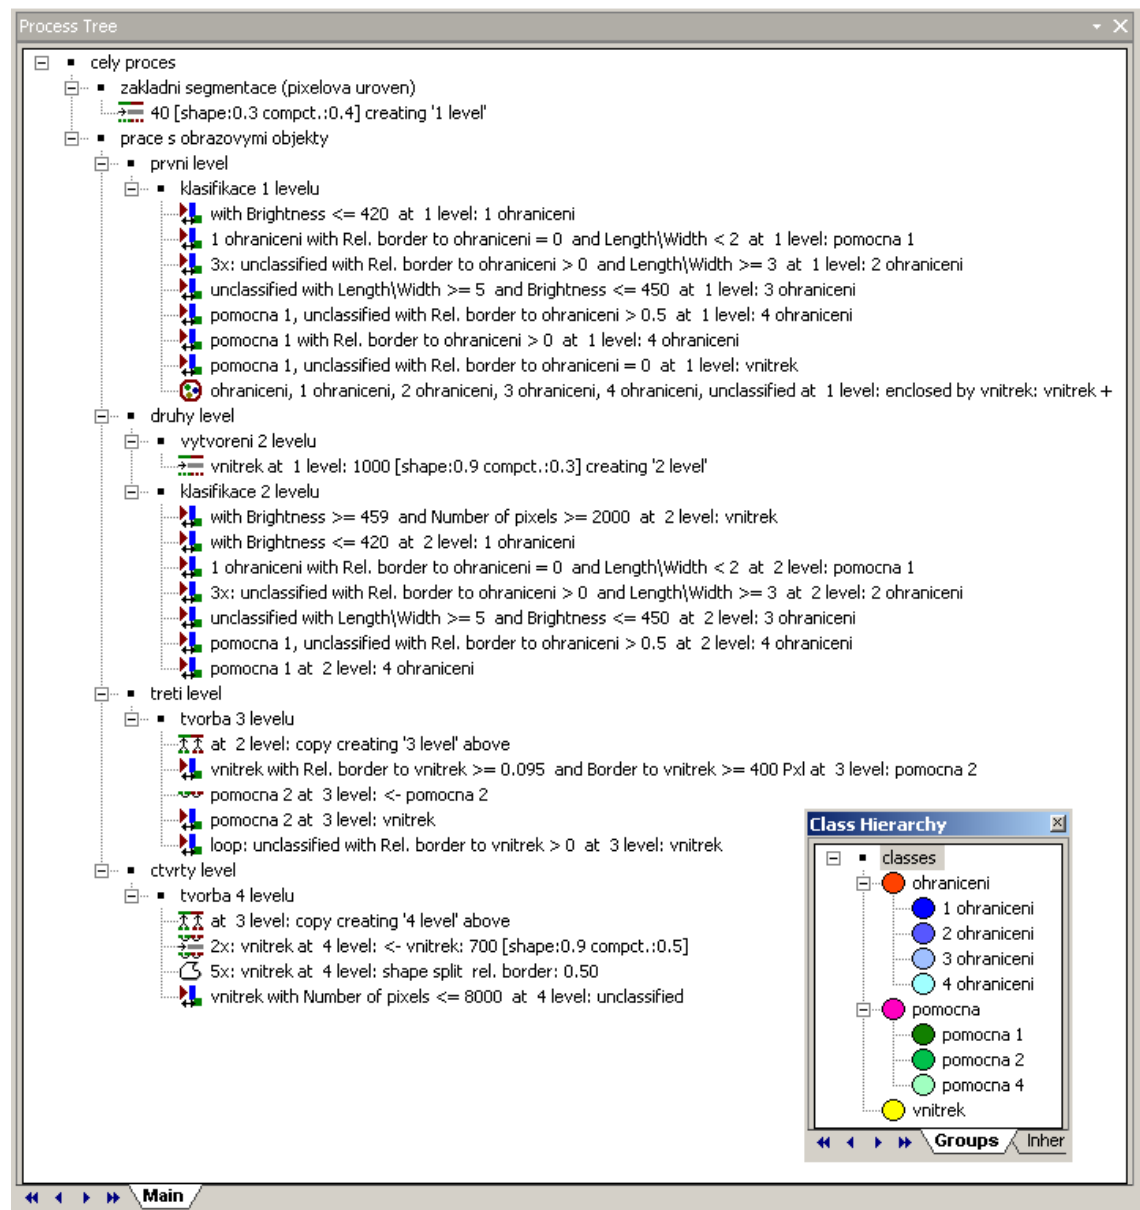
Příloha 1.3 Klasifikační báze pro zpracovávanou část snímku ESP_032060_0970 při použití originálních dat



