

UNIVERZITA KARLOVA V PRAZE

Přírodovědecká fakulta

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie

Studijní obor: Geografie a kartografie



**VYUŽITÍ RADAROVÝCH DAT V KLASIFIKACI
LAND COVER / LAND USE**

Bakalářská práce

Jan Gerschon

Vedoucí bakalářské práce: RNDr. Přemysl Štych Ph.D.

Praha 2015

Vysoká škola: Univerzita Karlova v Praze
Katedra: Aplikované geoinformatiky a kartografie

Fakulta: Přírodovědecká
Školní rok: 2014/2015

Zadání bakalářské práce

pro Jana Gerschona
obor Geografie a kartografie

Název tématu: VYUŽITÍ RADAROVÝCH DAT V KLASIFIKACI LAND COVER / LAND USE

Zásady pro vypracování

Cílem této bakalářské práce je zhodnotit možnosti klasifikace zemědělsky využívané půdy pomocí radarových dat. Bakalářská práce je zaměřena na klasifikaci land use/land cover pomocí zpracování radarových dat satelitu ERS-2. Pixelová a objektově orientovaná klasifikace jsou hlavními použitými metodami klasifikace zemědělské půdy (orná půda, travnaté porosty a třída zahrnující chmelnice, vinice a ovocné sady). Klasifikace jsou testovány pro dvě vybraná zájmová území a je provedeno hodnocení přesnosti výsledné klasifikace. Předzpracování snímků proběhne v softwaru NEST a následné klasifikace v softwaru ENVI. Dosažené výsledky jsou porovnány s podobně orientovanými studii.

Rozsah grafických prací: 10 - 20

Rozsah průvodní zprávy: 40 – 60 stran

Seznam odborné literatury:

CHENEY, M., BORDEN, B. (2009): Fundamentals of radar imaging. Siam, Philadelphia, 169 s.

DOBSON, M. C. a kol. (1995): Land-cover classification and estimation of terrain attributes using synthetic aperture radar. Remote Sensing of Environment, 51, č. 1, s. 199–214.

HALOUNOVÁ, L. (2004): Klasifikace černobílých leteckých snímků a radarových dat. Habilitační práce. Katedra mapování a kartografie FSv ČVUT, PRAHA, 143 s.

ZHANG, B., HONG, W., WU, Y. (2012): Sparse microwave imaging: Principles and applications. Science China Information Sciences, 55, č. 8, s. 1722–1754.

Vedoucí bakalářské práce: RNDr. Přemysl Štych, Ph.D.

Konzultant bakalářské práce:

Datum zadání bakalářské práce: 20.1. 2015

Termín odevzdání bakalářské práce: červen 2015

Platnost tohoto zadání je po dobu jednoho akademického roku.

RNDr. Přemysl Štych, Ph.D.

.....
Vedoucí bakalářské práce

RNDr. Přemysl Štych, Ph.D.

.....
Vedoucí katedry

V Praze dne 20.1. 2015

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně a že jsem všechny použité prameny řádně citoval. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

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 30. 6. 2015

.....

Jan Gerschon

Poděkování

Rád bych tímto poděkoval vedoucímu mé bakalářské práce RNDr. Přemyslu Štychovi Ph.D. za věnovaný čas, cenné rady a připomínky. Dále bych chtěl poděkovat Mgr. Janě Součkové za pomoc při výběru radarových dat. Evropské kosmické agentuře děkuji za jejich poskytnutí. V neposlední řadě děkuji rodině za podporu v průběhu celého studia.

Využití radarových dat v klasifikaci land use/land cover

Abstrakt

Bakalářská práce je zaměřena na zpracování a klasifikaci radarových dat. Snímky, pořízené v roce 2009 senzorem AMI-SAR umístěným na satelitu ERS-2, byly použity pro pixelovou a objektově orientovanou klasifikaci zemědělsky využívané půdy. Klasifikace byly testovány pro dvě vybraná zájmová území. Legenda byla převzata z databáze LPIS a obsahuje tři třídy – ornou půdu, travnaté porosty a třídu zahrnující chmelnice, vinice a ovocné sady. Předzpracování snímků proběhlo v softwaru NEST a následné klasifikace v softwaru ENVI. Výstupy z klasifikací byly porovnány a jako výrazně lepší se jeví objektová klasifikace využívající algoritmu SVM. Nejlepší výsledek klasifikace dosáhl celkové přesnosti 90,74 % a koeficientu Kappa 0,5.

Klíčová slova: řízená klasifikace, land use, ERS-2, SAR snímky, zemědělská půda

Radar data in the land use / land cover classification

Abstract

This bachelor thesis is focused on processing and classification of radar data. The images recorded in 2009 by the AMI-SAR sensor placed on the ERS-2 satellite were used for a pixel and object-based classification of agricultural land. The classifications were tested for two selected areas of interest. The legend was taken from the LPIS database and includes three classes – arable land, grassland and a class that involves hop fields, vineyards, and orchards. Preprocessing of the images was held in the NEST software and the subsequent classification in the ENVI software. The classification outcomes were compared and it was found out that the object classification seems to be significantly better using the SVM algorithm. The best result of the classification reached the overall accuracy of 90.74 % and the Kappa coefficient of 0.5.

Keywords: supervised classification, land use, ERS-2, agricultural land

Obsah

Seznam obrázků a tabulek	9
1 Úvod a cíle práce	10
2 Literární rešerše a úvod do problematiky	11
2.1 Dálkový průzkum Země	11
2.2 DPZ v mikrovlnné části spektra	11
2.2.1 Zobrazující radary	13
2.2.2 Prostorové rozlišení radaru	13
2.2.2.1 Příčné prostorové rozlišení	13
2.2.2.2 Azimutové prostorové rozlišení	14
2.2.3 Geometrické charakteristiky záznamů zobrazujících radarů	14
2.2.3.1 Měřítkové zkresení v šikmém směru	15
2.2.3.2 Poziční chyby způsobené nerovnostmi terénu	15
2.2.4 Parametry ovlivňující intenzitu radarového echa	17
2.3 Zpracování radarových dat	19
2.3.1 Radiometrická korekce	20
2.3.1.1 Adaptivní filtrace šumu	20
2.3.1.2 Zvětšení příznakového prostoru pomocí textury	22
2.3.2 Geometrické korekce	22
2.4 Klasifikace radarových dat	23
2.4.1 Řízená pixelová klasifikace	24
2.4.1.1 Maximální pravděpodobnost	24
2.4.2 Objektově-orientovaná klasifikace	24
2.4.2.1 Segmentace v ENVI	25
2.4.2.2 Objektová klasifikace v ENVI	25
2.4.2.3 Support Vector Machine (SVM)	26
2.4.3 Uvedení konkrétních studií land cover / land use na podstatě radarových dat	26
3 Data a metodika	31

3.1	Charakteristika zájmových území	31
3.2	Použitá data	31
3.2.1	Radarová data.....	31
3.2.2	LPIS.....	32
3.2.3	Výškopis ZABAGED	33
3.3	Předzpracování dat	33
3.3.1	Radiometrické korekce	33
3.3.1.1	Potlačení zrnité textury	33
3.3.2	Geometrické korekce	37
3.3.3	Koregistrace snímků	37
3.3.4	Zvětšení příznakového prostoru pomocí texturních měř.....	38
3.3.5	Maska zemědělsky využívané půdy.....	39
3.4	Tvorba trénovacích a validačních ploch.....	40
3.5	Pixelová klasifikace	41
3.6	Objektová klasifikace	42
3.7	Hodnocení přesnosti.....	42
4	Výsledky	44
4.1	Přesnost klasifikací.....	44
4.2	Klasifikace zemědělského land use.....	45
5	Diskuze	45
6	Závěr.....	48
	Použitá literatura.....	50
	Seznam příloh.....	55

Seznam obrázků a tabulek

Obr. 1: Výřez původního snímku a filtrovaných snímků Leeovým filtrem o velikosti kernelu 3x3, 5x5 a 9x9 pixelů	36
Obr. 2: Nastavení automatické koregistrace v programu NEST	38
Obr. 3: Ukázky výsledných texturních měř vypočtených z hlavního snímku pomocí kernelu o velikosti 9x9 pixelů	39
Obr. 4: Masky zemědělsky využívané půdy v roce 2009 pro ZÚ1 a ZÚ2	40
Obr. 5: Trénovací plochy pro zájmová území 1 a 2.....	41
Tab. 1: Přehled mikrovlnných pásem používaných radary	12
Tab. 2: Technické parametry senzoru AMI-SAR umístěného na družici ERS-2	32
Tab. 3: Hodnocení schopnosti filtrů potlačovat speckle ve snímku z 4. 5. 2009.....	35
Tab. 4: Hodnocení schopnosti filtrů potlačovat speckle ve snímku z 8. 6. 2009.....	35
Tab. 5: Počty a rozlohy trénovacích polygonů.....	41
Tab. 6: Přesnosti a kappa koeficient pixelové klasifikace ZÚ1	44
Tab. 7: Přesnosti a kappa koeficient pixelové klasifikace ZÚ2	44
Tab. 8: Přesnosti a kappa koeficient objektové klasifikace ZÚ1.....	44
Tab. 9: Přesnosti a kappa koeficient objektové klasifikace ZÚ2.....	45

1 Úvod a cíle práce

Informace o land use nebo land cover získané různými metodami dálkového průzkumu Země jsou využívány v mnoha oborech. Jedním ze způsobů získání těchto informací může být klasifikace radarových dat. Radarová data mají velký potenciál díky schopnostem mikrovln prostupovat atmosférou za zhoršených podmínek a také díky možnosti snímat zemský povrch i v noci. I přes tyto výhody nejsou radarová data využívána v takovém měřítku jako data optická. Hlavními důvody je složitý proces zpracování snímků a jejich interpretace, ale také horší dostupnost dat ve smyslu menšího počtu radarových systémů (Lusch 1999).

Cílem této bakalářské práce je zhodnotit možnosti řízené pixelové i objektově orientované klasifikace zemědělsky využívané půdy s použitím radarových snímků. Pro tento účel budou využity multitemporální VV polarizované snímky ze senzoru AMI-SAR umístěného na satelitu ERS-2. Klasifikace proběhne pro dvě vybraná území o velikosti 15x15 km. Značná část práce se zabývá zpracováním radarových dat. Tento proces je pro získání požadovaných informací velmi důležitý.

Bakalářská práce se skládá z teoretické části, metodologické části a části s výsledky. V teoretické části jsou popsány principy dálkového průzkumu Země v oblasti mikrovlnného záření, procesy předzpracování radarových dat a informace o klasifikaci snímků a použitých klasifikátorech. Dále je zde také uvedeno několik konkrétních studií land cover / land use na podstatě radarových dat. V poslední části jsou popsány a diskutovány výsledky klasifikací. Hodnocení přesnosti klasifikací bude provedeno pomocí chybových matic a dalších základních ukazatelů přesnosti. Přesnosti byly vypočítány na základě validačních dat získaných z databáze LPIS. Výsledky klasifikací budou také prezentovány pomocí čtyř mapových výstupů.

2 Literární rešerše a úvod do problematiky

2.1 Dálkový průzkum Země

Definice dálkového průzkumu Země je formulována mnoha způsoby, které se ovšem významem mnoho neliší. Obecně se jedná o způsob získávání informací o zemském povrchu a objektech na něm prostřednictvím přístrojů, které se zkoumaným povrchem či objekty sice nejsou ve fyzickém kontaktu, ale využívají odraženého či emitovaného elektromagnetického záření v jednom či více intervalech spektra (Campbell 1996 cit. v Dobrovolný 1998).

Elektromagnetické záření je podle jeho zdroje rozděleno na dva druhy. Prvním je záření Slunce, Země či samotných objektů. Pokud systémy pracují s tímto přírodním odraženým či emitovaným zářením, jde o tzv. pasivní dálkový průzkum.

O aktivní dálkový průzkum se jedná tehdy, pokud je elektromagnetické záření přístrojem uměle vyrobeno a není tedy přirozeného původu. Většinou jde o komplexní systémy, které dokáží záření s určitou frekvencí vyrobit, dále ho vyslat a po odrazu od zkoumaného objektu i přijmout a echo zaznamenat. Těmito systémy jsou například lasery nebo radary.

Druhy elektromagnetického záření jsou rozlišeny i podle vlnových délek a jím odpovídajících frekvencí. V dálkovém průzkumu se nejčastěji využívají vlnové délky viditelného, infračerveného a mikrovlnného záření (Kolář 1990). Halounová (2004) uvádí, že v pasivním dálkovém průzkumu je převážně využíváno záření viditelné a infračervené části spektra. V aktivním dálkovém průzkumu se využívá záření buď v rozsahu viditelné části spektra (lasery), nebo v oblasti mikrovlnného záření (radary). Právě data pořízená radary a jejich využití v klasifikaci land use a land cover jsou předmětem této práce.

2.2 DPZ v mikrovlnné části spektra

Hranice mikrovlnné části spektra není přesně definována a různí autoři používají různé hodnoty. Nejčastěji se uvádí rozmezí vlnových délek 1 mm až 1 m což odpovídá frekvenci 0,3 až 300 GHz (Campbell 1996 cit. v Dobrovolný 1998, Ahern 1995 cit. v Halounová 2004, Barbieri a Lichtenegger 2005).

Oblast mikrovlnného záření se dále rozděluje na menší intervaly, jejichž vymezení opět není pevně dané a v různých zdrojích se od sebe liší. V tabulce 1 je přehled používaných mikrovlnných pásem tak, jak je uvádí například Kolář a kol. (1997), nebo Lusch (1999). Oblast mikrovln mezi 1 GHz a 10 GHz a mezi 14 GHz a 16 GHz představuje část spektra, která je radary využívána nejčastěji (Barbieri a Lichtenegger 2005). V praktické části této práce byla použita data pořízena v pásmu C na vlnové délce 5,66 cm senzorem ERS-2 SAR.

