

**UNIVERZITA KARLOVA V PRAZE**  
**Přírodovědecká fakulta**  
Katedra aplikované geoinformatiky a kartografie



**ANALÝZA HUSTOTY LESNÍCH POROSTŮ  
S VYUŽITÍM TEXTURÁLNÍCH PŘÍZNAKŮ SNÍMKŮ VELMI  
VYSOKÉHO PROSTOROVÉHO ROZLIŠENÍ A DAT  
LETECKÉHO LASEROVÉHO SKENOVÁNÍ**


**ANALYSIS OF FOREST CANOPY DENSITY  
BASED ON TEXTURAL FEATURES OF HIGH RESOLUTION  
IMAGERY AND AIRBORNE LASER SCANNING DATA**

Diplomová práce

Bc. Petra Bromová

srpen 2012

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



*„...vystoupíš ze dveří myslivny, stojí před tebou Luzný směrem jižním pláň uzavíraje.  
Stojí tu, bělavou kostrbatou hlavu maje v bílé mlhy nebo černé mraky zahalenou.  
Stojí tu nehybně, věčně mlčí, jako by truchlil nad změnami posledních desetiletí.  
Z pravé, západní strany ohraničuje pláň Plattenhausen, Velký a Malý Špicberk,  
z levé, východní, Moorkopf a Marberg, všecky lesem zarostlé až do těch temen...“*

*Karel Klostermann: Ze světa lesních samot (1891)*

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně a že jsem všechny použité prameny řádně citovala.

Jsem si vědoma 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 28. srpna 2012

.....

Petra Bromová

### ***Poděkování***

V první řadě bych ráda poděkovala vedoucí mé práce Ing. Markétě Potůčkové, Ph.D. za věnovaný čas, cenné rady a připomínky. Dále děkuji Mgr. Vojtěchu Zeiskovi z Katedry botaniky za zapůjčení fotografického vybavení pro terénní průzkum a Ing. Lukáši Brodskému, Ph.D. z firmy GISAT za poskytnutí aktuální verze software eCognition. Také bych chtěla poděkovat svým přátelům a rodině za podporu.

## **Analýza hustoty lesních porostů s využitím texturálních příznaků snímků vysokého prostorového rozlišení a dat leteckého laserového skenování**

### **Abstrakt**

Hlavním cílem práce je zhodnotit hustotu lesních porostů na Šumavě. Smrkové lesy v této oblasti jsou silně poškozené kůrovcovou kalamitou, která zde vypukla před 20 lety. V území se tak prolínají suché i mladé stromy, zdravé lesy a slatě. Hustota lesních porostů byla hodnocena pomocí objektového přístupu s využitím panchromatických družicových snímků s velmi vysokým prostorovým rozlišením a dat LiDAR s malou hustotou bodů. První klasifikace byla provedena na základě texturálních příznaků určených pro jednotlivé objekty obrazu s využitím tří měr GLCM (kontrast, entropie a korelace). Přesnost této klasifikace hodnocená pomocí kappa indexu byla 0,45. Druhá klasifikace zkombinovala texturálních příznaky s informací z dat LLS a přesnost klasifikace se zvýšila na hodnotu 0,95.

**Klíčová slova:** hustota lesních porostů, textura, letecké laserové skenování, družicové snímky velmi vysokého prostorového rozlišení

## **Analysis of forest canopy density based on textural features of high resolution imagery and airborne laser scanning data**

### **Abstract**

The objective of this thesis is to assess the forest canopy density in the Šumava Mountains, Czech Republic. The spruce forests in this area have been suffering from the bark beetle outbreak for almost 20 years resulting in a mixture of dead and young trees, mature forest stands and peat bogs. The canopy density was evaluated using a very high spatial resolution panchromatic imagery and low point density LiDAR, combined with an object oriented approach. The classification based on three GLCM texture measures (contrast, entropy and correlation), which were derived from the image objects, resulted in a kappa index of accuracy of 0.45. Adding the information from the LiDAR data, the accuracy of the classification improved up to 0.95.

**Keywords:** forest canopy density, texture, airborne laser scanning, very high spatial resolution imagery

## OBSAH

<b>Přehled použitých zkratk</b> .....	<b>8</b>
<b>Seznam obrázků a grafů</b> .....	<b>9</b>
<b>Seznam tabulek</b> .....	<b>10</b>
<b>1 Úvod</b> .....	<b>11</b>
<b>2 Úvod do problematiky</b> .....	<b>13</b>
2.1 Využití DPZ při monitorování lesních porostů .....	13
2.2 Metody pro získávání strukturních parametrů vegetace .....	14
2.2.1 Data leteckého laserového skenování .....	14
2.2.2 Družicové snímky a jejich textura .....	16
2.3 Současný stav a problémy .....	19
<b>3 Charakteristika zájmového území</b> .....	<b>21</b>
3.1 Terénní průzkum .....	22
<b>4 Data a metodika</b> .....	<b>28</b>
4.1 Objektová klasifikace – segmentace .....	28
4.2 GLCM .....	30
4.2.1 Kontrast (contrast) .....	31
4.2.2 Entropie (entropy) .....	31
4.2.3 GLCM korelace (correlation).....	32
4.3 Zpracování dat LLS .....	32
4.4 Klasifikace .....	33
<b>5 Výsledky</b> .....	<b>35</b>
5.1 Výsledky GLCM.....	35
5.2 Klasifikace na základě GLCM textur.....	39
5.3 Výsledky dat LLS .....	40
5.4 Klasifikace s využitím dat LLS.....	42
5.5 Porovnání klasifikací.....	43
5.6 Hustota lesních porostů v zájmové oblasti.....	45
<b>6 Diskuze</b> .....	<b>47</b>
6.1 Terénní průzkum a jeho vyhodnocení.....	48
6.2 Segmentace .....	49
6.3 Textury .....	50

6.4 Data leteckého laserového skenování .....	52
6.5 Metody klasifikace.....	52
6.6 Výsledky klasifikace.....	53
<b>7 Závěr .....</b>	<b>55</b>
<b>Použité zdroje a literatura.....</b>	<b>57</b>
<b>Seznam příloh.....</b>	<b>62</b>

## **PŘEHLED POUŽITÝCH ZKRATEK**

<b>ALS</b>	<b>A</b> irborne <b>L</b> aser <b>S</b> canning
<b>ČÚZK</b>	Český úřad zeměměřický a katastrální
<b>DMR</b>	<b>D</b> igitální <b>m</b> odel <b>r</b> eliéfu
<b>DPZ</b>	<b>D</b> álkový <b>p</b> růzkum <b>Z</b> emě
<b>GLCM</b>	<b>G</b> rey <b>L</b> evel <b>C</b> o-occurence <b>M</b> atrix
<b>LiDAR</b>	<b>L</b> ight <b>D</b> etection <b>A</b> nd <b>R</b> anging
<b>LLS</b>	<b>L</b> etecké <b>l</b> aserové <b>s</b> kenování
<b>NP</b>	<b>N</b> árodní <b>p</b> ark
<b>ÚHÚL</b>	Ústav pro <b>h</b> ospodářskou <b>ú</b> pravu <b>l</b> esů

## SEZNAM OBRÁZKŮ A GRAFŮ

Obr. 1	Kůrovec se v oblasti Modravských slatí stále šíří.....	21
Obr. 2	Místa terénního průzkumu.....	23
Obr. 3	Určení zápoje v závislosti na rozmístění stromů.....	24
Obr. 4	Hemisférická fotografie vyhodnocovaná v programu Gap Light Analyzer.....	26
Obr. 5	Porovnání ortofot a hemisférické fotografie pro plochu 26.....	27
Obr. 6	Výsledky segmentace při různých poměrech parametrů barva/tvar a měřítkovém parametru 900.....	29
Obr. 7	Filtrace dat LLS.....	33
Obr. 8	Obnova lesa ve starých kůrovcových oblastech.....	47
Obr. 9	Příklad špatně vytvořených segmentů.....	50
Graf 1	GLCM kontrast × entropie.....	36
Graf 2	GLCM entropie × korelace.....	37
Graf 3	GLCM kontrast × korelace.....	37
Graf 4	Histogram výskytu rozdílů mezi klasifikacemi.....	43