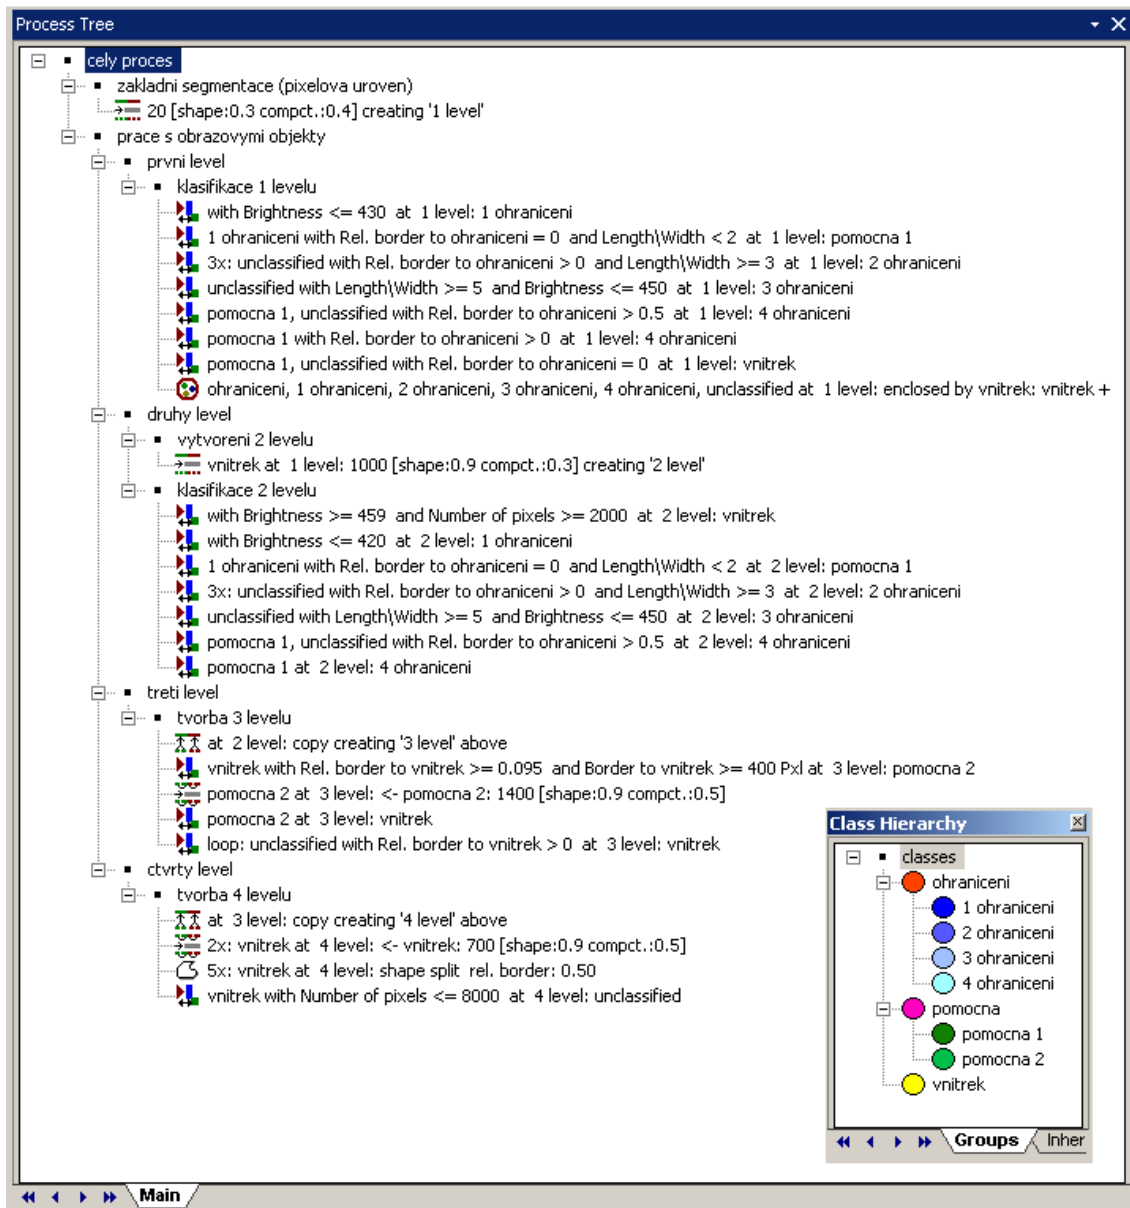
Příloha 1.4 Klasifikační báze pro zpracovávanou část snímku ESP_032060_0970 při použití filtrovaných dat (low pass median filtr 9)



Příloha 1.5 Klasifikační báze pro zpracovávanou část snímku PSP_007674_2240 při použití originálních dat