Snímání zemského povrchu v mikrovlnné části spektra eliminuje některé problémy, se kterými se setkáváme u optického či infračerveného snímání. Na rozdíl od většiny přístrojů, které měří odražené sluneční záření, má radar vlastní zdroj. Tento fakt je příčinou jedné z největších předností radaru, a to možnost snímání zemského povrchu i v noci. Další velkou předností mikrovlnného snímání je délka samotných vln, která jim umožňuje prostoupit atmosférou téměř za jakýchkoliv podmínek, tedy i přes oblaka, déšť, sněžení i dým. Signál radaru operujícího s vlnovou délkou větší než 2 cm je schopen proniknout oblaky. Pokud pracuje s vlnovou délkou větší než 4 cm, pronikne také deštěm (Barbieri a Lichtenegger 2005).

Další výhodou je podle Dobrovolného (1998) možnost snímání i v polárních oblastech, ve kterých nelze využít krátkovlnné záření kvůli nedostatečné intenzitě záření slunečního a v neposlední řadě také schopnost mikrovln procházet do určité hloubky pod povrchem.

Tab. 1: Přehled mikrovlnných pásem používaných radary

Pásmo	Vlnová délka [cm]	Frekvence [MHz]
K _a	0,75–1,1	40 000–26 500
K	1,1–1,67	26 500–18 000
K _u	1,67–2,4	18 000–12 500
X	2,4–3,75	12 500–8 000
C	3,75–7,5	8 000–4 000
S	7,5–15	4 000–2 000
L	15–30	2 000–1 000
P	30–100	1 000–300

2.2.1 Zobrazující radary

Zobrazující radary jsou aktivní systémy, nejčastěji umístěné na letadlech či družicích, vytvářející obrazový záznam. Tyto systémy vysílají krátké a intenzivní mikrovlnné impulzy (cca 1500 impulzů za sekundu) směrem ke scéně. Část impulzu se odrazí od zasažených objektů zpět a systémy měří jak sílu zachyceného impulzu, tak i dobu jeho šíření (Barbieri a Lichtenegger 2005).

V praxi se využívají dva typy. První je radar s reálnou aperturou (RAR), který je konstrukčně jednodušší, ale také pro vesmírný dálkový průzkum nepoužitelný. V případě, že bychom chtěli dosáhnout prostorového rozlišení lepšího než 100 m, anténa by musela být dlouhá i několik kilometrů (Barbieri a Lichtenegger 2005).

K překonání tohoto omezení byly vyvinuty radary se syntetickou aperturou (SAR), které umožňují simulaci takovýchto rozměrů antény. Díky SAR jsme schopni získat snímky s vysokým rozlišením i z výšek, ve kterých se pohybují vesmírné družice (Abdulrahman 2010).

2.2.2 Prostorové rozlišení radaru

U radaru rozlišujeme příčné prostorové rozlišení a podélné neboli azimutové prostorové rozlišení.

2.2.2.1 Příčné prostorové rozlišení

Příčné prostorové rozlišení (ve směru napříč osy letu) je dáno délkou pulzu, která je určena dobou, po kterou je pulz vysílán. Aby bylo možné od sebe rozlišit dva objekty, je potřeba, aby jejich šikmá vzdálenost byla větší než polovina délky pulzu. V případě, že by šikmá vzdálenost objektů byla menší než polovina délky pulzu, odrazy od nich by se časově překrývaly a na snímku by byly zaznamenány jako objekt jeden. Příčné prostorové rozlišení měřené v šikmých vzdálenostech je tedy rovno polovině délky pulzu a nezávisí na vzdálenosti objektu od nosiče. Rozlišení měřené v horizontálních vzdálenostech již na distanci od nosiče závisí (Dobrovolný 1997, Kolář a kol. 1997).

2.2.2.2 Azimutové prostorové rozlišení

Azimutové rozlišení je dáno šířkou vyslaného paprsku, kterou určuje délka antény a vlnová délka vyslaného signálu (Barbieri a Lichtenegger 2005). Pro radary s reálnou aperturou platí, že azimutové rozlišení závisí také na horizontální vzdálenosti od dráhy letu nosiče a to tak, že s rostoucí vzdáleností od dráhy letu se rozlišení zhoršuje. Dobrovolný (1998) píše, že lepšího rozlišení lze dosáhnout buď prodloužením antény a nebo použitím kratších vlnových délek, které jsou však více pohlcovány atmosférou.

Výrazně lepšího azimutálního rozlišení lze dosáhnout pomocí radaru se syntetickou aperturou. Každý objekt na zemském povrchu je pohybujícím se radarem snímán po určitý časový úsek, který je dán šířkou vyslaného paprsku. Pokaždé, když je vyslán impulz, radar se na své dráze letu posune o kousek dál. Echa těchto impulzů jsou potom zpracována tak, jako kdyby byla délka antény rovna délce trasy, kterou radar za dobu snímání objektu urazil (Stimson 1998). Zjednodušeně lze tedy říci, že SAR využívá k syntetizaci fyzicky krátké antény na velmi dlouhou pohybu svého nosiče.

Radary se syntetickou aperturou využívají pro zvýšení azimutálního rozlišení také Dopplerova efektu. Dopplerův efekt je obecně popisován jako změna frekvence elektromagnetické vlny v důsledku relativního pohybu mezi vysílačem a pozorovatelem (odražečem). V tomto případě jde o posun frekvencí v rámci šířky vyslaného paprsku. Echo zaznamenané z oblasti před nosičem a echo zaznamenané z oblasti za nosičem má vyšší respektive nižší frekvenci než záření vysílané. Systém tedy zpracovává jen velmi úzkou část paprsku, ve které se Dopplerův posun frekvencí projevuje minimálně (Barbieri a Lichtenegger 2005). Azimutální rozlišení SAR není, na rozdíl od RAR, závislé na horizontální vzdálenosti od dráhy letu nosiče a je konstantní v celé šířce záběru (Lusch 1999).

2.2.3 Geometrické charakteristiky záznamů zobrazujících radarů

U optických přístrojů je umístění objektů v obraze dáno úhlovým měřením vzhledem k dráze nosiče. Naproti tomu radary používají pro umístění objektu ve snímku jeho šikmou vzdálenost od antény. V důsledku tohoto odlišného způsobu pořizování dat, mají radarové snímky svá specifická zkreslení (Cheney a Borden 2009). V této práci

bude popsáno pouze měřítkové zkreslení v šikmém směru (Slant-range scale distortion) a poziční chyby způsobené nerovností terénu – zhuštění signálu (Foreshortening), zpětný překryv signálu (Layover), radarový stín (Shadowing) a slabý odraz (Elongation).

2.2.3.1 Měřítkové zkreslení v šikmém směru

K měřítkovému zkreslení dochází, protože radar měří polohu objektů v šikmých vzdálenostech. Takto naměřené vzdálenosti jsou přímo úměrné časovým intervalům mezi jednotlivými přijatými echy. Měřítko ve snímku v šikmých vzdálenostech se tedy mění od oblasti blízkého dosahu k oblasti vzdáleného dosahu a to tak, že objekty v oblasti blízkého dosahu se jeví jako stlačené (CCRS 2014, Dobrovolný 1998). Snímek v šikmých vzdálenostech můžeme převést na snímek ve skutečných horizontálních vzdálenostech pomocí trigonometrických funkcí a pomocí informace o nadmořských výškách (CCRS 2014).

2.2.3.2 Poziční chyby způsobené nerovností terénu

K pozičním chybám ve směru kolmém na dráhu letu způsobených nerovností reliéfu dochází i u optických senzorů či skenerů. U radarových snímků však dochází k relativnímu posunutí objektů blíže k senzoru (CCRS 2014). To je opět dáno již několikrát zmíněným faktem, že radar měří vzdálenost objektů od antény. Velikost pozičních chyb způsobených nerovností terénu je závislá na sklonu dopadu radarového signálu a sklonitosti svahů (Dobrovolný 1998). V následující části budou distorze popsány na příkladu hory.

1. Zhuštění signálu

Pokud radarový signál doputuje k základně nakloněného svahu hory dříve než k jejímu vrcholu, nastane zhuštění signálu. Na výsledném snímku bude skutečná délka svahu zkrácena a zobrazena nesprávně. V závislosti na sklonu svahu orientovaného k senzoru se míra zhuštění signálu mění. Maximální zhuštění signálu nastane tehdy, když je radarový paprsek na svah v celé jeho délce kolmý. V tomto případě jsou základna, svah i vrchol hory zobrazeny současně. Svahy postižené zhuštěním signálu jsou na snímku zobrazeny světlými odstíny šedi (CCRS 2014).

2. Zpětný překryv

Další významnou poziční chybou je zpětný překryv. Zpětný překryv je v podstatě extrémní případ zhuštění signálu. Překryv se v záznamu projevuje tehdy, když mikrovlny vyslané senzorem doputují k vrcholu hory předtím, než dosáhne jejího úpatí. Také echo signálu od vrcholu hory bude systémem přijato dříve. Z tohoto důvodu bude vrchol hory ve snímku posunut směrem k dráze nosiče a „překryje“ základnu hory. Ke zpětnému překryvu dochází nejčastěji u velmi strmých svahů, pod malými úhly dopadu signálu a v oblasti blízkého dosahu. Na snímku se vizuálně podobá efektu zhuštění signálu (CCRS 2014).

3. Radarový stín

Radarový stín nastane, když radarový signál není schopen dosáhnout povrchu a z těchto míst se tedy ani žádný nevrátí k záznamovému zařízení. K tomu dochází na strmých svazích odvrácených od dráhy nosiče nebo v místech za vertikálními objekty jako jsou například budovy. Jelikož z těchto oblastí radar nezaznamená žádnou odraženou energii, ve výsledném snímku se efekt stínu projevuje černou barvou. S rostoucím úhlem dopadu paprsku roste i efekt radarového stínu. Z toho vyplývá, že nejvýraznější je v oblasti vzdáleného dosahu (Dobrovolný 1998, CCRS 2014).

4. Slabý odraz

Na odvráceném svahu může docházet také ke slabému odrazu. Pokud je odvrácený svah snímán (není zastíněn), radarový signál z jeho spodní a horní části je přijat s relativně velkým časovým zpožděním. Z toho důvodu je reálná vzdálenost ve výsledném snímku „roztažena“. Zaznamenaná energie je rozložena do větší oblasti a proto jsou tyto svahy zobrazeny tmavými odstíny (Barbieri a Lichtenegger 2005).

Předchozí geometrické distorze radarových snímků mohou být opraveny pouze pomocí stereogrametrie nebo geometrické korekce za použití digitálního modelu terénu (Barbieri a Lichtenegger 2005) – viz. kapitola Geometrické korekce).

2.2.4 Parametry ovlivňující intenzitu radarového echa

Síla mikrovlnného signálu odraženého zpět k radaru je ovlivňována řadou parametrů. Tyto parametry zahrnují vlastnosti radaru a vlastnosti zemského povrchu. Mezi radarové charakteristiky patří frekvence, polarizace, úhel dopadu a azimut dopadajícího paprsku vzhledem k měřenému objektu. Charakteristikami zemského povrchu ovlivňující radarový signál jsou především drsnost povrchu, obsah vody, dielektrické vlastnosti objektu a topografie (Dobrovolný 1998, Lusch 1999). Většina ze zmíněných parametrů je spolu úzce spjata a změna jednoho parametru může mít dopad na parametry další (CCRS 2014). V následující části jsou uvedeny parametry, které podle různých autorů ovlivňují radarový signál nejzásadněji (Stimson 1998, Dobrovolný 1998, Barbieri a Lichtenegger 2005, CCRS 2014).

1. Drsnost povrchu objektu

Drsnost povrchu je obecně dominantním faktorem ovlivňujícím radarové echo. Drsný povrch je podle Koláře a kol. (1997) definována Rayleighovým kritériem takto:

$$\text{rms} > \frac{\lambda}{8 \cos \Theta}$$

Hladký povrch je definován takto:

$$\text{rms} < \frac{\lambda}{8 \cos \Theta}$$

kde rms je kvadratický průměr velikosti výšek nerovností, λ je vlnová délka vyslaného signálu a Θ je lokální úhel dopadu.

Z Rayleighova kritéria je zřejmé, že drsnost povrchu je přímo závislá na vlnové délce a úhlu dopadu. Pokud se povrch snímáný pod určitým úhlem určitou vlnovou délkou jeví jako hladký (resp. drsný), po změně obou nebo i jedné z těchto proměnných se může jevit jako drsný (resp. hladký). Podle Dobrovolného (1998) a Koláře a kol. (1997) dochází při interakci záření s povrchem, v závislosti na jeho drsnosti, k třem základním typům odrazu radarového signálu.

Hladké povrchy způsobují takzvaný zrcadlový odraz většiny energie zpravidla směrem od senzoru. Z důvodu minimálního odrazu signálu zpět k anténě jsou ve výsledném snímku tyto plochy zobrazeny tmavými odstíny.

Drsné povrchy mikrovlnnou energii rozptýlí do všech směrů neboli difúzně a značná část se tedy odrazí zpět k radaru. Jak již bylo zmíněno, velkou roli zde hraje úhel dopadu a vlnová délka signálu. Určitý povrch se za dané vlnové délky bude se zmenšujícím úhlem dopadu jevit drsněji. Od totožného povrchu v oblasti blízkého dosahu se tedy k anténě odrazí větší část energie než z oblasti vzdáleného dosahu (CCRS 2014).

Méně typické jsou koutové odražeče. Ty se nejčastěji vyskytují v zastavěných územích, skalních útvarech a útesech. Koutový odraz je způsoben dvojitým odrazem od dvou hladkých a na sebe kolmých povrchů. Jejich orientace směrem k anténě způsobí odraz většiny energie zpět k radaru a díky tomu jsou na radarovém snímku zobrazeny jako velmi světlé plošky (Dobrovolný 1998).

Ke specifickému tzv. několikanásobnému odrazu může dojít uvnitř vrstvy vegetace. Například v lese může dojít k odrazu od listů, větví, kmenů, podrostu a půdy. Podle Dobrovolného (1998) takový odraz od vegetace způsobuje změnu polarizace radarového signálu, čehož může být využito při klasifikaci vegetačních pokryvů.