## **SEZNAM TABULEK**

Tab. 1	Výsledky terénního průzkumu.....	27
Tab. 2	Výpočty textur .....	35
Tab. 3	Prahové hodnoty pro rozhodovací strom klasifikace s využitím textur.....	38
Tab. 4	Chybová matice klasifikace s využitím textur.....	39
Tab. 5	Výpočty odrazů dat LLS pro plochy terénního průzkumu .....	40
Tab. 6	Prahové hodnoty pro rozhodovací strom klasifikace s využitím textur a dat LLS .....	41
Tab. 7	Chybová matice klasifikace s využitím textur a dat LLS .....	42
Tab. 8	Porovnání klasifikací formou chybové matice .....	44
Tab. 9	Podíl kategorií hustoty lesních porostů na počtu segmentů.....	45
Tab. 10	Rozloha kategorií hustoty lesních porostů v zájmové oblasti.....	46
Tab. 11	Použité kombinace parametrů při multiresolution segmentation.....	49

## 1 ÚVOD

Lesy na Šumavě jsou v posledních letech vystaveny velkému zájmu veřejnosti. Důvodem je přemnožení podkorního hmyzu, především tzv. kůrovce, neboli lýkožrouta smrkového, který se v současnosti v tamějších smrkových porostech vyskytuje ve zvýšeném až kalamitním stavu (Knížek et al. 2010). Problematický je hlavně velkoplošný rozpad nepůvodních smrčín, čímž se zhoršuje ekologická stabilita lesních porostů i celého životního prostředí (Garčár et al. 2010). Mění se také hustota lesních porostů, která je důležitou fyziognomickou charakteristikou porostů. Dá se vyjádřit jako počet stromů na dané ploše nebo v procentech jako poměr velikosti jejich spodní (bazální) plochy k celkové rozloze stanoviště (Joshi et al. 2006). V této práci bude ale hustota vnímána jako zapojenost porostu. V Národní inventarizaci lesů prováděnou Ústavem pro hospodářskou úpravu lesů (ÚHÚL) je zápoj definován jako vzájemný dotyk a prolínání větví stromů. Vyjádří se jako poměr plochy zakryté vertikální projekcí korun stromů k celkové ploše porostu. Může nabývat hodnot od 0 do 100 %. Zapojenost lesních porostů je běžnou ekologickou charakteristikou, která ovlivňuje energetický, světelný a látkový režim v porostu (ÚHÚL, Inventarizace lesů, Metodika venkovního sběru dat). Používá se pro určování vhodnosti prostředí pro výskyt zvířat nebo mapování rizika požárů (Korhonen et al. 2011).

Hustotu porostů kromě kůrovce ovlivňují také například větrné katastrofy nebo zásahy člověka. Dosavadní studie poukazují na to, že spouštěcím faktorem všech kůrovcových kalamit jsou právě pozdě nebo nekompletně odstraněné polomy (Zemek, Heřman, Klouda 1999). Předmětem četných diskuzí je především způsob, jak s nastalou situací na Šumavě naložit. Různí autoři (např. Jonášová a Prach 2004, Hais 2009, Hais et al. 2009) zkoumají stav lesních ekosystémů v místech s holosečnou těžbou oproti porostům ponechaným samostatnému rozpadu. Oba dva typy ploch vykazují rozdílné chování, např. holiny se mnohem více přehřívají, což může mít vážné důsledky pro obnovu lesních porostů. Tyto plochy je proto třeba od sebe odlišit, k čemuž je využitelný mimo jiné i parametr hustota.

Strukturu lesních porostů, včetně jejich hustoty, lze zkoumat pomocí nejrůznějších metod DPZ. Kromě klasických optických metod je možné využít také radarové nebo laserové skenování. V této práci jsou k hodnocení hustoty lesních porostů využity panchromatické snímky z družice WorldView-2. Hustota porostů ale není určována přímo z hodnot šedi jednotlivých pixelů, ty jsou totiž využity k výpočtu textur. Další metodou hodnocení hustoty využitou v této práci jsou data leteckého laserového skenování (LLS). Díky přímému přístupu

## *1. Úvod*

ke strukturním parametrům vegetace je jejich potenciál k přesnému určení hustoty vegetace nejvyšší.

Cílem této práce je ohodnotit využitelnost texturálních příznaků panchromatických snímků velmi vysokého prostorového rozlišení a laserových dat k určení hustoty lesních porostů. Od jiných výzkumů, které se touto problematikou zabývaly, se tato práce liší hlavně zájmovým územím. Pokrývají ho smrkové lesy, které jsou však silně poškozené větrnými i hmyzími kalamitami. Z toho důvodu byla také hustota lesních porostů určována jako zapojenost a ne jako počet stromů, protože je obtížné určit, zda uschlý strom bez jehličí je stále ještě stromem.

Text práce je rozdělen do šesti částí. V úvodní teoretické části je čtenář seznámen s problematikou monitoringu lesních porostů pomocí dálkového průzkumu Země a se základními pojmy. Následuje popis zájmového území a terénního průzkumu. V další části je popsána použitá metodika. Hlavní část práce se věnuje popisu výsledků. V předposlední kapitole jsou porovnány informace z teoretické části práce se získanými výsledky. Závěr práce shrnuje nejdůležitější poznatky.

## 2 ÚVOD DO PROBLEMATIKY

### 2.1 Využití DPZ při monitorování lesních porostů

Monitorování lesů pomocí dálkového průzkumu Země (DPZ) má mnoho opodstatnění. DPZ totiž umožňuje zaznamenávat údaje pro rozsáhlé plochy nebo místa těžko dosažitelná terénním průzkumem. Měření je navíc možno periodicky opakovat, takže se tento způsob pořizování dat hodí nejen pro vyhodnocování aktuálního stavu, ale i změn, které v území nastaly v čase. Pozemní zkoumání je oproti tomu poměrně drahé a časově náročné, může ale pomoci ke správné kalibraci dat DPZ nebo k doplnění některých informací, a tak bývá poměrně často s metodami DPZ kombinováno (Tomppo et al. 2008).

Monitorování změn stavu lesa pomocí interpretace obrazových dat z DPZ má v Česku i ve světě poměrně dlouhou tradici. Tyto metody bývají využívány hlavně v zemích s velkými plochami lesních porostů. České lesy jsou analyzovány pomocí DPZ již od 90. let v souvislosti s úbytkem lesa v severních Čechách (Zemek, Heřman, Klouda 1999). V Národním parku (NP) Bavorský les se od roku 1988 pořizují barevné infračervené snímky a jejich analýza je standardním nástrojem pro vyhodnocení rozsahu a průběhu odumírání lesa (Hájek, Svoboda 2007; Heurich et al. 2010).

Tradiční metodou je využití analogového leteckého snímkování, později byly k dispozici snímky digitální s prostorově vyšším rozlišením. Satelitní snímky se v lesnictví začaly ve větší míře využívat asi před 20 lety, kdy se komerčně zpřístupnily snímky s rozlišovací schopností pod 20 m (Garčár et al. 2010, Heurich et al. 2010). Při pořizování leteckých snímků vznikají různé geometrické odlišnosti, které pak komplikují analýzu více časových horizontů. Nevýhodou leteckých snímků je pak hlavně nižší spektrální, radiometrická a časová rozlišovací schopnost než u snímků satelitních. Avšak cena leteckých snímků je nižší a prostorové rozlišení většinou vyšší (Hájek 2006). Výhodou satelitních snímků oproti leteckým snímkům je velkoplošnost a nižší náročnost při zpracování a vyhodnocování (Garčár et al. 2010). Kromě multispektrálních satelitních snímků je možné k monitorování vegetace využít také snímky hyperspektrální, které ještě zvyšují množství informace, které je možno z analýzy snímků získat (Treitz, Howarth 1999).

Protože množství vyhodnocovaných dat se stále zvyšuje, namísto vizuální interpretace snímků se stále častěji používají automatizované metody. Problematickou oblastí je ale vyhodnocování dat s velmi vysokým rozlišením, jako jsou letecké nebo podrobné satelitní

## 2. Úvod do problematiky

snímky, kde je vysoká spektrální variabilita mezi obrazovými prvky (pixely). Tradiční techniky klasifikace založené na identifikaci jednotlivých pixelů v obraze poskytují dobré výsledky jen pro snímky s nízkým a středním prostorovým rozlišením (Heurich et al. 2010). Značného zpřesnění klasifikace lze dosáhnout využitím objektové klasifikace, která jednotlivé pixely spojuje do homogenních ploch (tzv. segmentů) reprezentujících objekty (nebo části objektů) reálného světa. Tento přístup ke klasifikaci pak pracuje nejen se spektrálními charakteristikami, ale také s tvarem, texturou, prostorovým rozmístěním objektů, jejich vzájemnými vztahy a kontextem. Pro další zlepšení kvality modelu podle skutečných zákonitostí slouží fuzzy klasifikace a klasifikace na bázi neuronových sítí. Rozvoji těchto metod se v současnosti věnuje velká pozornost (Hájek 2006; Hájek, Svoboda 2007; Heurich et al. 2010).