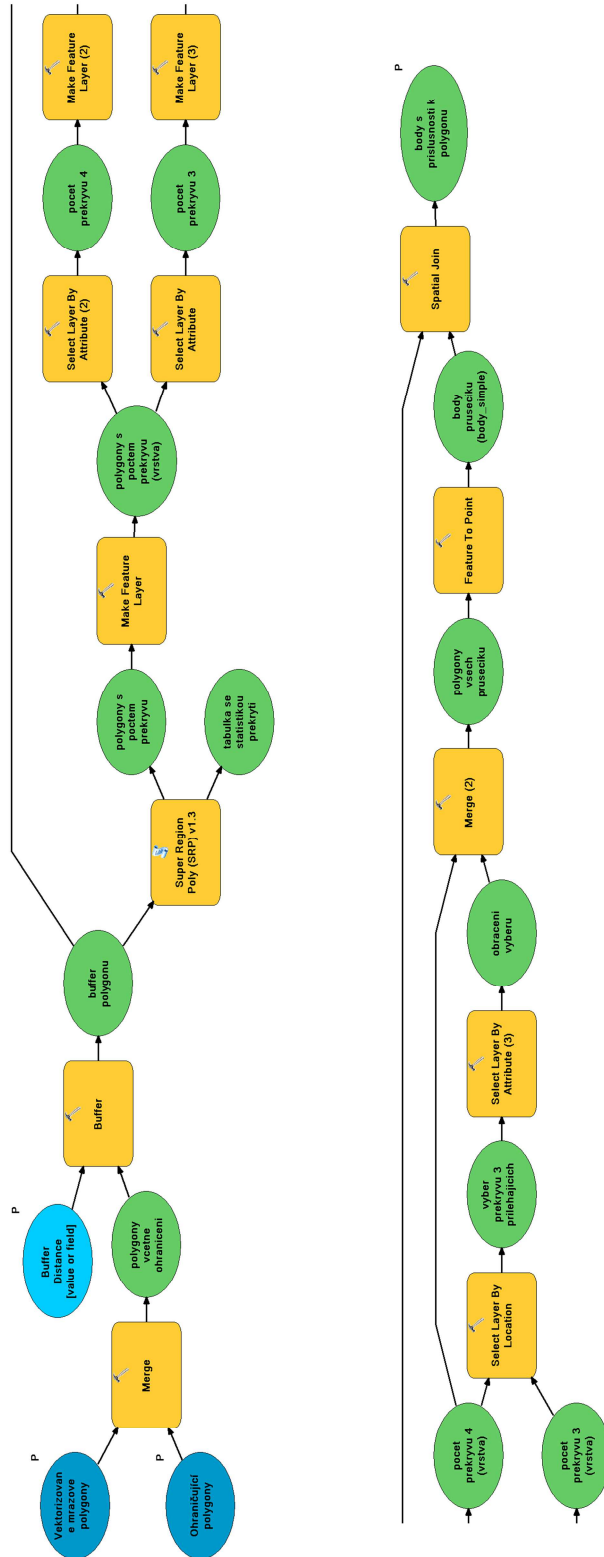


Příloha 1.6 Klasifikační báze pro zpracovávanou část snímku PSP_007674_2240 při použití filtrovaných dat (low pass median filtr 15)

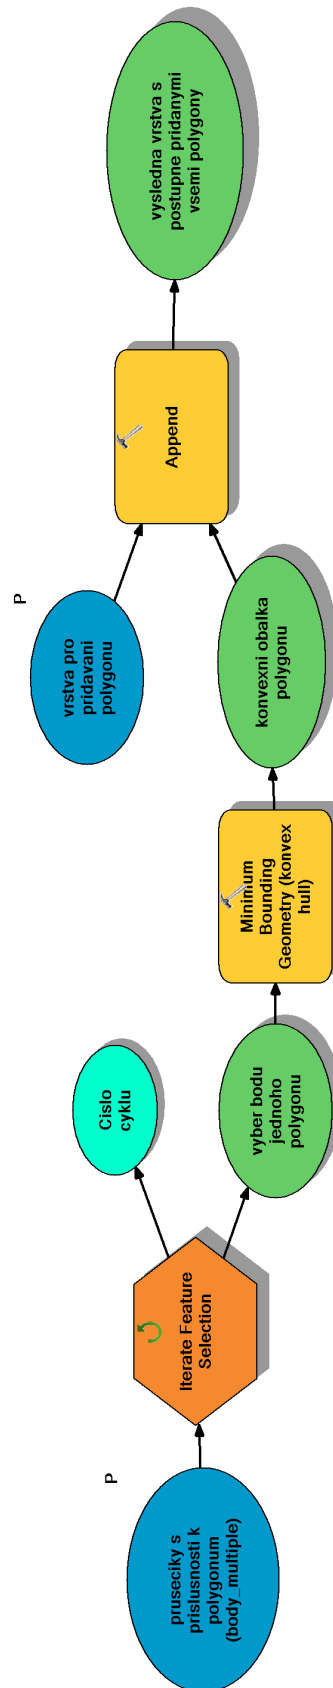


Příloha 2 Algoritmy použité ke zpracování výsledků klasifikace v prostředí ArcGIS