2. Geometrie radaru a zemského povrchu

Vztah mezi úhlem snímání a geometrií objektů na povrchu hraje velmi důležitou roli v tom, jak radarová energie s objekty interaguje. Změna v úhlu snímání má vliv na velikost pozičních chyb objektů v závislosti na sklonu, orientaci a tvaru těchto objektů.

Vzájemná orientace radarového paprsku a objektů významně ovlivňuje jejich vzhled na radarovém snímku. Zvláště pokud jsou objekty liniově uspořádány. Jde například o zemědělské plodiny, horská pásma či některé člověkem vytvořené struktury (CCRS 2014). Pokud paprsek dopadá kolmo na liniové prvky, radarové echo je mnohem silnější, než kdyby dopadal rovnoběžně s jejich uspořádáním (Dobrovolný 1998).

3. Vlhkost a dielektrické vlastnosti materiálů

Dobrovolný (1998) píše, že elektrické vlastnosti objektů jsou ovlivňovány geometrickými vlastnostmi, ovšem primárně obsahem vody v nich. Obecně platí, že se zvyšujícím se obsahem vody odrazivost a tedy i jas objektu ve snímku roste.

Měřtkem elektrických vlastností je dielektrická konstanta, která určuje odrazivost a vodivost různých materiálů. Dielektrická konstanta většiny suchých materiálů je zhruba 3 až 8. Oproti tomu dielektrická konstanta vody je 80. Tím, že vegetace má často velký obsah vody a při dešti dokáže množství vody zadržet, odráží zpět k radaru velkou část energie a ve snímku je pak zobrazena světlejšími odstíny šedi. Vysoké hodnoty dielektrické konstanty mají také kovové povrchy. (Kolář a kol. 1997).

4. Polarizace signálu

Při záznamu radarového echa je důležitá jeho polarizace. Každé elektromagnetické záření má elektrickou a magnetickou složku, které jsou navzájem kolmé. Polarizace nám říká, jak je elektrické pole prostorově orientováno vzhledem ke směru šíření vlny (Lusch 1999). Radarové systémy vysílají signál ve vertikální či horizontální rovině. Stejně tak ho mohou i přijímat.

Velká část odražené energie má stejnou polarizaci jako vyslaný signál, ale některé typy krajinného pokryvu signál depolarizují. Tato změna polarizace může být velmi důležitým nositelem informace o drsnosti povrchu, o přítomnosti vegetace či o pronikání signálu do vrstev sedimentů (Campbell 1996 cit. v Dobrovolný 1998)

2.3 Zpracování radarových dat

Radiometrické a geometrické korekce jsou nutnými kroky k získání radarového snímku vhodného ke klasifikaci. Díky těmto korekcím jsme schopni snímek transformovat z šikmých do skutečných pozemních vzdáleností, registrovat do souřadnicového systému, eliminovat měřítkové zkreslení v šikmém směru a distorze způsobené

nerovností terénu, či potlačit pro radarová data typický vysokofrekvenční šum neboli “speckle”.

2.3.1 Radiometrická korekce

Hlavním předmětem radiometrické korekce je potlačení zrnité textury ve snímku. Jednotlivé velmi světlé, nebo naopak velmi tmavé body vznikají jako náhodný proces. Světlé plošky vznikají tak, že se na snímaném území odpovídajícímu jednomu pixelu vyskytuje několik malých odražečů, které jsou v přesně stejné vzdálenosti od antény. Odraz od těchto odražečů se násobí a anténa přijme velmi výrazné echo. Tmavé body ve snímku jsou výsledkem takového rozmístění odražečů na území odpovídajícímu jednomu pixelu, při kterém se odrazy radarového signálu navzájem zeslabují a nakonec vytvoří velmi slabé echo (Mansourpour a kol. 2008).

Rajabi a kol. (2006) považuje snížení efektu speckle za jeden z nejdůležitějších procesů zkvalitnění radarových snímků. Existují dva hlavní způsoby redukce zrnité struktury – tzv. multilooking a různé typy filtrů. Multilooking je obvykle prováděn systémem již za procesu pořizování snímku (CCRS 2014). Redukce šumu pomocí metody multilooking se podrobně zabývá například Raney (1998).

V této práci jsou popsány pouze vybrané filtrační metody, které jsou určeny pro radarová data a zároveň jsou součástí softwaru Next ESA SAR Toolbox (NEST).

2.3.1.1 Adaptivní filtrace šumu

Adaptivní filtry se přizpůsobují lokálním specifickým vlastnostem, které jsou dány například terénem nebo vlhkostními poměry. Zrnitou strukturu adaptivní filtry potlačují na základě definování lokální míry heterogenity a do určité míry jsou schopny zachovat texturu snímku (Wang a kol. 2012).

1. Frostův filtr

Filtrovaný pixel je nahrazován hodnotou váženého součtu hodnot pixelů uvnitř kernelu. Váhy se snižují s rostoucí vzdáleností od filtrovaného pixelu. Frostův filtr vyhlazuje převážně homogenní plochy, zatímco oblastem s vysokým kontrastem do určité míry hodnoty zachovává. Součástí Frostova filtru je koeficient (tzv. Damping factor), jehož hodnota určuje míru vyhlazování obrazu

a na druhé straně míru zachování hran (Mansourpour a kol. 2008, Fang a kol. 2004).

2. Gamma MAP filtr

Na rozdíl od většiny adaptivních filtrů, které předpokládají Gaussovo (normální) rozdělení hodnot ve snímku, Gamma MAP filtr je založen na předpokladu, že hodnoty ve snímku mají gama rozdělení. Z tohoto důvodu je vhodný pro zemědělské nebo zalesněné oblasti, jejichž hodnoty na radarových snímcích tomuto rozdělení hodnot odpovídají (Rajabi a kol. 2006). Gamma MAP filtr předpokládá, že původní hodnota filtrovaného pixelu leží mezi hodnotou tohoto pixelu a průměrem hodnot všech pixelů v kernelu (Ozdarici 2010, Mansourpour a kol. 2008).

3. Leeův filtr

Leeův filtr využívá k výpočtu nové hodnoty pixelu statistického rozdělení hodnot pixelů uvnitř kernelu. Princip tohoto filtru je založen na předpokladu normálního rozdělení zrnitosti ve snímku a na předpokladu, že průměr a odchylka filtrovaného pixelu je rovna lokálnímu průměru a lokální odchylce všech pixelů v kernelu (Wang a kol. 2012, Rajabi a kol. 2006).

4. Leeův–Sigma filtr

Leeův–Sigma filtr, stejně tak jako Leeův filtr, využívá k výpočtu nové hodnoty pixelu statistického rozdělení hodnot v kernelu a předpokládá normální rozdělení zrnitosti ve snímku. Proces filtrace je podobný jako v případě Leeova filtru. Základní rozdílem je vymezení hodnot v rámci kernelu pomocí dvou prahových hodnot. Hodnoty pixelů ležících mimo tento rozsah jsou z procesu výpočtu nové hodnoty filtrovaného pixelu vyloučeny (Ozdaricic 2010, Zhang a kol. 2012).

2.3.1.2 Zvětšení příznakového prostoru pomocí textury

Textura snímku ovšem nemusí vždy reprezentovat nežádoucí vysokofrekvenční šum, ale může být i důležitým nositelem informace o daném povrchu. Tato informace může být využita pro rozšíření příznakového prostoru (Dobrovolný 1998). Mnoho studií dokazuje, že ve většině případů je pro radarové snímky textura nejdůležitějším zdrojem informací (Ulaby a kol. 1986, Dobson a kol. 1995, Dell'Acqua 2003 cit. v Ban a Wu 2005). Pro zvýraznění textury se používá filtračních oken různé velikosti, tedy stejně jako u klasických filtrů potlačujících šum. Výrazným rozdílem je ovšem způsob, jakým výpočet probíhá. Halounová (2004) píše, že „výpočet texturních měr není proveden pouze na základě vlastních digitálních hodnot, ale s použitím vztahů mezi těmito hodnotami“. Texturní míry mohou být například – průměr, směrodatná odchylka, rozptyl, homogenita, kontrast či entropie.

2.3.2 Geometrické korekce

Geometrie bočního snímání povrchu radarem způsobuje ve výsledném snímku značná zkreslení, která jsou popsána v kapitole Geometrické charakteristiky záznamů zobrazujících radarů. Pomocí geometrických korekcí jsou tato zkreslení odstraňována. Geometrické korekce zahrnují transformaci snímku v šikmých vzdálenostech do snímku ve skutečných pozemních vzdálenostech, registraci snímku a korekce vlivu lokálního úhlu dopadu radarového paprsku.

Pro převod snímku do snímku v horizontálních vzdálenostech jsou potřeba informace o geometrii snímání a nadmořské výšce snímaného terénu, například v podobě digitálního modelu terénu (DMT). Snímek je převzorkován tak, aby byla sjednocena velikost pixelů v příčném směru.

Dalším krokem geometrické korekce je rektifikace snímku. Účelem rektifikace je eliminovat zkreslení radarového snímku tak, aby jej bylo možno vlíčovat do souřadnicového systému či kartografického zobrazení. U radarových dat je z důvodu šikmého snímání nezbytná korekce vzhledem k nadmořské výšce a opět je tedy potřeba DMT. Ortorektifikace snímku se nejčastěji provádí pomocí vlíčovacích bodů a polynomické transformace.

2.4 Klasifikace radarových dat

Klasifikace je proces většinou automatického vyhodnocení dat dálkového průzkumu, při kterém dochází k rozdělení obrazového souboru do určitého počtu tříd. Každá třída je charakterizována svým vlastním klasifikačním pravidlem (Halounová 2004). Kolář a kol. (1997) definují klasifikační pravidlo jako vztah, který jisté hodnotě parametrů přiřazuje jednoznačně určitou velikost naměřených obrazových dat ve všech složkách víceobrazu. Klasifikační pravidla jsou dána příznaky, tedy charakteristickými změnami naměřené veličiny ve vztahu ke změně druhového nebo stavového parametru. Příznaky se obecně rozdělují do 4 skupin (Halounová 2004, Kolář a kol. 1997, Dobrovolný 1998):

1. Příznaky spektrální

Spektrální příznaky jsou založeny na odrazivých a vyzařovacích vlastnostech povrchu.

2. Příznaky prostorově spektrální

Tyto příznaky sledují spektrální hodnoty a jejich uspořádání v ploše. Jde například o homogenitu/heterogenitu objektu, tvar a velikost objektu či jeho strukturu.

3. Příznaky časové

Příznaky, které představují časový průběh spektrálních a prostorových změn objektu.

4. Příznaky polarizační

Tyto příznaky lze použít u radarových dat. Vyjadřují spektrální příznak měřený v polarizační rovině.

Na základě rešerše literatury bylo zjištěno, že pro klasifikaci radarových dat jsou využívány všechny zmíněné typy příznaků. Většina radarů se syntetickou aperturou není schopna pořizovat multispektrální data. Z toho důvodu se pro klasifikaci využívají data multitemporální nebo data s různou polarizací (Dobrovolný 1998). Jelikož se radarová data některých povrchů vzájemně relativně neliší, využívá se například maskování nebo rozšíření příznakového prostoru pomocí vypočtených kanálů. Tyto nové složky obrazu mohou vznikat například funkcemi posuzujícími texturu obrazu.

Automatická klasifikace obrazových dat může být provedena mnoha způsoby. V této práci jsou popsány pouze dvě metody řízené klasifikace, které jsou součástí softwaru ENVI a jsou aplikovány a porovnávány v praktické části, a to pixelová klasifikace *Maximum Likelihood* a objektově orientovaná klasifikace metodou *Support Vector Machine*.

2.4.1 Řízená pixelová klasifikace

Při řízené klasifikaci je nejprve nutností zvolit vhodné trénovací plochy. Trénovací plochy pro jednotlivé třídy musí mít takové hodnoty, aby bylo možné tyto třídy od sebe oddělit. V ideálním případě se tedy v příznakovém prostoru hodnoty jednotlivých trénovacích ploch tříd nepřekrývají (Halounová 2004). Tyto trénovací plochy mohou být určeny pomocí dalších zdrojů, ve kterých jsou známy informace o druhových či stavových parametrech. Kolář a kol. (1997) zdůrazňuje, že pro dobrý výsledek klasifikace jsou nutností reprezentativní a kompletní tréninková data.

2.4.1.1 Maximální pravděpodobnost

V praktické části této práce byla použita pixelová klasifikace maximální pravděpodobnosti, která je obecně využívána nejčastěji. Tato klasifikace předpokládá normální rozdělení hodnot každé třídy a v každém pásmu. Pro každý pixel je vypočítána pravděpodobnost příslušnosti k třídě na základě kvantitativního hodnocení rozptylu hodnot, kovariance a korelace každé třídy (Dobrovolný 1998). Pokud není zvolena prahová hodnota pravděpodobnosti, tak jsou klasifikovány všechny pixely. V případě, že práh zvolen je a maximální pravděpodobnost je menší než určená prahová hodnota, pixel zůstane neklasifikován (Exelis VIS 2015a).

2.4.2 Objektově-orientovaná klasifikace

Metody pixelové klasifikace bývají velmi často pro radarová data nevhodné. Důvodem je jejich velká heterogenita i v rámci jednotlivých tříd a také značný obsah šumu v obraze. Proto je využíváno složitější objektové klasifikace. U objektové klasifikace není základní jednotkou pro klasifikaci pixel, ale segment neboli skupina prostorově souvisejících pixelů. Prvním a základním krokem objektové klasifikace je segmentace obrazu. Jejím cílem je vytvořit segmenty (objekty) obsahující pixely podobných

vlastností. Segmenty mohou být tvořeny na základě spektrálních, prostorových či texturních vlastností nebo jejich kombinace (Halounová 2004).