Pro získávání informací o lesních plochách lze využít také radarová data typu SAR, kdy se využívá hlavně koherence mezi dvěma snímky, ve které se skrývá potenciál pro velkoplošné mapování. Množství informací získaných z radarových dat je ale zpravidla menší než u dat optických (např. Hyypä et al. 2000). Data leteckého laserového skenování zase umožňují přímé zjištění výšky porostu, která ale bývá často podhodnocena, a dalších strukturních parametrů jako je třeba právě hustota porostu (Zhao et al. 2011). Na základě tvaru koruny je například možné určit druh stromu. K tomu je ale potřeba dostatečná hustota zaznamenaných bodů, jakou poskytuje například full-waveform LiDAR. Ten umožňuje rekonstrukci celého odraženého signálu a zachytí tak mnohem více informace než LiDAR se záznamem diskretních pulzů (Miura a Jones 2010, Pirotti 2011). Velkou nevýhodou takových laserových dat ale bývá jejich vysoká pořizovací cena. Jako nejvhodnější se tak jeví spíše kombinace třírozměrných dat LLS, která poskytují informaci o struktuře, a dvourozměrných spektrálních dat pro informaci o spektrálních vlastnostech povrchu. Data LLS se mimoto dají využít k tvorbě digitálních modelů povrchu (např. Lim et al. 2003, Walter 2004, Ke, Quackenbush a Im 2010, Tonolli et al. 2011, Richardson a Moskal 2011).

## 2.2 Metody pro získávání strukturních parametrů vegetace

### 2.2.1 Data leteckého laserového skenování

Letecké laserové skenování (LLS) nebo také LiDAR (Light Detection and Ranging) představuje aktivní typ senzoru, který vysílá laserový paprsek (většinou v infračervené části spektra) k objektu a měří čas, za který se paprsek od objektu odrazí a vrátí zpět k senzoru. Podle způsobu zaznamenávání odrazů z jednotlivých pulzů se LiDARy dělí na přístroje s registrací pouze několika odrazů (discrete return) a vysoké hustoty odrazů (full waveform). Horizontální rozlišení lidarových dat určuje velikost stopy paprsku na zemi, která závisí na rozbíhavosti paprsku a výšce letu.

Full waveform LiDAR zaznamenává množství energie paprsku, který se k senzoru od objektu vrátí, v daných časových intervalech. Množství zaznamenaných dat je větší, a tak se tento typ LiDAR hodí pro zkoumání např. vertikální struktury vegetace. LiDAR se záznamem

## 2. Úvod do problematiky

diskrétních pulzů naopak zaznamenává většinou pouze první a poslední odraz. Oba dva typy LiDAR se dříve lišily také ve velikosti stopy paprsku na zemi. U full waveform bývala stopa většinou velká, až v řádu metrů, zatímco v případě diskrétních pulzů stopa většinou nepřesáhla velikost jeden metr (Lim et al. 2003). Od roku 2004 jsou však již k dispozici moderní přístroje, které umožňují zaznamenat kompletní průběh laserového paprsku i při použití stopy o velikosti 25 cm (Reitberg, Krzystek a Stilla 2009).

Zatímco LiDAR s malou stopou umožňuje při dostatečné hustotě bodů detailně modelovat jednotlivé části vegetace, LiDAR s velkou stopou zachytí celkovou strukturu vegetace a spíše pronikne až na zem. Schopnost paprsku projít vegetací je velmi důležitá pro určování výšky vegetace. Ta ale bývá většinou lehce podceněna (cca o 1 m), protože laserový paprsek málokdy zaznamená opravdu nejvyšší část porostu. Přesnost určení výšky tedy závisí na tvaru vegetace, hustotě laserových bodů a velikosti stopy paprsku (Pirroti 2011).

Pro své vlastnosti tedy data LLS poskytují přímý přístup ke strukturním parametrům vegetace. Ne všechna data LLS jsou ale vhodná pro analýzy. Například data LLS pořízená primárně pro topografické účely, tj. data s hustotou 1–2 body na  $m^2$ , se nehodí pro zkoumání uzavřenosti vegetace, protože nezaznamenají malé mezery v korunách stromů (Korhonen et al. 2011).

Mnoho autorů se již pokusilo využít data LLS k určení hustoty lesů jako počtu stromů na určité ploše. Heurich (2008) se v NP Bavorský les pokusil detekovat jednotlivé koruny stromů za využití dat LLS s vysokou hustotou bodů (5–10 bodů/ $m^2$ ) a pomocí watershed algoritmu, který se jinak používá hlavně v hydrologii. Poměrně úspěšná byla jeho metoda u vrchní vrstvy stromů, u spodní vrstvy se mu podařilo rozeznat jen malé procento stromů. Přesnější výsledky byly navíc dosaženy pro jehličnaté stromy než pro stromy listnaté. Bylo ale možno identifikovat přes 90 % objemu dřeva změřeného pozemním zkoumáním. Yu et al. (2011) úspěšně použili tzv. random forest technique, což je neparametrická regresní metoda pro určování atributů jednotlivých stromů z dat LLS s malou plochou stopy (small-footprint). Jednotlivé stromy určili segmentací pomocí rastrového modelu výšky vegetace. Richardson a Moskal (2011) ve své práci poukázali na problémy dat LLS při pronikání nižší hustou vegetací. Skutečná hustota vegetace byla výsledky analýzy podceňována.

Méně autorů se ale zabývá zapojeností porostu, protože tradiční lesní inventarizace tento parametr většinou opomíjejí (Korhonen et al. 2011). Podrobně se na tuto problematiku soustředili Korhonen et al. (2011), kteří věnovali zvýšenou pozornost také získávání dat pozemním měřením. Existují dva způsoby určení zapojenosti porostu: 1) vertical canopy cover (VCC), což je vertikální projekce korun ignorující mezery v koruně, a 2) angular canopy closure (ACC), který lépe popisuje světelné podmínky pod vegetací, je závislý na úhlu pozorování a sleduje i mezery uvnitř jednotlivých korun. Pozemní měření zapojenosti porostu se tradičně provádějí pomocí hemisférických fotografií. Výsledky z pozorování jehličnatých lesů ve Finsku potvrdily, že VCC a ACC v nízkých zenitových úhlech mají geometrii shodnou s daty LLS, a proto z nich mohou být odvozena přímo z podílu odrazů od vegetace, a to s velkou přesností.

## 2. Úvod do problematiky

Charakteristiky spojené se zapojeností porostu využili také např. Donoghue et al. (2007), kteří se snažili odlišit smrk a borovici v lesích ve Skotsku. Jako první metodu uplatnili předpoklad, že smrkové porosty jsou hustší než borové, a proto bude průnik dat LLS smrkovými porosty omezen více než v případě borovic. Druhou metodou bylo využití intenzity laserových dat, tj. blízkého infračerveného záření. Tato metoda se ukázala jako nejlepší samostatný ukazatel pro odlišení daných druhů stromů.

O kombinaci dat LLS a multispektrálních dat se jako jedni z prvních pokusili Hudak et al. (2006). Použili LiDAR se záznamem diskretních pulzů a multispektrální i panchromatické satelitní snímky ALI (Advanced Land Imager), z nichž získali celkem 26 proměnných, kterými pak pomocí mnohonásobné lineární regrese určovali hustotu a bazální plochu jehličnatých lesů v Idahu. Jednou z proměnných byla také směrodatná odchylka panchromatických snímků jako míra textury dat, v konečných modelech ale tato proměnná nebyla využita. Větší význam měly proměnné získané z dat LLS, ačkoli proměnné z dat ALI vysvětlovaly více variance v hustotě než v bazální ploše. Celkově bylo lepší přesnosti dosaženo u parametru bazální plocha. Fúzi laserových a multispektrálních dat zkoumali v nedávné době také Tonolli et al. (2011), ale jejich cílem byl odhad objemu dřeva v jižních Alpách. Použitá data LLS byla také pořízena pro topografické účely, v analýze ale byly využity spektrální příznaky multispektrálních snímků IRS.