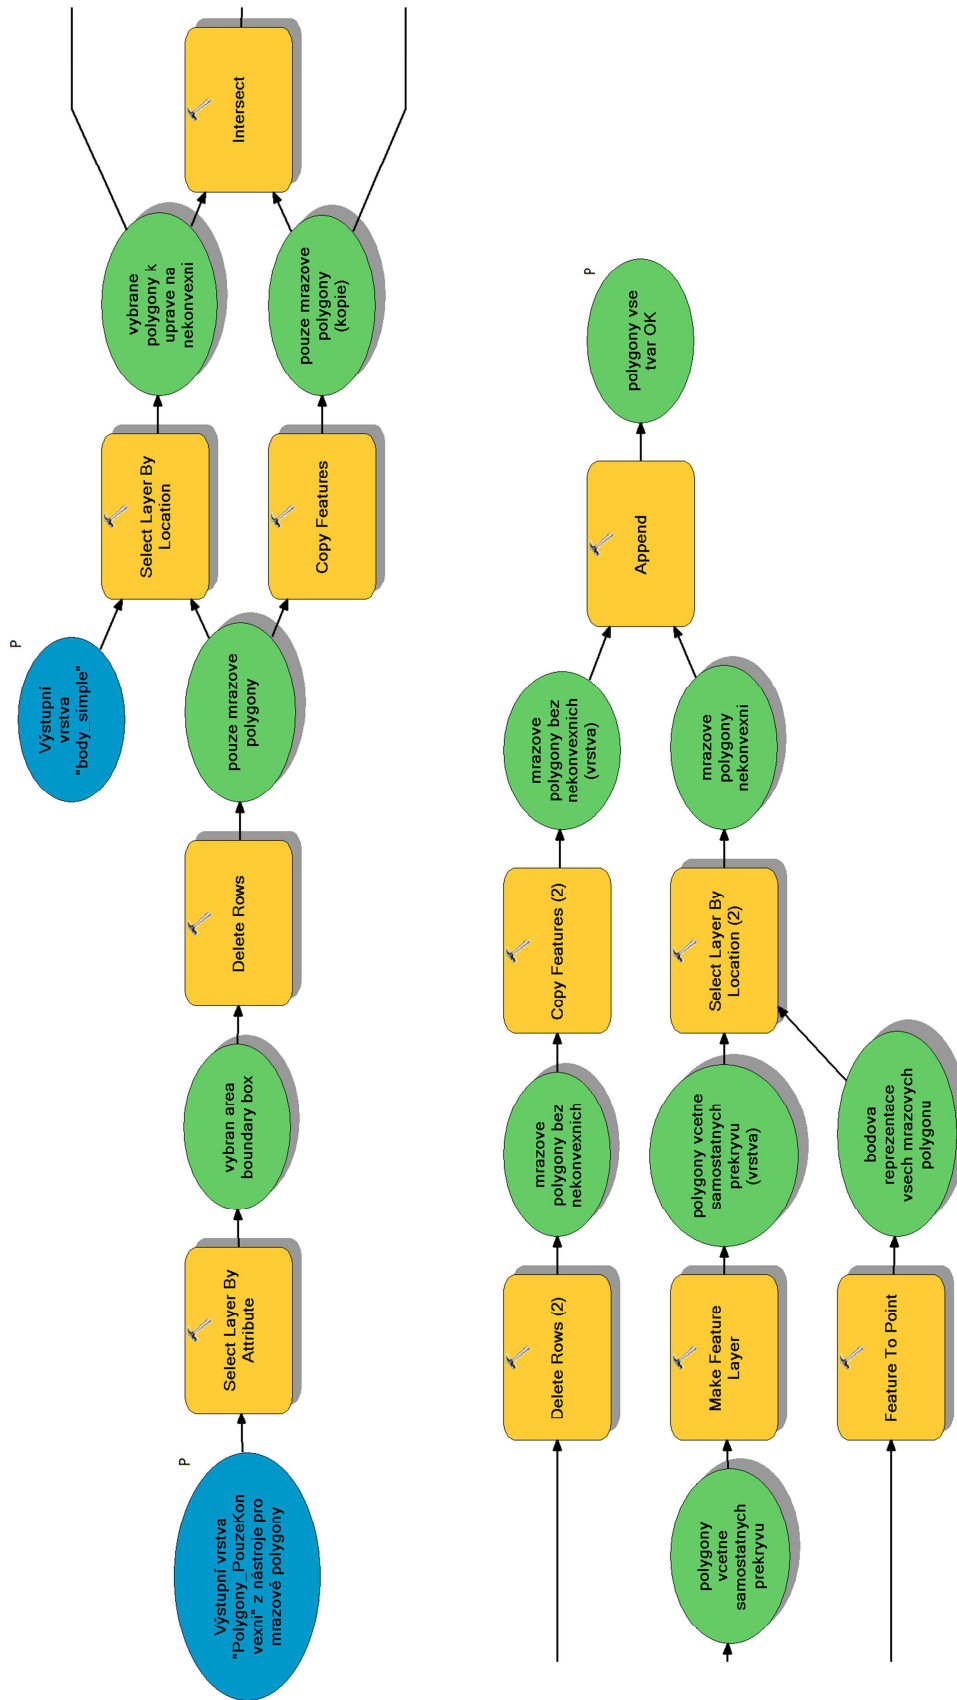
Příloha 2.1 Algoritmus k vygenerování průsečíků ohraničení vstupních polygonů