Segmentace radarových snímků je složitějším procesem než je tomu například u dat optických. V některých studiích se proto pro segmentaci využívá jiných dat. Ban (2003) provedl segmentaci obrazu na základě dat z optického senzoru SPOT 2. Ukázkou dalšího přístupu jsou studie Tso a Mather (1999), Kussula a kol. (2013) nebo Ianninia a kol. (2013), ve kterých jsou pro segmentaci použity informace o hranicích polí z jiných zdrojů. Tyto práce se zabývaly klasifikací zemědělských plodin a segmenty představovaly jednotlivá pole.

V praktické části této práce byla pro segmentaci radarových dat použita vektorová vrstva LPIS, ve které jednotlivé polygony představují zemědělské bloky s jednou kulturou.

2.4.2.1 Segmentace v ENVI

V softwaru ENVI jsou k dispozici segmentační algoritmy *Edge* a *Intensity*, přičemž oba jsou založeny na principu „zespodu – nahoru“. To znamená, že segmentace začíná na úrovni pixelu a segmenty vznikají „nabalováním“ pixelů okolních. Pro tuto práci by byl pravděpodobně vhodnější segmentační algoritmus *Intensity*. Tento algoritmus je vhodný pro data, která neobsahují výrazné hrany mezi jednotlivými třídami, což je pro zemědělské oblasti na radarových snímcích typické (Halounová 2004).

2.4.2.2 Objektová klasifikace v ENVI

Pro objektovou klasifikaci jsou v tomto programu dva přístupy – *Example-based* a *Rule-based*. V praktické části bakalářské práce je použita řízená klasifikace *Example-based*. Tato řízená objektová klasifikace využívá trénovacích ploch stanovených tříd k zařazení segmentů do těchto tříd. Zařazení segmentů probíhá na základě uživatelem vybraných vlastností, které mohou být spektrální (průměr, směrodatná odchylka, minimální hodnota a maximální hodnota), texturní (rozpětí, průměr, rozptyl a entropie) a prostorové (např. délka hranice, plocha, kompaktnost) (Exelis VIS 2015b).

Pro řízenou objektovou klasifikaci jsou k dispozici tři klasifikační algoritmy – *K Nearest Neighbor*, *Principal Components Analysis* a *Support Vector Machine (SVM)*. Pro tuto práci byl vybrán SVM, který je sice časově nejnáročnější, ovšem ze tří

dostupných algoritmů nejpřesnější (Exelis VIS 2015b). I podle výzkumu a rozsáhlé rešerše literatury Benediktssona a Waskeho (2007), týkající se klasifikace radarových a optických dat, je SVM buď přesnější nebo alespoň stejně přesný jako ostatní klasifikátory.

2.4.2.3 Support Vector Machine (SVM)

SVM je metoda řízené klasifikace odvozena z teorie statistického učení, která často dosahuje dobrých výsledků ze složitých dat a z dat obsahujících velký podíl šumu (Exelis VIS 2015c). Jedním ze základních principů je převod daného vstupního prostoru příznaků, ve kterém jsou trénovací data jednotlivých tříd lineárně neoddělitelná, do vícerozměrného, ve kterém již je možno tyto třídy od sebe lineárně rozdělit. Dělicí nadrovina je vedena tak, aby byla její vzdálenost od trénovacích tříd co největší (Nemmou a Chibani 2006). Převod příznakového prostoru na vícerozměrný probíhá pomocí kernelové funkce.

V softwaru ENVI jsou dostupné 4 typy kernelu. V praktické části byl použit kernel *RBF (Radial Basis Function)*, který je obecně nejpoužívanější (Hsu a kol. 2010, Trilobyte 2010). Pro kernel RBF je potřeba nastavit parametry gamma a C. Parametr gamma udává šířku kernelové funkce. Velikost parametru C funguje jako váha mezi složitostí rozdělení tréninkových dat a generalizačními vlastnostmi klasifikátoru (Hsu a kol. 2010).

2.4.3 Uvedení konkrétních studií land cover / land use na podstatě radarových dat

Díky schopnostem radarů snímat zemský povrch i v noci a za téměř jakéhokoliv počasí se radarová data stala velmi cenným nositelem informací (Waske a Schiefer 2006). Velkou výhodou radarových dat je i možnost využití polarizačních příznaků. Pro mapování land cover a land use na základě radarových snímků se využívají různé přístupy klasifikace, přičemž studie porovnávající pixelové a objektové klasifikace obecně ukazují lepší výsledky pro objektové rozpoznávání. Objektová klasifikace a její metody se staly předmětem velkého výzkumu právě za účelem klasifikace radarových dat, jelikož metody per-pixel nevykazovaly, díky specifickému vzhledu radarových snímků, uspokojivé výsledky (Davidson a kol. 2006).

Studie Ban a Wu (2005) zkoumá možnosti získávání informace o land use a land cover z multitemporálních dat kanadské družice RADARSAT. Autoři pracovali s 5 snímky oblasti severozápadně od Toronta, které byly pořízeny od 14. května do 18. srpna 2002. Tyto snímky měly jednoduchou horizontální polarizací a byly pořízených v pásmu C. Cílem práce bylo otestovat využitelnost snímků z RADARSATU pro per-pixel klasifikátory maximální pravděpodobnosti (MP) a neuronových sítí (NS). Pro klasifikaci byly z původních snímků vypočteny nové kanály za pomoci adaptivních filtrů Gamma MAP, Lee, Frost (kernel 11x11) a 4 texturních měř – průměru, standardní odchylky, korelace a entropie (kernel 11x11). Klasifikována byla postupně časová řada původních snímků, poté filtrovaných snímků, snímků s texturou a nakonec jejich různé kombinace. Klasifikační systém obsahoval celkem 10 tříd (hustě a řídce zastavěné území, silnice, les, park, golfové hřiště, vodní plochy a 3 typy zemědělských ploch).

Jak autoři předpokládali, klasifikace původních nefiltrovaných snímků dosáhla velmi špatné celkové přesnosti, a to 37,25 % (MP) a 39,85 % (NS). Celková přesnost klasifikací časových řad 5 filtrovaných snímků se zvýšila o 30–40 %. Nejlepší celkové přesnosti (78,25 %) v rámci filtrovaných snímků vykazoval klasifikátor NS aplikovaný na sadu vzniklou Frostovým filtrem. Klasifikace jednotlivých sad texturních měř vykazovala velmi výrazné rozdíly. Texturní míra průměr dosáhla u obou klasifikátorů nejlepší celkové přesnosti (MP: 74,95 % a NS: 82,65 %). Naopak jako nejhorší se ukázala korelace (MP: 31,55 % a NS: 30,3 %). Ačkoliv zmíněná korelace či entropie dosahují velmi špatné celkové přesnosti, kombinacemi s ostatními texturními mírami bylo dosaženo velmi dobrých výsledků. Důvodem jsou získané prostorové vztahy, které jsou pro každou texturní míru specifické (Ban a Wu 2005). V rámci této studie dosáhla nejlepší celkové přesnosti 89,7 % (kappa: 0,886) kombinace texturních měř průměru, standardní odchylky, korelace a klasifikátoru NS. Většina testovaných klasifikací pomocí neuronových sítí vykazovala oproti klasifikacím maximální pravděpodobnosti nepatrně lepší výsledky. Vysoké hodnoty celkové přesnosti naznačují potenciál dat z RADARSATu pro mapování land use a land cover.

Ve studii Thiel a kol. (2009) si dali autoři za cíl posoudit potenciál radaru Sentinel-1 pro mapování land cover, který v té době ještě nebyl v provozu. Z toho důvodu byl simulován použitím multitemporálních dat pásma C ze senzorů ERS-2 a

ENVISAT ASAR AP. Dataset obsahoval 10 snímků z ERS-2 (VV), 3 snímky ENVISAT ASAR Image Mode (VV) a 14 ENVISAT ASAR Alternating Polarization Mode (HH/HV). Zájmové území o velikosti 10x15 km se nachází ve středním Německu a převažují v něm zemědělské plochy, travnaté porosty a lesy. Redukce speckle byla provedena kombinací multi-looking a speciálního multitemporálního Queganova filtru.

Pro klasifikaci byly zvoleny základní třídy land cover – vodní plochy, lesy, zastavěná území, travnaté porosty a zemědělské plochy. Autoři nejdříve ze snímků vypočítali pro každou polarizaci (HH, VV a HV) 4 nové kanály sledující časové změny v naměřené intenzitě – minimální, maximální a průměrná hodnota intenzity každého pixelu ve všech snímcích a průměrná střední kvadratická odchylka (MVA – mean annual variation). Pomocí referenčních dat a histogramů těchto vypočítaných kanálů byla zkoumána separabilita jednotlivých tříd. Výpočtem MVA byl získán obraz s jasně rozlišitelnými zemědělskými plochami od ostatních tříd, přičemž rozdíl byl největší v případě HV dat. Vodní plochy byly nejlépe rozpoznatelné v HV kanálech. Rozdíl mezi třídou lesy a třídou travnaté porosty nebyl pouze v případě MVA. Naopak pro úspěšné oddělení lesů a zastavěných území nejsou vhodné žádné vypočtené obrazy. Proto autoři doporučují použít texturních měř.

Testovány byly metody rozhodovacího stromu a maximální pravděpodobnosti (MP). Obě vykazovaly dobré výsledky, ale autoři uvádí pouze metodiku a výsledky klasifikátoru MP. Do konečné klasifikace nebyly zahrnuty kanály s minimálními a maximálními hodnotami, protože jejich hodnoty mohou být velmi ovlivněny jednorázovými událostmi jako je například déšť nebo tání sněhu. Zahrnutím těchto kanálů do klasifikace se její přesnost snížila zhruba o 15 %. Autoři testovali různé kombinace a počty do klasifikace vstupujících snímků. Jako nejlepší se ukázala klasifikace kanálů s průměrnými hodnotami intenzity, MVA a texturními mírami, které byly vypočteny z časové řady čtyř VV a HV polarizovaných dat. Celková přesnost klasifikace byla v tomto případě více než 85 %. Nejmenší úspěšnosti klasifikace dosahovala třída travnatých porostů (uživatelská přesnost 78 %). K relativně velkým chybám docházelo u zemědělských ploch, které byly chybně klasifikovány jako travnaté porosty nebo zastavěná území.

Pixelový klasifikátor MP aplikovaný na radarová data použili ve své práci i Tso a Mather (1999). Autoři měli k dispozici časovou řadu 7 snímků (duben–září) z ERS-1. Zájmové území se nachází v zemědělské oblasti západně od města Feltwell ve Velké Británii. V této studii byla porovnávána per-pixel klasifikace s klasifikací objektovou. Testovány byly klasifikátory řízené klasifikace – MP, Kohonenovy samo-organizující neuronové sítě (SOM) a minimální vzdálenosti. Pro pixelovou klasifikaci byly jako vstupní data použity nezpracované snímky, snímky filtrované Leeovým filtrem, snímky sledující časové změny v naměřené intenzitě, texturní míry a různé kombinace. Objekty pro objektovou klasifikaci měly představovat jednotlivá pole. Autoři si proto pomocí RGB kanálů zobrazili 3 snímky, ze kterých byly hranice polí rozlišitelné vizuálně nejlépe. Následně hranice vektorizovali a nakonec převedli do rastrového formátu. Pro jednotlivé segmenty byly vypočteny průměrné hodnoty intenzity z každého ze 7 radarových snímků.

Nejlepších výsledků pixelové klasifikace bylo dosaženo algoritmem SOM na filtrovaných snímcích. Celková přesnost 61,43 % je ovšem velmi nízká. SOM klasifikátor aplikovaný na objekty vykazoval již mnohem lepší celkovou přesnost – 77,80 %. Tuto úroveň autoři považují pro mapování zemědělských plodin za dostatečně vysokou, ovšem pro ještě přesnější výsledky doporučují integrovat optické snímky.

Objektovou klasifikací zemědělských plodin se ve své habilitační práci zabývala také Halounová (2004). Bylo použito dvou radarových snímků z roku 1997 – 10. a 27.července. Studované území je ohraničeno mapovým listem Olomouc v měřítku 1:50 000. Trénovací plochy byly určeny pozemním šetřením a následnou klasifikací optických dat. Pro zvětšení příznakového prostoru bylo vypočteno celkem 42 nových kanálů – 2 kanály vzniklé trojnásobným použitím mediánového filtru o kernelu 5x5 pixelů a 10 texturních měř pro oba snímky a pro dvě velikosti kernelu (5x5 a 7x7 pixelů). Segmentace obrazu proběhla s použitím dvou původních snímků a 2 kanálů vzniklých trojnásobnou filtrací. Texturní míry nebyly do procesu segmentace zařazeny. Třídy vyplývaly z terénního šetření v zájmovém území. Jednalo se o třídy les, pšenice, vojtěška, kukuřice, ječmen, cukrovka, řepka a ostatní. Bylo testováno celkem 5 klasifikací, do kterých pokaždé vstupovaly různé kombinace snímků a vypočtených kanálů. Pro všech 5 klasifikací byla použita metoda nejbližšího souseda. Nejvyšší

celkové přesnosti 63 % dosáhla klasifikace, která použila 2 původní snímky a všech 42 vypočtených kanálů.

Špatný výsledek klasifikace má podle autorky 3 hlavní důvody. Prvním z nich jsou segmenty, které často neodpovídají objektům jednotlivých tříd. Druhým důvodem mohou být samotné snímky. Ve snímku z 10. 7. nese část studovaného území důsledky záplav a druhý snímek byl naměřen pod vysokým úhlem dopadu signálu, při kterém je naměřená intenzita ovlivněna spíše vlhkostí než drsností povrchu. Třetím důvodem je pak malý časový rozdíl mezi pořízením obou radarových snímků. Na základě rešerše literatury lze ovšem za jeden z hlavních důvodů považovat nedostatečnou časovou řadu snímků. Ve většině studií je použita časová řada alespoň 4 radarových snímků.