### 2.2.2 Družicové snímky a jejich textura

Hustotu porostů je možno zkoumat i z multispektrálních optických dat. Joshi et al. (2006) porovnali čtyři různé metody pro získání informací o hustotě porostu z dat Landsat ETM+. Využili metody neuronových sítí, mnohonásobnou lineární regresi, klasifikaci maximální pravděpodobnosti a tzv. forest canopy density mapper, což je metoda pro získání hustoty vegetace z dat Landsat TM pomocí čtyř parametrů. Nastavení prahových hodnot parametrů ale závisí na zkušenostech člověka a metoda je tak značně subjektivní. 89 % variance v hustotě vegetace bylo vysvětleno metodou neuronových sítí, která tak byla lepší než zbylé tři metody a podávala správné předpovědi. Tato metoda je ale trochu komplikovaná při tvoření a není vždy úplně přesně známo, jak funguje.

Hustotě lesa se věnovali i Platt a Schoennagel (2009), kteří zkoumali její vztah s rizikem vzniku lesních požárů v Coloradu. Použili historické letecké snímky a současná ortofota, které hodnotili pomocí objektového přístupu v programu eCognition. Les rozdělili do čtyř kategorií hustoty na základě jeho spektrálních příznaků s využitím fuzzy klasifikace. Kontrolu klasifikace provedli porovnáním s manuální klasifikací (korelace 0,88) a klasifikací používanou organizací USDA Forest Service (korelace 0,61).

Různí autoři pracují také s texturou obrazových dat, která je důležitou kvalitativní charakteristikou nejrůznějších objektů. Formální definice textury neexistuje, většinou ale bývá popisována jako míra prostorových změn v hodnotách šedi blízkých (sousedních) pixelů v obraze (Haralick 1973; Bharati, Liu a MacGregor 2004; Sarker a Nichol 2011). Při využití

## 2. Úvod do problematiky

textury při klasifikaci se předpokládá, že hodnoty šedi nejsou po snímku rozmístěny zcela náhodně, ale že existují určité závislosti pro jednotlivé třídy krajinného pokryvu (Rodriguez-Galiano et al. 2012).

Bharati, Liu a MacGregor (2004) definují čtyři různé přístupy k analýze textury, které se liší metodou získávání texturálních příznaků:

1. **Statistické metody.** Nejpoužívanější metodou z této skupiny je grey-level co-occurrence matrix (GLCM), která využívá statistik druhého řádu z šedotónových histogramů obrazu.
2. **Strukturální metody.** Definují texturu jako opakující se prostorové prvky, např. linie. Kvůli popisu jenom pravidelných tvarů je ale využití těchto metod omezené.
3. **Metody založené na modelování.** Pro každý pixel se určuje jeho empirický model na základě váženého průměru pixelů z okolí.
4. **Metody založené na transformaci.** Převádějí obraz do nové podoby (např. Fourierova transformace, Multi-way Principal Component Analysis (MPCA), vlnková (wavelet) transformace.

Nejčastěji je jako míra textury využita GLCM. Na základě výzkumu autorů Carr a Pellon de Miranda (1998) je tento přístup v případě optických družicových dat lepší než jiné metody hodnocení textury, včetně semivariance, která také patří mezi geostatistické metody a bývá používána jako nástroj pro určení vhodné velikosti okna, ve kterém je poté počítána GLCM (Coburn a Roberts 2004). GLCM vyjadřuje pravděpodobnost, že dva pixely vzdálené od sebe o počet pixelů  $\delta$  v daném směru  $\theta$  mají stejnou intenzitu (hodnotu šedi). Existuje tedy mnoho různých kombinací, Haralick et al. (1973) doporučují využít  $\delta = 1$  nebo  $2$  a  $\theta = 0^\circ, 45^\circ, 90^\circ$  a  $135^\circ$ .

K hodnocení GLCM lze přistupovat mnoha různými přístupy (viz Haralick et al. 1973), z nichž některé jsou silně korelované. Většina autorů doporučuje využít entropii, druhý úhlový moment (angular second moment) nebo kontrast a pak také korelaci nebo homogenitu. Velmi důležitá je také volba velikosti okna, ve kterém bude GLCM hodnocena, protože zásadním způsobem mění dosažené výsledky.

Před provedením analýzy s využitím GLCM je tedy třeba se zamyslet nad několika proměnnými, které shrnují např. Franklin, Maudie a Lavigne (2001). Patří mezi ně volba velikosti vyhledávacího okna, volba vhodných měř textury, volba spektrálních kanálů, pro který bude textura určována, radiometrické rozlišení dat a volba vzdálenosti a jejího směru mezi jednotlivými dvojicemi pixelů.

Pokud je při využití textury v analýze leteckých nebo družicových snímků zkoumaným parametrem hustota lesa, bývá většinou uvažována jako počet stromů na určitou plochu. Výjimku tvoří práce Lévesque a Kinga (2003), kteří zkoumali mimo jiné uzavřenost vegetace ve smíšených lesích v Kanadě za využití digitálních leteckých snímků s různým prostorovým rozlišením. Jako nejužitečnější byly na základě výsledků určeny snímky s velikostí pixelu 0,5 m. Textury (GLCM) a semivarianci hodnotili v kombinaci s metodami spectral unmixing.

## 2. Úvod do problematiky

Pozemní měření uzavřenosti vegetace bylo provedeno pomocí kalibrované tabulky pro určení podílu černého povrchu na bílém pozadí (Lévesque a King 1999). Textura se ukázala být důležitou proměnou při modelaci zkoumaných parametrů, spektrální příznaky a obrazové frakce přispěly jen málo do konečných modelů.

Moskal a Franklin (2002) se pomocí textury leteckých snímků pokusili klasifikovat druhy stromů v jehličnatých a smíšených lesích v Kanadě. Nejlepší přesnosti klasifikace (86,7 %) dosáhli se snímky s prostorovým rozlišením 60 cm, využití textury (GLCM) zpřesnilo klasifikaci o cca 15 % oproti využití pouze spektrálních příznaků. Autoři také došli k závěru, že vztah mezi lesní strukturou a texturou snímků je silnější, pokud je velikost pixelu těchto snímků 1 m nebo méně.

Kayitakire, Hamel a Defourny (2006) využili snímky Ikonos pro získání parametrů výška, věk, hustota a bazální plocha u stejnověkových smrkových lesů v Belgii. Texturu hodnotili také pomocí GLCM. Nejlépe odhadnutou veličinou byla výška, kde byly chyby srovnatelné jako při využití LiDAR nebo SAR. Velká chyba byla zaznamenána u odhadů hustoty a bazální plocha byla jen slabě korelovaná s texturními příznaky vegetace.

Ozdemir a Karnieli (2011) se snažili získat strukturální parametry suchého lesa v Izraeli pomocí snímků WorldView-2. Texturu hodnotili na základě směrodatné odchylky hodnot šedi a GLCM a prokázali, že strukturální parametry lesa jsou významně korelovány s texturními příznaky. Strukturu lesa hodnotili také Wunderle, Franklin a Guo (2007). Zkoumali vztah SCI (Structural Complexity Index) ke spektrálním příznakům, texturám GLCM a NDMI (Normalized Difference Moisture Index) za využití snímků SPOT, jejichž prostorové rozlišení bylo pomocí pansharpeningu zvýšeno na 2,5 m. Došli k závěru, že nejlépe jsou s SCI korelovány spektrální příznaky středního infračerveného pásma a NDMI, proto by se k vegetačním studiím měly využívat snímky obsahující tyto spektrální pásma. Z texturních příznaků se nejlépe osvědčila míra kontrast a to spíše při větších velikostech vyhledávacího okna.

Srovnání spektrálních příznaků, vegetačních indexů a texturních příznaků pro určení množství biomasy v tropických lesích v Hong Kongu provedli Sarker a Nichol (2011). Využili snímky ALOS AVNIR-2 s velikostí pixelu 10 m. Využití GLCM textur poskytovalo mnohem lepší výsledky než využití spektrálních příznaků včetně vegetačních indexů. Nejlepších výsledků (korelace 0,88) bylo dosaženo při využití poměrů texturních parametrů.

Jednou z mála prací, které k hodnocení strukturálních parametrů lesa pomocí textury využívají objektový přístup, je výzkum Ozdemira et al. (2008). Využili snímky ASTER s prostorovým rozlišením 15 m a sledovali korelaci bazální plochy heterogenního středomořského lesa v Turecku s GLCM prvky homogenita, kontrast a odlišnost (dissimilarity). Nejvyšší korelaci ( $r = 0,69$ ) vykazovala bazální plocha určená Gini koeficientem s parametrem homogenita.