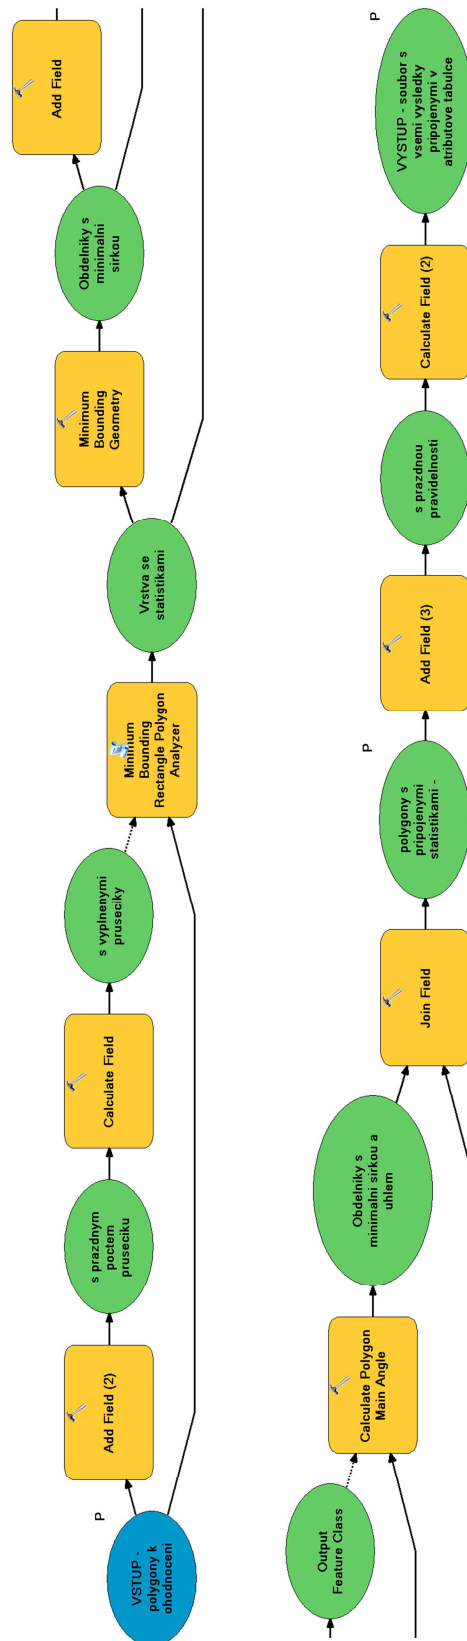
Příloha 2.2 Algoritmus k vygenerování zjednodušených polygonů z průsečíků ohraničení



Příloha 2.3 Algoritmus pro úpravu zjednodušených polygonů (odstranění překrytí)



Příloha 2.4 Algoritmus pro výpočet a připojení statistik polygonů do atributové tabulky




Příloha 3 Mapy výsledné klasifikace (lokalita A)

Příloha 3.1 Zpracovávaná data s vyznačenými průsečíky ohraničení vstupních polygonů

ZPRACOVÁVANÁ OBRAZOVÁ DATA S VYZNAČENÍM PRŮSEČÍKŮ POLYGONŮ


Polygonální struktury na Marsu na 69.79° s. š. a 64.92° v. d.



Příloha 3.2 Vyhodnocení na základě manuální vektorizace

INTERPRETACE NA ZÁKLADĚ MANUÁLNÍ VEKTORIZACE

Polygonální struktury na Marsu na 69,79° s. š. a 64,92° v. d.




příloha diplomové práce
Jan KŘÍŽ
Praha 2013

Zdroj dat: HIRISE, Mars Reconnaissance Orbiter, NASA/JPL/University of Arizona
vlastní šetření autora

Příloha 3.3 Vyhodnocení na základě klasifikace OBIA nad originálními daty

OBJEKTOVÁ KLASIFIKACE APLIKOVANÁ NA ORIGINÁLNÍ DATA

Polygonální struktury na Marsu na 69.79° s. š. a 64.92° v. d.




Zdroj dat: HIRISE, Mars Reconnaissance Orbiter, NASA/JPL/University of Arizona
vlastní šetření autora

příloha diplomové práce
Jan KŘÍŽ
Praha 2013

Příloha 3.4 Vyhodnocení na základě klasifikace OBIA nad filtrovanými daty

OBJEKTOVÁ KLASIFIKACE APLIKOVANÁ NA FILTROVANÁ DATA

Polygonální struktury na Marsu na 69.79° s. š. a 64.92° v. d.