Mapování land cover a land use městské oblasti provedli na základě multitemporálních a plně polarizovaných dat z družice RADARSAT-2 ve své studii Niu a Ban (2013). Šest snímků bylo pořízeno během vegetačního období od června do září roku 2008 a zájmové území se nacházelo severně od Toronta. Z každého snímku autoři vygenerovali kanály nesoucí informace o různých polarimetrických vlastnostech, které byly vypočteny převážně na základě koherenční matice (např. Pauliho, Freemanova nebo Cloude-Pottierova dekompozice). Pro víceúrovňovou segmentaci byly po řadě testů vybrány kanály vzniklé Pauliho dekompozicí a Leeovou filtrací (kernel 7x7 pixelů). Řízená klasifikace 11 tříd proběhla pomocí algoritmu SVM a testovány byly různé kombinace vstupujících dat. Vždy byly vypočteny standardní odchylky a průměrné hodnoty pro všechny objekty. Nejlepších výsledků dosahovala klasifikace všech 6 kanálů vzniklých Pauliho dekompozicí. Celková přesnost v tomto případě byla téměř 93 %, což autoři označují za výborný výsledek. K největším chybám docházelo v třídě husté zástavby, která byla z 21 % špatně klasifikována jako průmyslová oblast, nebo oblast s nízkou hustotou zástavby. Naopak nejlépe klasifikovanými třídami byly golfové hřiště a zemědělské plochy se zpracovatelskou přesností 96,63 % respektive 98,36 %.

3 Data a metodika

Cílem této práce je provést a zhodnotit dva přístupy řízené klasifikace land use s využitím radarových dat. Prvním z nich je per-pixel klasifikace pomocí algoritmu maximální pravděpodobnosti a druhým objektově orientovaná klasifikace metodou Support Vector Machine (SVM). Klasifikace proběhly pod maskou, která byla vymezena zemědělsky využívanou půdou. Legenda zahrnuje 3 kategorie:

1. Orná půda (OP)
2. Travnaté porosty – pastviny a louky (TP)
3. Chmelnice, vinice a ovocné sady (OST)

3.1 Charakteristika zájmových území

Zájmová území se nacházejí v zemědělské oblasti povodí Odry v Ústeckém kraji. Dvě oblasti o velikosti 15x15 km jsou znázorněny na mapě v příloze 1. Tato dvě území byla vybrána na základě přítomnosti všech tří kategorií a dostupnosti radarových dat z roku 2009. Zájmové území 1 (dále jen ZÚ1) se nachází mezi městy Kadaň, Žatec a Podbořany. Výrazným prvkem je Nechanická vodní nádrž. Zájmové území 2 (dále jen ZÚ2) se rozprostírá mezi městy Louny a Most.

3.2 Použitá data

Pro účely bakalářské práce byly použity 2 hlavní datové zdroje – radarové snímky pořízené satelitem ERS-2 a geodatabáze LPIS (Land Parcel Identification Systém), což je systém evidence užívání půdy pro zemědělské dotace.

3.2.1 Radarová data

Výběr radarových snímků a žádost o jejich dodání byla provedena pomocí softwaru EOLI-SA a internetových stránek Evropské kosmické agentury (ESA). Pro bakalářskou práci byla použita časová řada šesti radarových snímků pořízených systémem AMI-SAR umístěným na satelitu ERS-2.

Satelit ERS-2 vypustila v roce 1995 na oběžnou dráhu ESA jako následovníka družice ERS-1 a v červenci roku 2011 její činnost řízeným způsobem ukončila.

Parametry radaru se syntetickou aperturou umístěného na této družici jsou uvedeny v tabulce 2.

Tab. 2: Technické parametry senzoru AMI-SAR umístěného na družici ERS-2

Typ senzoru	Jednofrekvenční
Frekvenční pásmo	C
Prostorové rozlišení	30 m
Frekvence	5,3 GHz
Vlnová délka	5,6 cm
Záběr senzoru	100 km
Perioda snímání	35 dní
Polarizace	VV

Zdroj: ESA (2015a)

Všechny dodané radarové snímky byly zpracované na úrovni, která je označována zkratkou *PRI* (Precision Image Product). Na této úrovni zpracování obsahují snímky korekci antény, jsou převedeny z šikmých vzdáleností na skutečné (horizontální) vzdálenosti, nejsou geokódovány a nejsou z nich ani odstraněny distorze vzniklé nerovností terénu (ESA 2015b). Každý ze šesti snímků byl pořízen při pohybu satelitu ERS-2 od severu k jihu (descending mode), a to na stejné relativní oběžné dráze č. 394. Velikost pixelu je 12,5x12,5 m. Termíny pořízení radarových snímků jsou následující:

- 30. března 2009
- 4. května 2009
- 8. června 2009
- 13. července 2009
- 17. srpna 2009
- 21. září 2009

3.2.2 LPIS

LPIS (Land Parcel Identification System) je systém primárně sloužící k ověřování žádostí o dotace poskytované na zemědělskou půdu (LPIS 2004). V této práci jsou použita vektorová polygonová data z roku 2009, která obsahují například informace o velikosti, průměrné svažitosti, nadmořské výšky půdních bloků a informace o přítomné zemědělské kultuře. Na základě databáze LPIS byly vybrány trénovací a validační plochy potřebné pro řízenou klasifikaci.

3.2.3 Výškopis ZABAGED

ZABAGED (Základní báze geografických dat České republiky) je digitální geografický model území ČR. Jeho výškopisná část byla v této práci použita pro tvorbu digitálního modelu terénu (DMT), který byl následně použit pro korekci radarových snímků. Vytvořený DMT má velikost pixelu 1 m.

3.3 Předzpracování dat

Předzpracování dat proběhlo v softwaru Next ESA SAR Toolbox (NEST). Nest je volně dostupný software pro prohlížení, předzpracování a analyzování dat jak z ESA SAR misí (ERS-1 a 2, ENVISAT a Sentinel-1), tak i misí třetích stran (JERS-1, ALOS PALSAR, RADARSAT nebo TerraSAR-X).

V prvním kroku byly v metadatech snímků aktualizovány informace o přesné poloze a rychlosti družice, které jsou důležité pro topografickou korekci. Původní metadata obsahují pouze teoretické a obecně nepřesné informace o dráze družice, a proto jsou nahrazeny přesnějšími informacemi, které jsou dostupné přibližně 5 týdnů po pořízení snímku (NEST 2013).

3.3.1 Radiometrické korekce

3.3.1.1 Potlačení zrnité textury

Hlavním předmětem radiometrické korekce bylo nalezení vhodné metody pro potlačení efektu speckle ve snímcích. Pro tento účel proběhl test adaptivních filtrů dostupných v softwaru NEST. Na radarových snímcích ze 4. května a 8. června byly testovány tři velikosti kernelů – 5x5, 7x7 a 9x9 pixelů. Pro zhodnocení schopnosti jednotlivých filtrů potlačovat speckle byly vypočítány indexy ENL (Equivalent Number of Looks), SSI (Speckle Suppression Index) a SMPI (Suppression and Mean Preservation Index), které jsou pro tento účel používány nejčastěji (Wang a kol. 2012).

1) ENL

Index ENL se počítá na základě této rovnice (Gagnon a Joun 1997 cit. v Wang a kol. 2012):

$$ENL = \left(\frac{\text{průměr}}{\text{standardní odchylka}} \right)^2$$

Čím vyšší je hodnota ENL filtrovaného snímku, tím vyšší je i jeho účinnost potlačování speckle.

2) SSI

Index SSI se počítá následujícím způsobem:

$$SSI = \frac{\sqrt{\text{kovariance}(S_f)}}{\text{průměr}(S_f)} \times \frac{\text{průměr}(S_p)}{\sqrt{\text{kovariance}(S_p)}}$$

Kde S_f = filtrovaný snímek a S_p = původní snímek.

Pokud je filtr účinný, hodnota indexu je menší než 1. Nižší hodnoty znamenají vyšší výkonnost filtrování speckle (Sheng and Xia 1996 cit. v Wang a kol. 2012).

3) SMPI

Tento index posuzuje jak výkonnost filtrů, tak jejich schopnost zachovávat původní hodnoty v obraze. Rovnice pro jeho výpočet vypadá takto:

$$SMPI = Q \times \frac{\sqrt{\text{kovariance}(S_f)}}{\sqrt{\text{kovariance}(S_p)}}$$
$$Q = 1 + |\text{průměr}(S_p) - \text{průměr}(S_f)|$$

Čím nižší hodnota indexu, tím lepší výkonnost filtru ve smyslu zachování průměrné hodnoty a potlačení speckle.

V tabulce 3 a 4 jsou vypočtené hodnoty indexů. Žádný z testovaných filtrů nepřinesl nejvyšší hodnotu indexu ENL a zároveň nejnižší hodnoty indexu SSI a indexu SMPI.

Nejlepších výsledných hodnot indexů bylo v naprosté většině případů dosaženo pomocí Leeova filtru. Jedinou výjimkou jsou hodnoty ENL a SSI u Gamma MAP filtru, které jsou stejné nebo velmi podobné. Hodnota indexu SMPI, která odráží i schopnost filtru zachovat původní hodnoty, je ale u Gamma MAP filtru výrazně horší. Pro oba snímky vykazují indexy ENL a SSI nejlepších výsledků u Leeova filtru o velikosti kernelu 9x9 pixelů. Index SMPI dosahuje nejlepších hodnot u Leeova filtru s velikostí kernelu

5x5 pixelů. Na obrázku 1 je zobrazen výřez snímku z 8. června 2009, na který byly aplikovány tři velikosti Leeova filtru.

Na základě výsledných hodnot testovaných indexů byl na všech šesti radarových snímků aplikován Leeův filtr s velikostí kernelu 9x9 pixelů.

Tab. 3: Hodnocení schopnosti filtrů potlačovat speckle ve snímku z 4. května 2009

Filtr	Velikost kernelu	Průměr	ENL	SSI	SMPI
Původní snímek		4 853,28			
Lee	5x5	4 844,22	1,74	0,87	8,74
	7x7	4 842,05	2,02	0,84	10,24
	9x9	4 841,66	2,24	0,82	10,30
Frost (df=2)	5x5	4 819,26	1,62	0,89	30,99
	7x7	4 821,62	1,70	0,88	28,57
	9x9	4 826,94	1,70	0,88	23,91
Gamma MAP	5x5	4 834,88	1,75	0,87	16,85
	7x7	4 825,04	2,03	0,84	24,48
	9x9	4 817,83	2,23	0,82	29,78


Pozn.: Zeleně jsou vyznačeny nejlepší výsledné hodnoty indexů a červeně nejhorší výsledné hodnoty indexů.

Tab. 4: Hodnocení schopnosti filtrů potlačovat speckle ve snímku z 8. června 2009

Filtr	Velikost kernelu	Průměr	ENL	SSI	SMPI
Původní snímek		17 320,19			
Lee	5x5	17 272,11	2,33	0,87	42,80
	7x7	17 267,80	2,65	0,85	45,08
	9x9	17 263,87	2,91	0,83	47,31
Frost (df=2)	5x5	17 162,87	2,21	0,89	139,97
	7x7	17 159,15	2,41	0,87	140,11
	9x9	17 165,41	2,53	0,86	133,15
Gamma MAP	5x5	17 224,17	2,31	0,88	84,83
	7x7	17 202,29	2,62	0,85	100,76
	9x9	17 182,82	2,85	0,84	114,75

Pozn.: Zeleně jsou vyznačeny nejlepší výsledné hodnoty indexů a červeně nejhorší výsledné hodnoty indexů.

Obr. 1: Výřez původního snímku (nahore) a filtrovaných snímků Leeovým filtrem o velikosti kernelu 3x3 (vlevo), 5x5 (dole) a 9x9 pixelů (vpravo)



3.3.2 Geometrické korekce

Geometrické korekce radarových snímků byly provedeny pomocí nástroje *Range-Doppler Terrain Correction* v softwaru *NEST*. Tímto byly získány snímky nejen opravené o zkreslení způsobené nerovností terénu, ale i ortorektifikované do souřadnicového systému WGS 84. Pro topografické korekce byl použit DMT vygenerovaný z vrstevnic ZABAGED. Dále je nutné zadat interpolační metodu pro převzorkování snímku a velikost pixelu. V tomto případě byla použita bilineární interpolace a velikost pixelu 12,5x12,5 m.

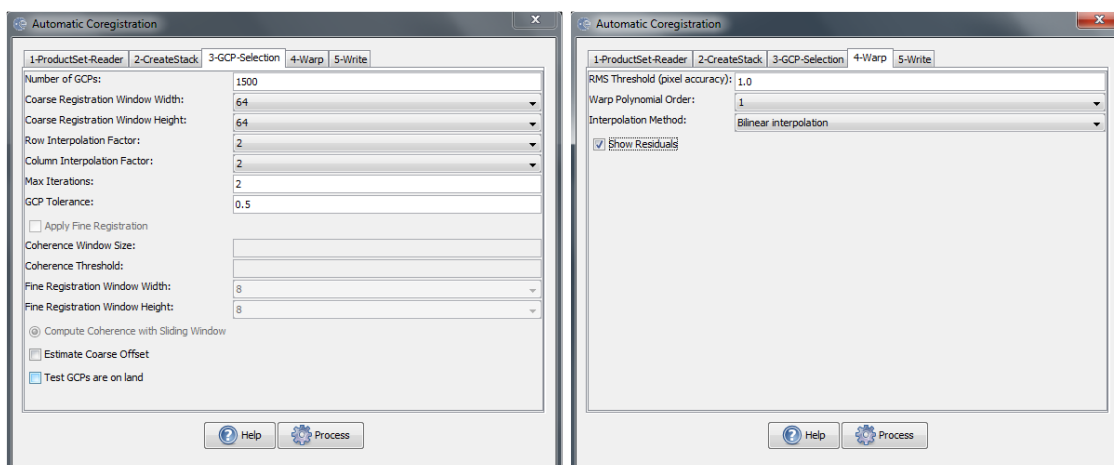
3.3.3 Koregistrace snímků

Koregistrace snímků slouží k polohovému „ztotožnění“ snímků. Snímky označené jako vedlejší (slave bands) jsou transformovány a polohově sjednoceny se snímkem, který je zvolen hlavním (master band). V programu *NEST* k tomu slouží nástroj *Automatic Coregistration*. Proces je plně automatický v tom smyslu, že od uživatele nevyžaduje manuální určení kontrolních bodů.