## 2. Úvod do problematiky

Objektový přístup společně s texturami použili také Balaguer et al. (2010), jejichž cílem byla klasifikace zemědělské oblasti na středomořském pobřeží ve Španělsku. Více se soustředili na využití semivariogramu, výsledky ale porovnali také s klasifikací za využití sedmi parametrů GLCM. Jako obrazová data byla využita ortofota s prostorovým rozlišením 0,5 pixelů. Celková přesnost klasifikace snímků s využitím GLCM dosáhla 86,9 %, v případě semivariogramu se ještě zlepšila na 90,7 %.

Kombinaci objektového přístupu, textur a dat LLS zkoumali Ke, Quackenbush a Im (2010) ke klasifikaci druhů stromů ve smíšených lesích ve státě New York v USA. Použili multispektrální snímky QuickBird s velikostí pixelu 2,44 m a data LLS s nízkou hustotou odrazů (průměrná vzdálenost mezi jednotlivými odrazy 2,5 m). Textury byly hodnoceny pomocí GLCM, využity byly míry průměr a směrodatná odchylka. Nejvyšší přesnosti klasifikace dosáhli při využití všech druhů příznaků (spektrální, texturní, laserové) a při segmentaci, která byla provedena na základě multispektrálních dat i dat LLS.

### 2.3 Současný stav a problémy

Nejpoužívanějšími zdroji dat pro zkoumání lesních porostů bývaly snímky pořízené družicemi Landsat nebo Spot, případně letecké snímky. Nyní autoři zkoumají spíše využití satelitních snímků s velmi vysokým prostorovým rozlišením a hyperspektrálních, laserových nebo radarových dat. Vzhledem k rozloze lesních porostů v Česku se satelitní snímky se středním prostorovým rozlišením považují za nedostatečné a hodí se spíše pro národní inventarizační účely. Satelitní snímky s vysokým prostorovým rozlišením jsou však hlavně v českém prostředí využívány velmi zřídka a nahrazovány jsou většinou snímky leteckými, jejichž zpracování zejména ve více časových horizontech je obtížnější. Vizualní interpretace snímků je nahrazována pixelovou nebo objektovou klasifikací, v poslední době také metodami strojového učení a dalšími statistickými metodami, například regresní a korelační analýzou. Tyto metody poskytují lepší výsledky především při klasifikaci dat vysokého prostorového rozlišení.

Zatímco dříve se většina prací zaměřovala na hodnocení zdravotního stavu lesa nebo monitorování rozsahu lesních porostů, nyní se mnohem častěji věnuje pozornost struktuře lesních porostů, která zahrnuje např. hustotu, objem kmenů, množství biomasy nebo prostorové uspořádání. K analýze těchto parametrů ale nestačí pouze spektrální informace, je třeba využít také další příznaky, např. informace o textuře obrazových dat. V mnoha studiích již bylo prokázáno, že přidání texturních příznaků přesnost klasifikace zvyšuje (např. Franklin, Maudie a Lavigne 2001; Moskal a Franklin 2002; Narasimha Rao et al. 2002; Coburn a Roberts 2004, Mallinis et al. 2008; Sarker a Nichol 2011).

Při objektovém přístupu k satelitním snímkům velmi vysokého prostorového rozlišení je možno sledovat vztah mezi texturou objektů a lesní strukturou. Mnoho autorů už takové metody využilo pro získání řady lesních parametrů, hustota porostu jako jeho zapojenost se však v těchto pracích téměř nevyskytuje. Příčinou může být fakt, že zapojenost porostu nepatří do

## *2. Úvod do problematiky*

tradičních lesních inventarizací (Korhonen et al. 2011). Často bývá zkoumána hustota lesa jako počtu stromů na určité ploše, ta ale v kombinaci s texturními mírami nedosahuje dostatečné přesnosti. Zapojenost porostů však má v tomto přístupu lepší předpoklady (viz Lévesque a King 2003).

Mnoho informací o prostorovém uspořádání lesa pak poskytují především data leteckého laserového skenování, která jsou ale poměrně drahá, náročná na zpracování a ne vždy dostupná v požadované kvalitě (např. Chen a Hay 2011). Pro určování zápoje lesních porostů bývají využívána častěji, velmi podrobně se této problematice věnovali Korhonen et al. (2011). Data LLS pro oblast Šumavy existují, byla ale pořízena primárně pro topografické účely, proto je jejich hustota poměrně malá. Sama o sobě se tedy nehodí pro podrobné analýzy struktury lesních porostů a bude proto studováno jejich využití v kombinaci s družicovými daty velmi vysokého prostorového rozlišení.

### 3 CHARAKTERISTIKA ZÁJMOVÉHO ÚZEMÍ

Zájmové území se nachází v centrální části Šumavy v lokalitě Březníku a Modravských slatí (viz Příloha 2). Rozkládá se u hranice s Německem a kompletně spadá do území Národního parku Šumava. Vzhledem k výpočetním schopnostem používaného hardware byla zvolena velikost území cca 53 km<sup>2</sup>. Na severovýchodě je území ohraničeno obcí Modrava, na severozápadě přibližně Rokytskou slatí, na jihu státní hranicí. Nejnižším bodem je obec Modrava s nadmořskou výškou cca 980 m n. m., nadmořská výška nejvyšších pohraničních vrcholů se pohybuje okolo 1370 m n. m. Kromě Modravy se v území nenachází žádné jiné obce, z 97 % ho tedy pokrývají jehličnaté lesy a slatě. Zájmové území bylo vybráno proto, že tato pohraniční část Šumavy s přesahem do Německa směrem k Luznému a Roklanu je oblastí největšího plošného rozpadu horských smrčín na Šumavě (Hais 2009, Heurich et al. 2010).



*Obr. 1: Kůrovec se v oblasti Modravských slatí stále šíří*

Jako počátek problémů s kůrovcem na Šumavě lze považovat roky 1983 a 1984, ve kterých došlo v důsledku vichřic k rozsáhlým polomům v Národním parku (NP) Bavorský les v Německu na ploše 173 ha. Přibližně polovina těchto ploch se nacházela v přírodních zónách a byla ponechána přirozenému rozkladu. Rozpadající se stromy tak poskytly dobré podmínky pro další šíření kůrovce (viz např. Obr. 1). V dalších letech kůrovec napadl i zdravé stromy a

### 3. Charakteristika zájmového území

v roce 1995 plocha rozpadlých smrčín v NP Bavorský les poprvé přesáhla 200 ha v jednom roce (Hais 2009, Heurich et al. 2010).


Na české straně se kůrovec výrazněji projevil roku 1992 a od té doby se rozloha odumírajícího lesa každoročně zvyšuje. V roce 1995 byla Správou NP Šumava vyhlášena a v roce 1997 ještě rozšířena bezzásahová zóna na jih od silnice mezi Roklanskou hájenkou a Březníkem. V roce 1996 už bylo kůrovcem napadeno 80 % této bezzásahové plochy. V druhé polovině 90. let byly v okolí bezzásahového pásma prováděny holosečné těžby, aby se zabránilo dalšímu šíření kůrovce (Hais 2009, Heurich et al. 2010).

K dalším výrazným polomům na Šumavě došlo v letech 2007 a 2008 (orkán Kyrill, vichřice Emma a Ivan) a plocha evidovaného poškození se každoročně zvyšuje (Knížek et al. 2010). V roce 2009 už bylo celorepublikově evidováno téměř 3 mil. m<sup>3</sup> „kůrovcového dříví“, což je nejvyšší zaznamenané roční množství za 50 let a pravděpodobně se jedná i o vůbec nejvyšší historickou hodnotu. Podobný vývoj událostí je možno sledovat i v řadě okolních zemí. Nejvážnější situace je v jihozápadních a středních Čechách, kde tato oblast bezprostředně souvisí s větrnými polomy z let 2007 a 2008 (Knížek et al. 2010).

#### 3.1 Terénní průzkum

Ještě před začátkem klasifikace bylo třeba v zájmovém území provést terénní průzkum a vybrat plochy, které pomohou s určením texturních příznaků a počtu laserových odrazů jednotlivých kategorií korunového zápoje. Na základě vizuálního hodnocení bylo ze segmentovaného snímku vybráno 44 ploch reprezentujících různé typy lesa (viz Obr. 2), ve kterých byl určen korunový zápoj. Souřadnice míst byly ukládány pomocí navigačního přístroje s využitím systému GPS a polohovou přesností cca 2 m.