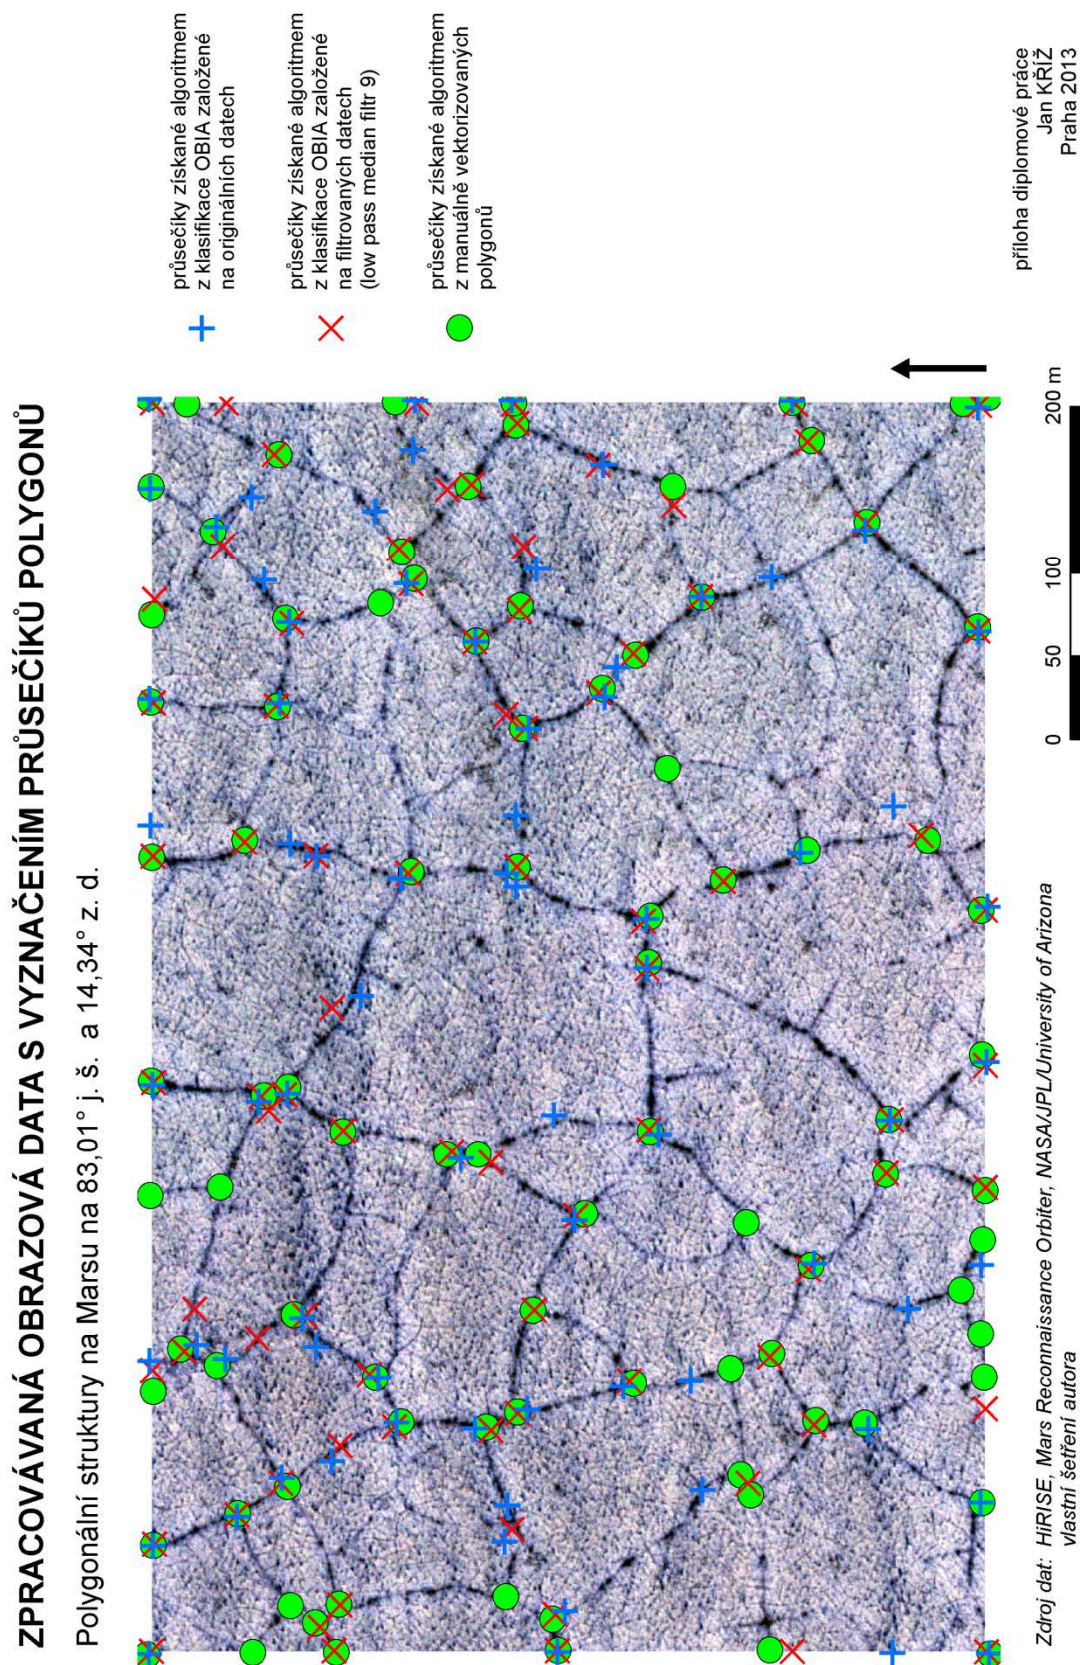


příloha diplomové práce
Jan KŘÍŽ
Praha 2013

Zdroj dat: HIRISE, Mars Reconnaissance Orbiter, NASA/JPL/University of Arizona
vlastní šetření autora

Příloha 4 Mapy výsledné klasifikace (lokalita B)


Příloha 4.1 Zpracovávaná data s vyznačenými průsečíky ohraničení vstupních polygonů



Příloha 4.2 Vyhodnocení na základě manuální vektorizace

INTERPRETACE NA ZÁKLADĚ MANUÁLNÍ VEKTORIZACE

Polygonální struktury na Marsu na 83,01° j. š. a 14,34° z. d.



Zdroj dat: HIRISE, Mars Reconnaissance Orbiter, NASA/JPL/University of Arizona
vlastní šetření autora


0 50 100 200 m

příloha diplomové práce
Jan KŘÍŽ
Praha 2013

Příloha 4.3 Vyhodnocení na základě klasifikace OBIA nad originálními daty

OBJEKTOVÁ KLASIFIKACE APLIKOVANÁ NA ORIGINÁLNÍ DATA

Polygonální struktury na Marsu na 83,01° j. š. a 14,34° z. d.




příloha diplomové práce
Jan KŘÍŽ
Praha 2013

Zdroj dat: HIRISE, Mars Reconnaissance Orbiter, NASA/JPL/University of Arizona
vlastní šetření autora

Příloha 4.4 Vyhodnocení na základě klasifikace OBIA nad filtrovanými daty