Koregistrace pomocí softwaru *NEST* je rozdělena do několika kroků. Prvním krokem je *Create Stack* operátor, který prostorově překryje snímky a seskupí je do jednoho produktu. Vedlejší snímky jsou převzorkovány tak, aby odpovídaly snímku hlavnímu. Druhým krokem je výběr kontrolních bodů (*GCP Selection*). V této fázi je nejprve generován soubor rovnoměrně rozmístěných bodů v hlavním snímku a následně jsou vypočteny odpovídající body ve vedlejších snímcích. Dalším krokem je vytvoření finálního koregistrovaného snímku pomocí operátoru *Warp*. Tento operátor vypočítává RMS (kvadratický průměr) a směrodatnou odchylku kontrolních bodů a z procesu koregistrace odstraní ty, které překročí zvolený práh přesnosti. Pro vyhodnocení přesnosti koregistrace snímků je doporučena hodnota *RMS mean* (*NEST* 2013). V této práci byla u všech snímků hodnota *RMS mean* menší než 0,44 pixelu, což je pro účely klasifikace dostačující.

V této práci byl snímek z 8. června 2009 zvolen jako hlavní. Detailní nastavení výběru kontrolních bodů a operátoru *Warp* je na obrázku 2.

Obr. 2: Nastavení automatické koregistrace v programu NEST




3.3.4 Zvětšení příznakového prostoru pomocí texturních měř

Výpočet kanálů s texturními mírami je možné provést při finální fázi objektové klasifikace v programu ENVI. K dispozici jsou zde ovšem pouze čtyři míry, s jejichž pomocí bylo dosaženo velmi špatných výsledků klasifikace. Z tohoto důvodu byly texturní míry vypočteny před samotnou klasifikací, a to pomocí nástroje *Co-occurrence Measures*. Celkem je zde na výběr 8 texturních měř – průměr, rozptyl, entropie, nepodobnost, homogenita, kontrast, korelace a druhý obecný moment. Tyto texturní míry byly pro každý radarový snímek vypočteny s filtračním oknem o velikostech 9x9 pixelů. Celkem tedy vzniklo 48 nových kanálů. Texturní míry zjišťovaly vztahy mezi sousedními pixely ve čtyřech směrech (0°, 45°, 90°, 135°). Na obrázku 3 jsou ukázky vypočtených kanálů pomocí texturních měř, které byly použity pro objektovou klasifikaci.

Obr. 3: Ukázky výsledných texturních měr vypočtených z hlavního snímku pomocí kernelu o velikosti 9x9 pixelů




a) původní snímek




b) průměr




c) rozptyl




d) entropie



e) nepodobnost



f) homogenita




g) kontrast

3.3.5 Maska zemědělsky využívané půdy

Zájmová území obsahují i jiné prvky land use než zemědělskou půdu (zastavěná území, vodní plochy, důl, komunikace, atd.). Proto byla vytvořena maska, pod kterou bude klasifikace probíhat. Masky (obrázek 4) zájmových území byly vygenerovány z polygonové vrstvy LPIS.

Obr. 4: Masky zemědělsky využívané půdy v roce 2009 pro ZÚ1 (nahore) a ZÚ2 (dole)



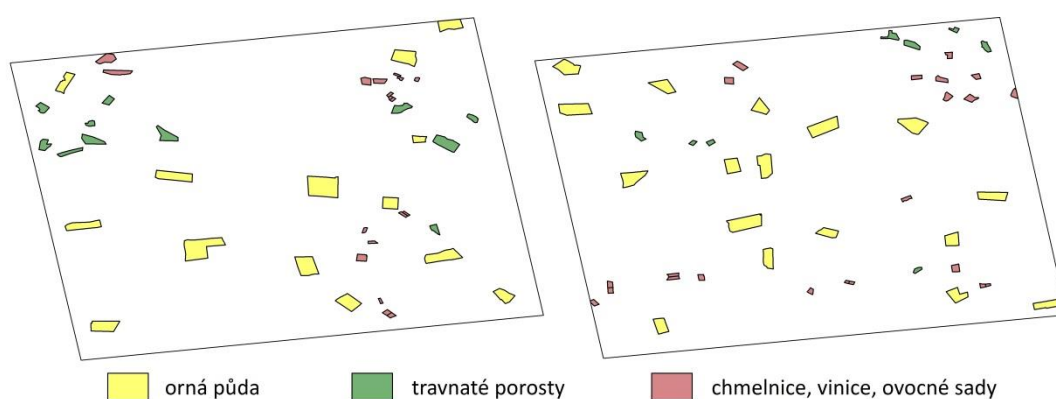
3.4 Tvorba trénovacích a validačních ploch

V této fázi byly určeny trénovací a validační plochy pro všechny kategorie, které mají být ze snímku klasifikovány. Těmito hledanými kategoriemi jsou orná půda, travnaté porosty a sloučené třídy chmelnice, vinice a ovocné sady. Trénovací i validační plochy byly vybírány nad podkladovými daty, které představovala polygonová vrstva LPIS. Pro

trénovací plochy ovšem nebyly vybrány z LPIS celé polygony představující zemědělské půdní bloky, ale pouze jejich vnitřní část tak, aby byly eliminovány pixely na hranicích. Tyto pixely totiž často nesou smíšenou spektrální informaci. Na obrázku 5 jsou znázorněny zvolené trénovací plochy pro obě zájmová území. Počty a rozlohy trénovacích ploch jsou uvedeny v tabulce 5.

Validační plochy slouží k testování celkové úspěšnosti klasifikace. V této práci je představují všechny zemědělské půdní bloky z polygonové vrstvy LPIS mimo těch, které byly použity jako plochy trénovací.

Obr. 5: Trénovací plochy pro ZÚ1 (vlevo) a ZÚ2 (vpravo)



Tab. 5: Počty a rozlohy trénovacích polygonů

zájmové území 1		
třída	počet polygonů	rozloha [ha]
OP	14	621,9
TP	11	148,3
OST	18	100,6

zájmové území 2		
třída	počet polygonů	rozloha [ha]
OP	17	627,3
TP	8	84,1
OST	20	126,8

3.5 Pixelová klasifikace

Pro pixelovou klasifikaci radarových snímků byl zvolen klasifikátor maximální pravděpodobnosti. V prvním kroku byla zvolena předem vytvořená maska, pod kterou klasifikace proběhne. V dalším kroku byly nahrány trénovací plochy ve formátu shapefile. Prahová hodnota pravděpodobnosti byla nastavena na hodnotu 0 tak, aby byly klasifikovány všechny pixely pod maskou.

Testovány byly různé kombinace pásem vzniklých Leeovým filtrem nebo výpočtem texturních měř. Nakonec do klasifikace vstupovala pouze časová řada šesti snímků vzniklých Leeovým filtrem, jelikož přidáním jakýchkoliv texturních měř se přesnost pixelové klasifikace u obou zájmových území spíše zhoršovala.

3.6 Objektová klasifikace

Pro objektovou klasifikaci byla v programu ENVI zvolena možnost *Example-based*. Proces probíhal opět pod vytvořenou maskou zemědělsky využívané půdy. Segmenty byly vytvořeny podle hranic zemědělských bloků získaných z databáze LPIS. Po rozsegmentování obrazu byly nahrány trénovací plochy. V dalším kroku byly vybrány atributy a kanály, které budou do klasifikace vstupovat. Atributy mohou být spektrální, texturní či prostorové, a vždy jsou vypočteny pro každý segment. V rámci každého atributu je možné specifikovat, ze kterých pásem bude vypočítán. Klasifikátorem byl algoritmus SVM. Typ kernelové funkce byl zvolen *Radial Basis*. U tohoto kernelu je potřeba zadat dva parametry – *gamma* a *C* (viz. kapitola Support Vector Machine). Pro klasifikaci byla hodnota *gamma* 0,03 a parametr *C* 100. Proto, aby byly klasifikovány všechny segmenty, byla prahová hodnota přenastavena na nulu.

Testováno bylo mnoho různých kombinací atributů a pásem. Nejlepších výsledků klasifikace bylo dosaženo v případě, kdy pro každý segment byly vypočítány následující atributy:

- *Spectral Mean* a *Spectral STD* pro všech 6 snímků vzniklých Leeovým filtrem
- Texturní parametry průměr, rozptyl, entropie, nepodobnost, homogenita a kontrast pro snímky z 8. června, 13. července, 17. srpna a 21. září
- Prostorový atribut *Area* (velikost segmentu)

3.7 Hodnocení přesnosti

Hodnocení přesnosti klasifikací také proběhlo v softwaru ENVI. Pro výpočet přesností a chybových matic na základě validačních ploch v podobě vektorových vrstev je zde nástroj *Confusion Matrix Using Ground Truth ROIs*. Validacími plochami byly všechny půdní bloky z databáze LPIS kromě těch, které byly použity jako plochy trénovací.

Klasifikační chybové matice vyjadřuje vztah mezi výsledky klasifikace a validačními daty. Matice je čtvercová a počet sloupců a řádků je roven počtu kategorií. Hodnoty

v matici mohou představovat buď počet pixelů nebo jejich procentuální část. Každý sloupec matice reprezentuje hodnoty získané z validačních dat a každý řádek reprezentuje hodnoty získané klasifikací. Hodnoty na hlavní diagonále tedy představují počty či podíly správně klasifikovaných pixelů a hodnoty mimo tuto diagonálu ukazují chyby v klasifikaci. Dále byly vypočteny následující charakteristiky přesnosti – celková přesnost klasifikace, koeficient Kappa, uživatelská a zpracovatelská přesnost pro každou třídu, chyby z nesprávného zařazení a z opomenutí také pro každou třídu.

Chyba z nesprávného zařazení se udává v procentech a vztahuje se k pixelům, které byly do dané třídy přiřazeny klasifikátorem chybně a ve skutečnosti patří do třídy jiné. Výsledná hodnota představuje podíl nesprávně zařazených pixelů do určité třídy z celkového počtu zařazených pixelů do téže třídy. Chyba z opomenutí se také udává v procentech a vztahuje se k pixelům, které byly chybně klasifikovány mimo danou třídu. Výsledná hodnota pro danou třídu představuje podíl chybně zařazených pixelů do ostatních tříd a správně zařazených pixelů do dané třídy (Dobrovolný 1998).

Zpracovatelská a uživatelská přesnost je udávána v procentech a je vypočítána pro každou třídu. Zpracovatelská přesnost představuje poměr mezi počtem pixelů klasifikovaných správně a celkovým počtem pixelů z validačních ploch dané třídy. Uživatelská přesnost je poměr počtu správně klasifikovaných pixelů a celkového počtu pixelů klasifikovaných do dané třídy (Exelis VIS 2015d).

Celková přesnost klasifikace se vyjadřuje jako podíl součtu správně klasifikovaných pixelů všech tříd a celkové sumě pixelů. Hodnota koeficientu Kappa představuje schopnost testované klasifikace vyhnout se chybám, které by vznikly při náhodném zařazování pixelů do tříd (Dobrovolný 1998). Interval koeficientu nabývá hodnot od 0 do 1. Výsledná hodnota koeficientu Kappa rovna 1 se dá tedy vyložit tak, že daná klasifikace se vyhnula 100 % těchto chyb.

4 Výsledky

4.1 Přesnost klasifikací

V tabulkách 6 až 9 jsou uvedené zpracovatelské (ZP) a uživatelské přesnosti (UP) spolu s přesností celkovou a koeficientem Kappa. Pixelová klasifikace dosáhla celkové přesnosti 60,5 % pro ZÚ1 a 45,28 % pro ZÚ2. Kappa koeficient byl pro obě tyto klasifikace velmi nízký – 0,18 respektive 0,07. Objektovou klasifikací bylo dosaženo lepších výsledků. Celková přesnost pro ZÚ1 dosáhla 85,44 % a pro ZÚ2 byla 90,74 %. Kappa koeficient 0,45 a 0,5 se ovšem ani v tomto případě nedá označit jako dostačující. V příloze 2 jsou uvedeny chybové matice výsledných klasifikací. Podrobněji jsou výsledky jednotlivých klasifikací popsány v diskuzi.

Tab. 6: Přesnosti a kapa koeficient pixelové klasifikace ZÚ1

Třída	ZP [%]	UP [%]
OP	59,68	97,09
TP	75,7	20,14
OST	46,49	9,04
Celková přesnost – 60,5 %		
Kappa koef. – 0,18		

Tab. 7: Přesnosti a kapa koeficient pixelové klasifikace ZÚ2

Třída	ZP [%]	UP [%]
OP	44,64	98,13
TP	78,26	4,1
OST	44,42	10,48
Celková přesnost – 45,28 %		
Kappa koef. – 0,07		

Tab. 8: Přesnosti a kapa koeficient objektové klasifikace ZÚ1

Třída	ZP [%]	UP [%]
OP	87,26	97,21
TP	68,67	34,79
OST	70,12	39,4
Celková přesnost – 85,44 %		
Kappa koef. – 0,45		

Tab. 9: Přesnosti a kappa koeficient objektové klasifikace ZÚ2

Třída	ZP [%]	UP [%]
OP	91,12	99,3
TP	80,21	24,59
OST	86,57	44,72
Celková přesnost – 90,74 %		
Kappa koef. – 0,5		

4.2 Klasifikace zemědělského land use

Pixelová klasifikace se pro klasifikaci zemědělských ploch ukázala jako velmi nevhodná a její výsledky nepřinášejí v podstatě žádnou hodnotnou informaci. Z tohoto důvodu jsou v této části popsány výsledky jen objektových klasifikací.

Zemědělské plochy v ZÚ1 zabírají celkovou plochu 15 451,7 ha. Podle výsledků objektové klasifikace je z toho 12 477,2 ha (80,8 %) orné půdy, 2 167,9 ha (14 %) travnatých ploch a 806,6 ha (5,2 %) vinic, chmelnic a ovocných sadů. Skutečné zastoupení těchto tříd v roce 2009 bylo podle databáze LPIS následující – orná půda 88,2 %, travnaté porosty 8,7 % a vinice, chmelnice ov. sady 3,1 %.