## MÍSTA TERÉNNÍHO PRŮZKUMU

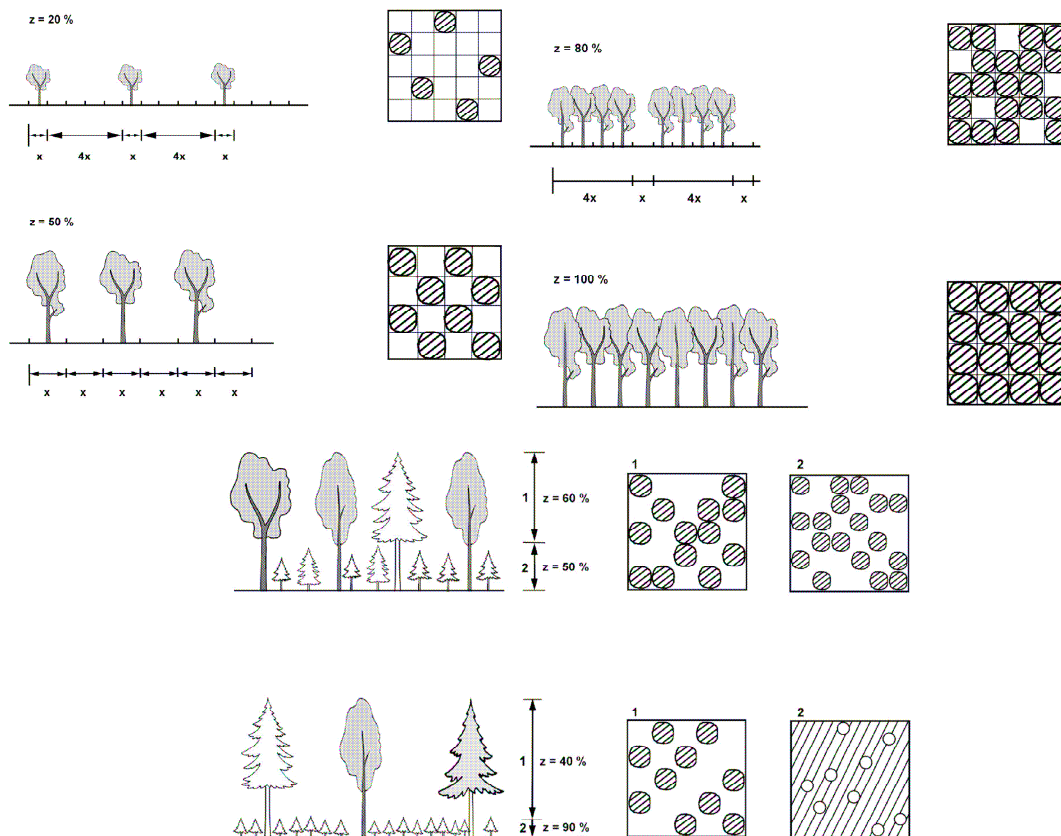


**Obr. 2: Místa terénního průzkumu**

V terénu lze korunový zápoj určit různými způsoby, které ve své bakalářské práci popisuje např. Wernerová (2007). Nejjednodušší a nejrychlejší metodou je vizuální odhad, který v České republice využívá například ÚHÚL při Národní inventarizaci lesů. Pracovníci v terénu zapojenost odhadují vizuálně s přesností na 10 % pro každou porostní vrstvu zvlášť (viz Obr. 3). V tomto případě je vizuální odhad také tím nejvhodnějším způsobem, protože jiné metody nejsou pro určování zápoje pro různé porostní vrstvy příliš vhodné, jelikož by docházelo k vzájemnému ovlivňování těchto vrstev. V metodice Národní inventarizace lesů ÚHÚL se také poněkud odlišně hodnotí zapojenost mladých porostů, jejichž větve a koruny se ještě zdaleka nedotýkají – pokud jsou nárosty po ploše pravidelně rozmístěny a dá se tedy předpokládat, že

### 3. Charakteristika zájmového území

v dospělosti bude porost zapojený, nezaznamenává se aktuální míra zapojenosti, ale její očekávaná hodnota v budoucnu. Vizuální metoda hodnocení zapojenosti tak je poněkud subjektivní a vyžaduje praxi.



**Obr. 3: Určení zápoje v závislosti na rozmístění stromů (zdroj: ÚHÚL, Inventarizace lesů, Metodika venkovního sčítání dat)**

Určitou kombinací vizuálního odhadu a přesnějšího měření zapojenosti je použití kalibrované tabulky pro určení podílu černého povrchu na bílém podkladu. Tuto metodu ve svém výzkumu použili Lévesque a King (1999), kteří tak určili zapojenost lesního porostu v intervalech po 5 %. Pro dosažení dostatečné přesnosti bylo určování hustoty několikrát opakováno, následně i porovnáno s měřením pomocí speciálního přístroje pro určování indexu listové plochy (Leaf Area Index – LAI) a výsledkem byla poměrně vysoká korelace mezi oběma měřeními.

Běžně využívanou metodou pro určování zapojenosti lesních porostů je pořizování fotografií lesa kolmo k obloze, kdy je možno určit velikost, tvar a rozmístění mezer v lesním porostu. Při tomto způsobu se využívá fotoaparát se speciálním širokoúhlým objektivem zvaným rybí oko. Výsledkem jsou tzv. hemisférické fotografie, které zachycují celou stromovou klenbu v maximálním úhlu 180°. Fotografie se poté vyhodnocují pomocí speciálních programů, které určí počet pixelů reprezentujících vegetaci, resp. oblohu a vypočtou míru zapojenosti

### 3. Charakteristika zájmového území


porostu (Joshi et al. 2006, Korhonen et al. 2011). Tato metoda může poskytovat velmi přesné výsledky, proto byla zvolena i pro tuto práci.

Kvalita a vypovídací schopnost pořízených hemisférických fotografií ale závisí na celé řadě faktorů. Kromě kvality samotného technického vybavení, především speciálního objektivu, záleží také na nastavení expozice a zaostření snímků. Kontrast mezi oblohou a vegetací by měl být dostatečný pro přesné zařazení všech pixelů snímku do jedné z těchto dvou kategorií. Nesprávně zvolená expozice může způsobit přespvětlení snímků, které pak znemožní jejich vyhodnocení. Neméně důležitou podmínkou při pořizování hemisférických fotografií je počasí. Obloha by měla být jednolitá, nejlépe zcela zatažená, a bez slunečního svitu, který způsobuje nerovnoměrné osvětlení snímané scény a komplikuje vyhodnocování snímků. Lepších výsledků je dosaženo při použití černobílých fotografií (Frazer et al. 2001).

Terénní průzkum s využitím hemisférických fotografií byl proveden 21. 4. a 23. 6. 2012. Povětrnostní podmínky bohužel nebyly ideální. Počasí po oba dva dny bylo polojasné až oblačné. 21. 4. bylo kvůli značnému množství sněhu v zájmové oblasti nasnímáno pouze 16 zájmových ploch, 23. 6. bylo nasnímáno zbylých 28 ploch. Na každé zájmové ploše byly pořízeny 2 až 3 fotografie, v hustém lese bylo snímků pořízeno více než na místech s velmi řídkým stromovým porostem. Fotoaparát byl umístěn na stativu ve výšce 1,3 m nad zemským povrchem, aby se omezil vliv podrostu, a zorientován k severu.

Získané hemisférické fotografie byly vyhodnoceny pomocí programu Gap Light Analyzer (dostupný například z URL: <http://www.rem.sfu.ca/forestry/publications/downloads/gaplightanalyzer.htm>), který je přímo určen k získávání hodnot uzavřenosti vegetace z hemisférických fotografií. Do výpočtu je možno zařadit mnoho dalších proměnných, např. distorzi objektivu, zeměpisné souřadnice, nadmořskou výšku a orientaci místa pořízení fotografie nebo začátek a konec vegetačního období. Pomocí prahové hodnoty jsou pixely rozděleny na ty představující oblohu a na ty ostatní, tedy vegetaci (viz Obr. 4). Klasifikace je poměrně jednoduchá v případě, že existuje dostatečný kontrast mezi oblohou a vegetací. Pro zpřesnění klasifikace je možné rozdělit obraz do jednotlivých RGB kanálů. V případě oblačné oblohy se osvědčilo využití modrého spektrálního pásma. Po provedení klasifikace snímku program vypočte procento uzavřenosti vegetace.