OBJEKTOVÁ KLASIFIKACE APLIKOVANÁ NA FILTROVANÁ DATA


Polygonální struktury na Marsu na 83,01° j. š. a 14,34° z. d.



Příloha 4.5 Vyhodnocení na základě pixelové klasifikace nad filtrovanými daty

PIXELOVÁ KLASIFIKACE APLIKOVANÁ NA FILTROVANÁ DATA

Polygonální struktury na Marsu na 69.79° s. š. a 64.92° v. d.



příloha diplomové práce
Jan KŘÍŽ
Praha 2013


Zdroj dat: HIRISE, Mars Reconnaissance Orbiter, NASA/JPL/University of Arizona
vlastní šetření autora

Příloha 5 Mapy výsledné klasifikace (lokalita C)

Příloha 5.1 Zpracovávaná data s vyznačenými průsečíky ohraničení vstupních polygonů

ZPRACOVÁVANÁ OBRAZOVÁ DATA S VYZNAČENÍM PRŮSEČÍKŮ POLYGONŮ

Polygonální struktury na Marsu na 43,51° s. š. a 87,13° v. d.




příloha diplomové práce
Jan KŘÍŽ
Praha 2013

Zdroj dat: HiRISE, Mars Reconnaissance Orbiter, NASA/JPL/University of Arizona
vlastní šetření autora

Příloha 5.2 Vyhodnocení na základě manuální vektorizace

INTERPRETACE NA ZÁKLADĚ MANUÁLNÍ VEKTORIZACE

Polygonální struktury na Marsu na 43,51° s. š. a 87,13° v. d.