Zemědělské plochy v ZÚ2 zabírají celkovou plochu 15 540,8 ha. Podle výsledků objektové klasifikace je z toho 13 394,6 ha (86,2 %) orné půdy, 784,8 ha (5,1 %) travnatých ploch a 1361,4 ha (8,8 %) vinic, chmelnic a ovocných sadů. Skutečné zastoupení těchto tříd v roce 2009 bylo podle databáze LPIS následující – orná půda 93,1 %, travnaté porosty 2,1 % a vinice, chmelnice ov. sady 4,8 %.

Výsledky objektových klasifikací jsou v této práci prezentovány i v podobě 2 mapových výstupů (přílohy 3 a 4). Mapy byly vytvořené pomocí softwaru ArcGIS 10.2.

5 Diskuze

Tato práce měla za cíl zhodnotit a otestovat pixelovou a objektově orientovanou klasifikaci zemědělského land use s použitím radarových dat. Nedílnou součástí je zpracování radarových dat, které zahrnuje například odstranění šumu, geometrické korekce nebo koregistraci snímků. Na základě tří vypočtených indexů se podařilo vybrat nejvhodnější metodu potlačení speckle – Leeův filtr 9x9 pixelů. Radarové snímky byly úspěšně ortorektifikovány a opraveny o topografické chyby. Koregistrace

neboli „ztotožnění“ snímků proběhlo s přesností dostačující pro účely této práce. Fáze zpracování snímků byla velmi náročná a vyžadovala mnoho času. Ne všechny snímky se podařilo připravit úspěšně, ovšem naštěstí se jednalo o snímky pořízené mimo vegetační období. Samotnou klasifikací se podařilo potvrdit obecně známý fakt, že objektová klasifikace je pro radarová data vhodnější než pixelová. Objektovou klasifikací bylo dosaženo poměrně dobrých výsledků, ovšem zejména uživatelské přesnosti se jako dostatečné označit nadají. Výsledné přesnosti klasifikací a možné metody pro jejich vylepšení jsou uvedeny níže.

Pixelová klasifikace ZÚ1 dosáhla nejlepší zpracovatelské přesnosti pro třídu TP (75,7 %). Podobného výsledku bylo docíleno i pro ZÚ2 (78,26 %). Třída OP byla lépe klasifikována na ZÚ1 s výsledkem 59,68 %. Fakt, že více než 40 % orné půdy (na ZÚ2 dokonce 65 %) bylo chybně klasifikováno jako TP nebo OST, se podepsal na velmi špatné uživatelské přesnosti těchto dvou tříd. Důvodem je i několikanásobně menší plocha, kterou TP i OST v porovnání s OP ve skutečnosti zabírají (orná půda zabírá více než 80 % na ZÚ1 i ZÚ2). Pouze 4,1–20,14 % pixelů zařazených do tříd TP a OST bylo klasifikováno správně.

Výrazně lepších výsledků bylo dosaženo pomocí objektové klasifikace. V obou zájmových územích bylo dosaženo nejvyšší zpracovatelské i uživatelské přesnosti pro třídu OP. V ZÚ1 byla zpracovatelská přesnost pro tuto třídu 87,26 % a v ZÚ2 91,12 %. Naopak nejhorší zpracovatelskou přesnost měla třída TP v ZÚ1 – 68,67 %. Tento případ je jediný, u kterého došlo k poklesu zpracovatelské přesnosti v porovnání s pixelovou klasifikací. Nejčastěji byly travnaté porosty chybně klasifikovány jako OP (21,41 %).

Nízké hodnoty uživatelské přesnosti třídy TP a OST jsou i v tomto případě značně ovlivněné skutečnou rozlohou jednotlivých tříd. Chybné zařazení i jednoho relativně malého segmentu, který je ve skutečnosti ornou půdou, do třídy TP nebo OST tak způsobí značné snížení uživatelské přesnosti těchto tříd.

Dobrovolný (1998) uvádí, že použití běžných pixelových klasifikátorů na radarová data je často velmi problematické. S tím se shodují výsledky pixelové klasifikace maximální pravděpodobnosti v této práci. Testovaná metoda pixelové klasifikace je pro rozpoznání daných tříd zemědělského land use nevhodná, což potvrzují i hodnoty koeficientu Kappa. V případě ZÚ1 se tato klasifikace vyhnula pouze

18 % chyb, které by vznikly při náhodném zařazení pixelů do tříd. Pro ZÚ2 to bylo dokonce jen 7 %. Ani zvětšení příznakového prostoru o texturní míry nevedlo u pixelové klasifikace ke zlepšování ukazatelů přesnosti. Toto zjištění je v rozporu se studií Ban a Wu (2005), ve které bylo přidáním kanálů nesoucích informaci o vybraných texturních mírách docíleno lepších výsledků.

Jestliže přidání kanálů s texturními mírami bylo pro pixelovou klasifikaci kontraproduktivní, v případě objektové klasifikace tomu bylo naopak. Pokud informace o textuře využity nebyly, tak výsledné přesnosti dosahovaly kvalit téměř srovnatelných s pixelovou metodou. Objektovou klasifikací bylo u každé třídy dosaženo zvýšení zpracovatelské přesnosti v průměru o 22,5 %. Celková přesnost objektové klasifikace pro ZÚ1 byla 85,44 % a pro ZÚ2 90,74 %. Porovnáním celkových přesností obou metod klasifikací tedy došlo k růstu o 24,94 % u ZÚ1 a o 45,46 % u ZÚ2. Tento prudký nárůst je způsoben převážně zlepšením přesnosti klasifikace třídy OP. Pomocí objektově orientované klasifikace tedy bylo docíleno dobrých zpracovatelských přesností u jednotlivých tříd. Největší problém ovšem představují některé plochy orné půdy, které byly chybně klasifikované jako travnaté plochy nebo třída zahrnující vinice, chmelnice, ovocné sady. Tento fakt se podepsal na uživatelské přesnosti těchto dvou tříd, která dosáhla maximálně na 44,72 %.

Také Tso a Mather (1999) porovnávali pixelový a objektový přístup ke klasifikaci zemědělských ploch z dat ERS-2. Pixelovou klasifikací docílili celkové přesnosti 61,43 % a objektovou klasifikací 77,8 %. V jejich případě šlo tedy o nárůst přesnosti více než 16 %. Objektovou klasifikaci zemědělských plodin z radarových dat testovala ve své habilitační práci také Halounová (2004). K dispozici měla pouze 2 snímky, ze kterých ovšem vypočítala 42 dalších kanálů převážně s texturními mírami. Výsledkem byla celková přesnost 63 %. Nižší celková přesnost než je docílena v této BP, je pravděpodobně způsobena nedostatečnou časovou řadou snímků, složitější legendou a, jak uvádí sama autorka, nepřiliš kvalitní segmentací, která neodpovídá hranicím polí.

K zlepšení výsledků objektové klasifikace by mohlo vést několik kroků. Jedním z nich je použití radarových dat s různou polarizací. Jak již bylo v této práci zmíněno, některé typy povrchů způsobují změnu polarizace signálu. Typickým případem jsou některé typy vegetace. Data s různou polarizací by proto mohla být pro klasifikaci

zemědělských ploch velmi vhodná. Polarizační příznaky jsou použity v mnoha studiích, které dosáhly dobrých výsledků klasifikace radarových dat (Thiel a kol. 2009, Niu a Ban 2011, Alberga a kol. 2008, Park a Chi 2008, Riedel a kol. 2006).

Dalším přínosem pro klasifikaci by mohla být integrace radarových a optických dat. Dobrovolný (1998) vidí největší přínos této kombinace v rozdílných způsobech formování informace. Zatím optická data jsou odrazem především chemického složení snímaných objektů, radarový signál je ovlivněn drsností povrchu a obsahem vody. Integrací radarových a optických dat se zabývá mnoho studií (Chust a kol. 2004, Huang a kol. 2007, Soria-Ruiz a kol. 2010). Například ve studii Benediktsson a Waske (2007) zabývající se klasifikací zemědělských plodin bylo docíleno celkové přesnosti přesahující 80 %. Integrace by mohla proběhnout i s dalšími radarovými daty pořízenými na jiné frekvenci, například v pásmu L.

Ke zlepšení přesnosti klasifikace by mohl vést i výpočet dalších kanálů nesoucích informace o časových změnách nebo detailnější rozdělení některých klasifikačních tříd. Například třída orná půda obsahuje mnoho odlišných povrchů. Různé zemědělské plodiny představují rozdíl i v hodnotách intenzity naměřených radarem. Tento fakt způsobuje problém při výběru reprezentativních trénovacích ploch a následné klasifikaci.

6 Závěr

Cílem práce bylo zhodnotit využitelnost řízené pixelové a objektově orientované klasifikace zemědělsky využívané půdy s použitím radarových snímků. Radarová data představovala časová řada šesti VV polarizovaných snímků pořízených senzorem AMI-SAR v roce 2009. Snímky byly zpracovány v programu NEST. Výpočet texturních měř proběhl v softwaru ENVI. V tomto programu proběhly i samotné klasifikace dvou vybraných území. Pro obě klasifikace byla zvolena řízená metoda. Pixelová klasifikace byla provedena algoritmem maximální pravděpodobnosti, objektová klasifikace pak s využitím algoritmu SVM. U pixelové klasifikace bylo nejlepších výsledků dosaženo pomocí časové řady 6 snímků, na které byl aplikován adaptivní Leeův filtr s velikostí kernelu 9x9 pixelů. Celková přesnost pixelové klasifikace byla 60,5 % pro ZÚ1 a 45,28 % pro ZÚ2. Do objektové klasifikace vstupovalo 6 snímků vzniklých Leeovým filtrem a

dále 6 texturních měr vypočtených pro 4 původní snímky (celkem tedy 30 snímků). Objektová klasifikace dosáhla pro obě zájmová území lepších výsledků než klasifikace pixelová. Celková přesnost byla 85,44 % pro ZÚ1 a 90,74 % pro ZÚ2. Nejlepších výsledků dosáhla kategorie OP se zpracovatelskou přesností 87,26 % a 91,12 %, naopak nejhoršího výsledku v obou zájmových území dosáhla kategorie TP (68,67 % a 80,21 %). Uživatelské přesnosti kategorie TP a OST byly velmi nízké (24,59–44,72 %).

Objektová klasifikace radarových dat přinesla výrazně lepší výsledky než klasifikace pixelová. Stále ale nejsou výsledky dostačující a za účelem jejich vylepšení by bylo vhodné použít například radarová data s různou polarizací, případně využít i dat pořízených optickými přístroji.

Použitá literatura

- ABDULRAHMAN, K. A. (2010): *Remote sensing*. Skripta. Department of Applied Sciences, University of Technology, Baghdad, 74 s.
- ALBERGA, V. a kol. (2008): *Comparison of polarimetric SAR observables in terms of classification performance*. *International Journal of Remote Sensing*, 29, č. 14, s. 4129–4150.
- BAN, Y. (2003): *Multi-temporal ERS-1 and LANDSAT TM data for agricultural crop classification: an artificial neural network approach*. *Canadian Journal of Remote Sensing*, 29, č. 4, 518–526.
- BAN, Y., WU, Q. (2005): *RADARSAT SAR Data for Landuse/Land-Cover Classification in the Rural-Urban Fringe of Greater Toronto Area*. In: TOPPEN, F., PAINHO, M. (ed.): *Proceedings of 8th AGILE Conference on Geographic Information Science*. Estoril, s. 26–33.
- BARBIERI, M., LICHTENEGGER, J. (2005): *Introduction to SAR for Geology*. In: FLETCHER, K. (ed.): *Spaceborn radar applications in Geology*. ESA Publications Division ESTEC, Noordwijk, s. 19–79.
- BENEDIKTSSON, J. A., WASKE, B. (2007): *Fusion of support vector machines for classification of multisensor data*. *IEEE Transactions on Geoscience and Remote Sensing*, 45, č. 12, s. 3858–3866.
- CCRS (2014): *Fundamentals of Remote Sensing*. The Canada Centre for Remote Sensing, Natural Resources Canada, Vancouver, 258 s.
- CHENEY, M., BORDEN, B. (2009): *Fundamentals of radar imaging*. Siam, Philadelphia, 169 s.
- CHUST, G., DUCROT, D., PRETUS, J. L. (2004): *Land cover discrimination potential of radar multitemporal series and optical multispectral images in a Mediterranean cultural landscape*. *International Journal of Remote Sensing*, 25, č. 17, s. 3513–3528.
- DAVIDSON, G. a kol. (2006): *Single-look classification accuracy for polarimetric SAR*. *International Journal of Remote Sensing*, 27, č. 22, s. 5073–5080.

- DOBROVOLNÝ, P. (1998): *Dálkový průzkum Země, digitální zpracování obrazu*. Skripta. PŘF Masarykova univerzita, katedra geografie, Brno, 211 s.
- DOBSON, M. C. a kol. (1995): *Land-cover classification and estimation of terrain attributes using synthetic aperture radar*. *Remote Sensing of Environment*, 51, č. 1, s. 199–214.
- ESA (2015a): *ESA Operational EO Missions* [online]. [cit. 2015-5-10]. Dostupné z: <https://earth.esa.int/web/guest/missions/esa-operational-eo-missions/ers/instruments/sar>
- ESA (2015b): *SAR Precision Image Product* [online]. [2015-5-10]. Dostupné z: <https://earth.esa.int/web/guest/data-access>
- EXELIS VIS (2015a): *Maximum Likelihood (Using ENVI)* [online]. [cit. 2015-4-9]. Dostupné z: <http://www.exelisvis.com/docs/maximumlikelihood.html>.
- EXELIS VIS (2015b): *Example-Based Classification (Using ENVI)* [online]. [cit. 2015-4-9]. Dostupné z: http://www.exelisvis.com/docs/Example_Based_Classification.html.
- EXELIS VIS (2015c): *Support Vector Machine Background (Using ENVI)* [online]. [cit. 2015-4-9]. Dostupné z: <http://www.exelisvis.com/docs/backgroundsvm.html#references>.
- EXELIS VIS (2015d): *Calculate Confusion Matrices (Using ENVI)* [online]. [cit. 2015-5-25]. Dostupné z: <http://www.exelisvis.com/docs/CalculatingConfusionMatrices.html>.
- FANG, Q. a kol. (2004): *Speckle noise reduction in SAR imagery using local adaptive median filter*. *GIScience & Remote Sensing*, 41, č. 3, s. 244–266.
- HALOUNOVÁ, L. (2004): *Klasifikace černobílých leteckých snímků a radarových dat*. Habilitační práce. Katedra mapování a kartografie FSv ČVUT, PRAHA, 143 s.
- HSU, CH. W., CHANG, CH. CH., LIN, CH. J. (2010): *A practical guide to support vector classification*. Department of Computer Science, National Taiwan University, Taipei, 16 s. Dostupné z: <http://www.csie.ntu.edu.tw/~cjlin>.