### 3. Charakteristika zájmového území




**Obr. 4: Hemisférická fotografie vyhodnocovaná v programu *Gap Light Analyzer***

Při vyhodnocování fotografií bylo v několika případech pojata podezření na změnu stavu lesních porostů mezi datem pořízení družicového snímku a terénním průzkumem, tj. přibližně za rok a půl. Plochy, které podle družicového snímku měl koncem roku 2010 pokrývat zdravý les, se změnilý v les suchý, resp. usychající. Stejně tak usychající lesy v roce 2010 byly v roce 2012 už jenom holými kmeny. Důsledkem těchto změn jsou naměřené hodnoty zapojenosti z roku 2012, které ale neodpovídají skutečnému stavu z roku 2010. Protože se ale jedná o plochy s charakteristickou texturou, bylo třeba je do klasifikace nějakým způsobem začlenit.

Jako pomocný zdroj informací tak byla použita barevná ortofota, na kterých je aktuální stav lesa vidět mnohem lépe než na černobílém snímku WorldView. Bohužel není k dispozici ortofoto, které by bylo pořízeno ve stejné době jako družicový snímek, použita tak byla ortofota z roku 2008 (Geodis) a z roku 2011 (ČÚZK) dostupná například z Národního geoportálu INSPIRE provozovaného organizací CENIA (<http://geoportal.gov.cz/web/guest/map>). Obě ortofota lze pomocí WMS služby nahrát do programu ArcMap a přesně v nich lokalizovat místo pořízení hemisférické fotografie.

Na základě porovnání ortofot z roku 2008 a 2011 bylo u čtyř ploch rozhodnuto zvýšit kategorii zapojenosti lesa o jednu úroveň. Tyto plochy jsou v tabulce 1 označeny hvězdičkou. V případě všech ploch se v roce 2012 jednalo už o v podstatě jen holé kmeny stromů. V roce 2008 to byly víceméně zdravé stromy a v roce 2011 byly ještě stále obaleny suchým jehličím, jejich zapojenost tak byla prokazatelně vyšší než v roce 2012 (viz Obr. 5). Pro kontrolu byly také použity informace z dat LLS (viz dále), jejichž stáří se nejvíce blíží datu pořízení snímku WorldView.

### 3. Charakteristika zájmového území



**Obr. 5:** Porovnání ortofot a hemisférické fotografie pro plochu 26: a) ortofoto z roku 2008, b) ortofoto z roku 2011, c) hemisférická fotografie z roku 2012 (červeně vyznačeno místo pořízení snímku)

Čtyři plochy terénního průzkumu byly z hodnocení vyřazeny. Ve většině případů se jednalo o špatně vysegmentované plochy, kde se mísily různě husté lesní porosty. Zapojenost tak byla určena pro 40 ploch, přehled naměřených hodnot shrnuje tabulka 1. Pro účely klasifikace bylo rozhodnuto rozdělit zapojenost do pěti kategorií: 0 – 20 %, 20,1 – 40 %, 40,1 – 60 %, 60,1 – 80 % a 80,1 – 100 %.

**Tab. 1:** Výsledky terénního průzkumu

Plocha	Naměřená zapojenost [%]	Kategorie	Plocha	Naměřená zapojenost [%]	Kategorie
1	84,44	5	21	8,27	1
2	68,24	4	22	6,72	1
3	0,41	1	23	16,48	1
4	19,41	1	24	12,29	1
5	1,04	1	25	0,43	1
6	14,63	1	26*	26,76	3
7	9,175	1	27	1,69	1
8	58,44	3	28	0,02	1
9	2,19	1	29	21,43	2
10	15,47	1	30	6,98	1
11	80,63	5	31	6,92	1
12	3,21	1	32	10,71	1
13	6,62	1	33	4,01	1
14	75,92	4	34	10,28	1
15	4,92	1	35	5,52	1
16	47,78	3	36	20,61	2
17	13,49	1	37	51,34	3
18	2,96	1	38	57,9	3
19*	16,48	2	39*	48,85	4
20	0,13	1	40*	32,09	3

**Poznámka:** \* kategorie byla oproti naměřené hodnotě zvýšena

## 4 DATA A METODIKA

Primárním datovým zdrojem byly panchromatické snímky WorldView-2, pořízené 27. 10. 2010 za téměř bezoblačné oblohy. Zasazeny byly do souřadného systému UTM, pásmo 33 N. Radiometrické rozlišení snímků činilo 16 bitů a jednotlivé pixely měly velikost 50 cm. Bylo tedy možné rozlišit koruny jednotlivých stromů. Snímky pokrývající zájmové území byly pomocí mozaikování spojeny do jednoho souboru. Proces byl proveden v programu Geomatica od společnosti PCI Geomatics, konkrétně v modulu OrthoEngine. Použita byla metoda automatického mozaikování bez jakýchkoli barevných úprav.

Jako doplňující zdroj informace byla využita data LLS ve formátu *las*, která byla pořízena na jaře roku 2011. Na rovině je vzdálenost mezi jednotlivými body cca 1 až 2 m. Hustota bodů je tak cca 0,5 bodu/m<sup>2</sup>, v porostech s vyšší zapojeností stoupá hustota laserových odrazů na cca 1 bod/m<sup>2</sup>. Jedná se o tzv. full-waveform data, z jejich vlastností byl využit počet odrazů pro charakterizování hustoty vegetace. Protože snímky WorldView i data LLS byly pořízeny s krátkým časovým odstupem, je možné předpokládat, že v mezidobí v území neproběhly výraznější změny a získané informace se budou doplňovat.

Protože neexistuje jednoznačná metodika pro určení zapojenosti porostů z optických dat za využití textury, byl testován vlastní nový postup. Analýza hustoty porostů byla prováděna pomocí objektového přístupu v programu eCognition, ve kterém byla obrazová data WorldView byla rozčleněna na segmenty o podobných spektrálních vlastnostech.


Texturální příznaky hustoty porostů z panchromatických dat byly následně doplněny také o informace z dat LLS s předpokladem, že dojde k dalšímu zlepšení přesnosti klasifikace. Program eCognition od verze 8.7 přímo podporuje data LLS ve formátu *las*, není tedy třeba je převádět na jiné formáty.

### 4.1 Objektová klasifikace – segmentace

Základní jednotkou objektové klasifikace není pixel, ale skupina prostorově souvisejících pixelů s podobnými vlastnostmi. Tyto skupiny pixelů (segmenty) představují objekty reálného světa nebo jejich části a jsou tvořeny tzv. segmentací. Segmentační algoritmy zahrnují spektrální i tvarové charakteristiky tvořených segmentů. Existuje řada různých segmentačních algoritmů, program eCognition jich nabízí sedm (eCognition Developer 8.7: Reference Book 2011).

Nejjednodušší jsou metody Chessboard a Quadtree, které obraz rozdělí do čtvercových objektů. Mezi složitější metody patří například tzv. multiresolution segmentation popsaná autory Baatz a Schäpe (2000), která byla použita také v této práci. Jedná se o tzv. bottom-up přístup, kdy z dílčích pixelů vznikají objekty shlukováním do dané míry homogenity, která je definována jako směrodatná odchylka vážená počty pixelů. Růst objektů omezují parametry segmentace, což jsou v tomto případě měřítkový (scale) parametr, který řídí velikost vznikajících objektů, a váhy pro spektrální a tvarové vlastnosti. Čím větší je měřítkový parametr, tím více pixelů a z nich vznikajících segmentů může být spojeno, a vznikají tak větší objekty.

Spektrální a tvarové vlastnosti řídí kritéria barva (colour), tvar (shape), kompaktnost (compactness) a hladkost (smoothness). Dvojice parametrů barva/tvar definuje při tvorbě objektů důležitost barvy vs. tvarové homogenity. Součet parametrů je jedna, proto čím vyšší je důležitost barvy, tím nižší je důležitost tvarového kritéria. Tvarové kritérium se dále dělí na dvojici parametrů kompaktnost/hladkost, jejichž součet je opět jedna. Kompaktnost posuzuje odchylku od kompaktního tvaru a vyjádří se jako poměr obvodové délky hraniční linie objektu ku počtu pixelů tvořících objekt. Hladkost je kritériem tvarové heterogenity a jedná se tentokrát o poměr obvodové délky hraniční linie objektu a nejkratší délky obvodu čtyřúhelníka opsaného obrazovému objektu paralelně k obrazovému rastru.