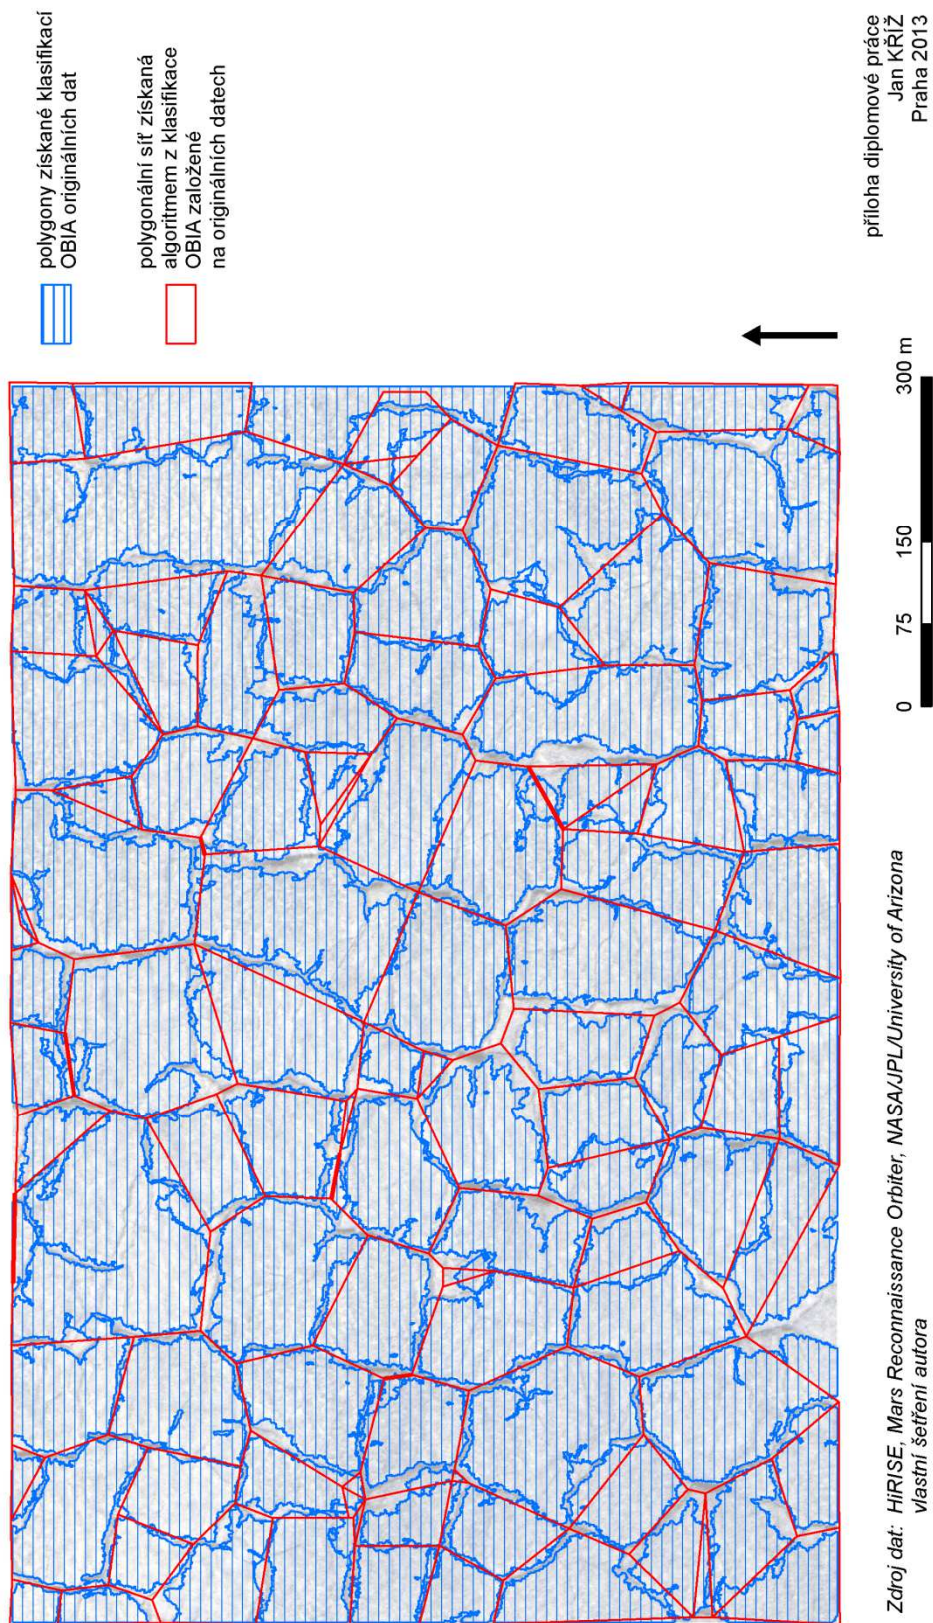
příloha diplomové práce
Jan Kříž
Praha 2013

Zdroj dat: HIRISE, Mars Reconnaissance Orbiter, NASA/JPL/University of Arizona
vlastní šetření autora

Příloha 5.3 Vyhodnocení na základě klasifikace OBIA nad originálními daty

OBJEKTOVÁ KLASIFIKACE APLIKOVANÁ NA ORIGINALNÍ DATA

Polygonální struktury na Marsu na 43,51° s. š. a 87,13° v. d.



Příloha 5.4 Vyhodnocení na základě klasifikace OBIA nad filtrovanými daty

OBJEKTOVÁ KLASIFIKACE APLIKOVANÁ NA FILTROVANÁ DATA

Polygonální struktury na Marsu na 43,51° s. š. a 87,13° v. d.