- HUANG, H., LEGARSKY, J., OTHMAN, M. (2007): *Land-cover Classification Using Radarsat and Landsat Imagery for St. Louis, Missouri*. Photogrammetric Engineering & Remote Sensing, 73, č. 1, s. 37–43.
- IANNINIA, L., MOLIJN, R. A., HANSEN, R. F. (2013): *Integration of multispectral and C-band SAR data for crop classification*. Proceeding of SPIE, Remote Sensing for Agriculture, Ecosystems, and Hydrology, Dresden, 11 s.
- KOLÁŘ, J. (1990): *Dálkový průzkum Země*. Skripta. SNTL – Nakladatelství technické literatury, Praha, 170 s.
- KOLÁŘ, J., HALOUNOVÁ, L., PAVELKA, K. (1997): *Dálkový průzkum Země 10*. Skripta. Vydavatelství ČVUT, Praha, 164 s.
- KUSSUL, N. a kol. (2013): *Crop classification in Ukraine using optical and SAR images*. International Journal “Information Models and Analyses“, 2, č. 2, s. 118–122.
- LPIS (2004): *Principy českého LPIS* [online]. [cit. 2015-5-16]. Dostupné z: <http://www.lpis.eu/cz/case/ch0201.html>.
- LUSCH, D. O. (1999): *Introduction to Microwave Remote Sensing*. Center For Remote Sensing and Geographic Information Science, Michigan State University, Lansing, 84 s.
- MANSOURPOUR, M., RAJABI, M. A., REZAEI, Z. (2008): *Radiometric and Geometric Correction Methods for Active Radar and SAR Imageries*. Department of Geomatics Engineering, University of Tehran, Tehran, 10 s.
- NEST (2013): *Next ESA SAR Toolbox – Help topics*. Součást softwaru NEST.
- NEMMOUR, H., CHIBANI, Y. (2006): *Multiple support vector machines for land cover change detection: An application for mapping urban extensions*. ISPRS Journal of Photogrammetry and Remote Sensing, 61, č. 2, s. 125–133.
- OZDARICI, A., AKYUREK, Z. (2010): *A comparison of SAR filtering techniques on agricultural area identification*. ASPRS 2010 Annual Conference, San Diego, 10 s.
- NIU, X., BAN, Y. (2013): *Multi-temporal RADARSAT-2 polarimetric SAR data for urban land-cover classification using an object-based support vector machine*

- and a rule-based approach*. International Journal of Remote Sensing, 34, č. 1, s. 1–26.
- PARK, N. W., CHI, K. H. (2008): *Integration of multitemporal/polarization C-band SAR data sets for land-cover classification*. International Journal of Remote Sensing, 29, č. 16, s. 4667–4688.
- RAJABI, M. A., MANSOURPOUR, M., BLAIS, J. A. (2006): *Effects and performance of speckle noise reduction filters on active radar and SAR Images*. ISPRS, Workshop on Topographic Mapping from Space, Ankara, 6 s. Dostupné z: http://www.isprs.org/proceedings/XXXVI/1W41/makaleler/Rajabi_Speckle_Noise.pdf.
- RANEY, R. K. (1998): *Radar Fundamentals: Technical Perspective*. In: Henderson, F. M., LEWIS, A. J. (ed): *Principles and applications of imaging radar – Manual of remote sensing, volume 2*. John Wiley and sons, New York, s. ?.
- SORIA-RUIZ, J. a kol. (2010): *Land-cover classification using radar and optical images: a case study in Central Mexico*. International Journal of Remote Sensing, 31, č. 12, s. 3291–3305.
- STIMSON, W. (1998): *Introduction to airborne radar*. SciTech Publishing, Mendham, 584 s.
- THIEL, C. a kol. (2009): *Analysis of multi-temporal land observation at C-band*. Geoscience and Remote Sensing Symposium, IEEE International, IGARSS 2009, č. 3, s. 318–321.
- TRILOBYTE (2010): *Support Vector Machine (Using Trilobyte)* [online]. [cit. 2015-4-9]. Dostupné z: <http://www.trilobyte.cz/downloadfree/qcemanual/svm.pdf>.
- TSO, B., MATHER, P. M. (1999): *Crop discrimination using multi-temporal SAR imagery*. International Journal of Remote Sensing, 20, č. 12, s. 2443–2460.
- ULABY, F. T. a kol. (1986): *Textural information in SAR images*. IEEE Transaction on Geoscience and Remote Sensing, 24 s.
- WANG, X., GE, L., LI, X. (2012): *Evaluation of filters for Envisat ASAR peckle suppression in pasture area*. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, č. 1–7, s. 341–346.

WASKE, B., SCHIEFER, S. (2006): *Classifying segmented multitemporal SAR data from agricultural areas using support vector machines*. In: BRAUN, M. (ed.): *Second Workshop of the EARSeL SIG on Remote Sensing of Land Use & Land Cover – Application and Development*, Bonn, s. 48–54.

ZHANG, B., HONG, W., WU, Y. (2012): *Sparse microwave imaging: Principles and applications*. *Science China Information Sciences*, 55, č. 8, s. 1722–1754.

Seznam příloh

Příloha 1: Přehledová mapa zájmových území	56
Příloha 2: Chybové matice pro pixelové i objektově orientované klasifikace (%) ...	57
Příloha 3: Výsledek objektové klasifikace zemědělských ploch na ZÚ1.....	58
Příloha 4: Výsledek objektové klasifikace zemědělských ploch na ZÚ2.....	59

Příloha 2: Chybové matice pro pixelové i objektově orientované klasifikace (%)

pixelová klasifikace – zájmové území 1

	orná p.	travnaté p.	ch., v., o.s.	celkem
orná půda	59,68	13,19	18,26	54,8
travnaté porosty	24,65	75,7	35,25	28,91
chmel., vin., ov. sady	15,67	11,11	46,49	16,29
zpracovatelská přesnost	59,68	75,7	46,49	
uživatelská přesnost	97,09	20,14	9,04	

pixelová klasifikace – zájmové území 2

	orná p.	travnaté p.	ch., v., o.s.	celkem
orná půda	44,64	8,98	12,64	42,38
travnaté porosty	35,61	78,26	42,94	36,79
chmel., vin., ov. sady	19,75	12,76	44,42	20,83
zpracovatelská přesnost	44,64	78,26	44,42	
uživatelská přesnost	98,13	4,1	10,48	

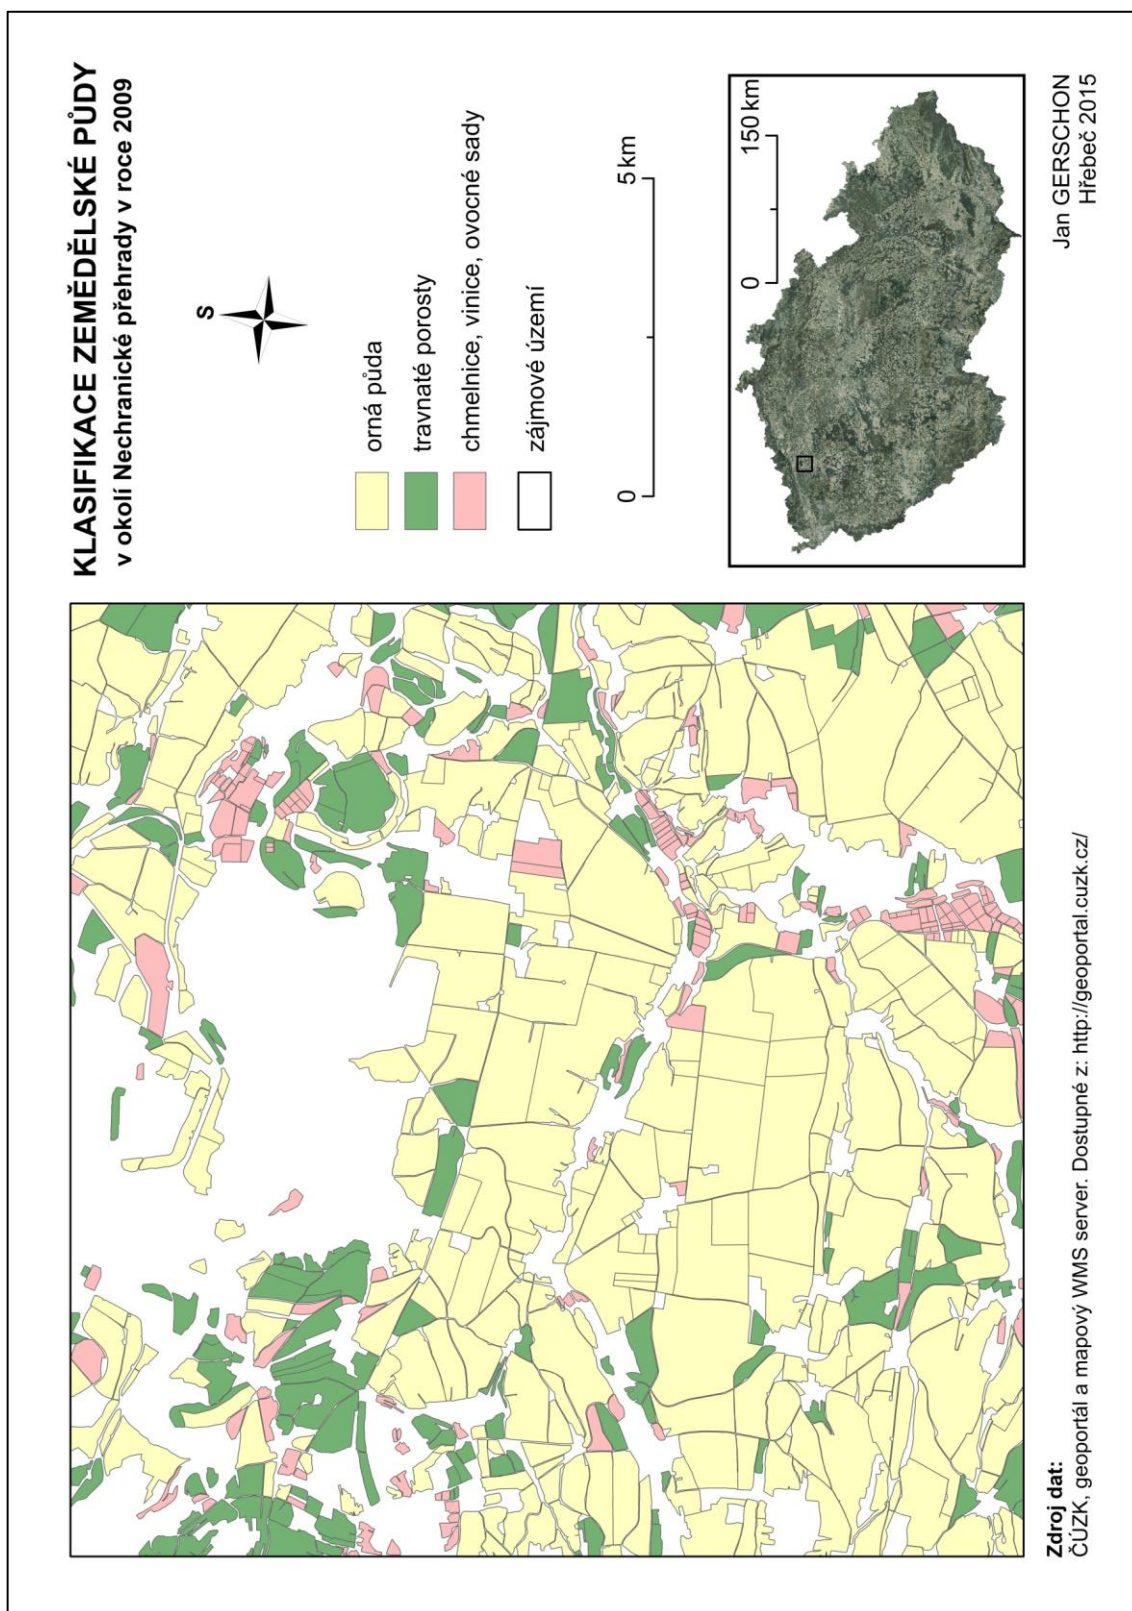
objektová klasifikace – zájmové území 1

	orná p.	travnaté p.	ch., v., o.s.	celkem
orná půda	87,26	21,41	24,95	80,75
travnaté porosty	10	68,67	4,93	14,03
chmel., vin., ov. sady	2,74	9,92	70,12	5,22
zpracovatelská přesnost	87,26	68,67	70,12	
uživatelská přesnost	97,21	34,79	39,4	

objektová klasifikace – zájmové území 2

	orná p.	travnaté p.	ch., v., o.s.	celkem
orná půda	91,12	6,28	11,26	86,19
travnaté porosty	3,95	80,21	2,17	5,05
chmel., vin., ov. sady	4,93	13,51	86,57	8,76
zpracovatelská přesnost	91,12	80,21	86,57	
uživatelská přesnost	99,3	24,59	44,72	

Příloha 3: Výsledek objektové klasifikace zemědělských ploch na ZÚ1



Příloha 4: Výsledek objektové klasifikace zemědělských ploch na ZÚ2