**Obr. 6: Výsledky segmentace při různých poměrech parametrů barva/tvar a měřítkovém parametru 900: a) 0,9/0,1; b) 0,6/0,4; c) 0,3/0,7; d) 0,1/0,9**

Nastavení jednotlivých parametrů segmentace bylo tedy nutné věnovat velkou pozornost, aby vznikly vhodně velké a relativně homogenní objekty. Podle Ozdemira et al. (2008) je pro

vytvoření smysluplných objektů důležitý především parametr barva, protože spektrální příznaky jsou primárním zdrojem informace obsažené ve snímcích. Byly testovány různé kombinace parametrů barva/tvar a to konkrétně (0,1/0,9), (0,2/0,8), (0,3/0,7), (0,4/0,6), (0,5/0,5), (0,6/0,4), (0,7/0,3), (0,8/0,2) a (0,9/0,1). Kompaktnost/hladkost byly ponechány v poměru (0,5/0,5). Při nízkých hodnotách parametru tvar byly však tvořeny velmi nekompaktní segmenty, při velmi nízkých hodnotách parametru barva zase docházelo k míchání různých typů lesa (viz Obr. 5). Podle vizuálního hodnocení tak byla jako nejvhodnější kombinace zvolena hodnota parametru tvar 70 a hodnota parametru barva 30. Měřítkový parametr byl testován v hodnotách 500, 600, 700, 800, 900 a 1000 a jako nejvhodnější byla vybrána hodnota 900. Při nižších hodnotách měřítkového parametru opět vznikaly poměrně nekompaktní segmenty. Do segmentace vstupovaly pouze spektrální příznaky snímků WorldView, data LLS nebyla využita.

## 4.2 GLCM

Grey-Level Co-occurrence Matrix (GLCM) je matice, která vyjadřuje, jak často (s jakou pravděpodobností) se v obraze vyskytují jednotlivé kombinace stupňů šedi. Jedná se většinou o veličiny druhého řádu, protože je zkoumán vztah mezi dvojicemi pixelů v obraze. Jednotlivé pixely spolu sousedí nebo jsou od sebe jen málo vzdáleny. Někdy se využívají také veličiny prvního řádu, což jsou statistiky počítané bez ohledu na prostorové vztahy mezi pixely, např. průměr, směrodatná odchylka, modus nebo medián (Coburn a Roberts 2004, GLCM Texture Tutorial 2007).

Při zkoumání dvojic pixelů záleží samozřejmě také na směru, ve kterém se tak děje. Program eCognition umožňuje určit GLCM v směru 0°, 45°, 90° a 135°, kdy 0° je směr vertikální a 90° směr horizontální. Protože rozdíly mezi jednotlivými směry mohou být poměrně velké, je vhodné využít výpočet ve všech směrech, kdy jsou hodnoty GLCM v jednotlivých směrech sečteny (eCognition Developer 8.7: Reference Book 2011).

Každá GLCM je pro vyjádření pravděpodobnosti normalizována:

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}},$$

kde  $i$  je číslo řádku,  $j$  je číslo sloupce,  $V_{i,j}$  je hodnota matice v buňce  $i,j$ ,  $N$  je počet řádků nebo sloupců a  $P_{i,j}$  je normalizovaná hodnota v buňce  $i,j$ . Jedná se tedy o poměr určité dvojice hodnot ku celkovému počtu dvojic a výsledek se vždy pohybuje v intervalu (0,1) (GLCM Texture Tutorial 2007, eCognition Developer 8.7: Reference Book 2011).

Podle způsobu určování vah jednotlivých buněk GLCM je možno tyto míry textury rozdělit do tří skupin (GLCM Texture Tutorial 2007):

1. **Textury založené na kontrastu.** Váhy se určují podle vzdálenosti buňky od diagonály matice, protože na diagonále se nacházejí dvojice pixelů se shodnou hodnotou šedi, tj. se žádným kontrastem. Do této skupiny patří míry kontrast, odlišnost a homogenita.
2. **Textury založené na uspořádání.** Zkoumá se pravidelnost uspořádání hodnot v matici. Tyto míry jsou vahami samy o sobě. Jedná se o druhý úhlový moment, maximální pravděpodobnost a entropii.
3. **Popisné statistiky textur GLCM.** Statistiky jako průměr (mean), variance a korelace (correlation) se určují v závislosti na výskytu určitých hodnot sousedních pixelů.

Některé míry jsou spolu korelovány, většinou ty ze stejné skupiny. Např. homogenita je korelována s kontrastem a odlišností. GLCM variance je korelována se všemi mírami ze skupiny kontrastu. Entropie je korelována s druhým úhlovým momentem. Naopak GLCM průměr a korelace nejsou korelovány s žádnou jinou GLCM mírou (GLCM Texture Tutorial 2007).

Nejčastěji využívanými mírami GLCM jsou entropie, druhý úhlový moment, kontrast, korelace a homogenita. Na základě informací o jejich korelovanosti byly pro tuto práci zvoleny míry kontrast, entropie a korelace, tj. z každé skupiny jedna.

#### 4.2.1 Kontrast (contrast)

Kontrast je míra lokálních variací hodnot šedi mezi jednotlivými pixely. Pro výpočet kontrastu se jednotlivé prvky GLCM násobí vahami vzhledem ke vzdálenosti od diagonály matice. Protože na diagonále se nacházejí dvojice pixelů se shodnou hodnotou šedi, tj. se žádným kontrastem, používá se pro výpočet váhy následující rovnice:

$$\sum_{i,j=0}^{N-1} P_{i,j} (i-j)^2$$

Čím více se od sebe budou hodnoty šedi dvou pixelů lišit, tím větší bude jejich váha (GLCM Texture Tutorial 2007).

#### 4.2.2 Entropie (entropy)

Entropie je pojem používaný nejčastěji ve fyzice nebo matematice. Vyjadřuje míru neurčitosti systému, někdy bývá také označována jako míra neuspořádanosti. Protože logaritmus nuly není definován, předpokládá se, že  $0 \cdot \ln 0 = 0$ . Pokud je pravděpodobnost výskytu jednotlivých kombinací stupňů šedi v obraze stejná, hodnoty šedi jsou rozložené náhodně, resp. rovnoměrně a entropie je vysoká (GLCM Texture Tutorial 2007).

$$\sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j})$$

### 4.2.3 GLCM korelace (correlation)

GLCM korelace sleduje lineární závislost hodnot šedi sousedních pixelů. Je nezávislá na všech ostatních mírách textury.


$$\sum_{i,j=0}^{N-1} P_{i,j} \left[ \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right]$$

## 4.3 Zpracování dat LLS

Aby data LLS obsahovala jenom odrazy od lesního porostu, muselo být originální bodové mračno vyfiltrováno. Cílem bylo odstranit všechny body do vzdálenosti 1,3 m od zemského povrchu. Tato výšková hranice zaručuje odstranění vlivu lesního podrostu a ve stejné výšce byly během terénního průzkumu pořízeny i hemisférické fotografie.

Pro práci byla zvolena kombinace programů LAStools a ArcGIS. Ze sady nástrojů LAStools byl nejprve zvolen las2shp, který převádí bodové mračno ve formátu *las* na jednotlivé body ve formátu shapefile. Vlastní filtrace bodů pak byla prováděna v programu ArcGIS s pomocí nadstavby 3D Analyst, která umožňuje práci s trojrozměrnými daty.

Pro popis zemského povrchu byl zvolen bodový digitální model reliéfu DMR 4G, který byl odvozen právě z používaného bodového mračna. Principem filtrace bodového mračna bylo nalézt všechny body, které se nacházejí ve vzdálenosti do 1,3 m od bodů DMR 4G (tedy zemského povrchu) a poté výběr převrátit. Protože ale vzdálenost jednotlivých bodů DMR 4G je 5 m, bylo třeba body zahustit. K tomu byla vzhledem k pravidelnému rozmístění bodů vybrána metoda interpolace IDW a vytvořen rastrový DMR o velikosti buňky 1 m. Tento rastr byl poté převeden zpět na body a proveden prostorový výběr. Tak byly vybrány všechny body, jejichž vzdálenost od zemského povrchu je větší než 1,3 m (viz Obr. 6). Tyto body byly vyexportovány do nové vrstvy a poté opět pomocí programu LAStools a nástroje shp2las převedeny do formátu *las*.



*Obr. 7: Filtrace dat LLS: a) snímek WorldView, b) originální bodové mračno, c) vyfiltrované bodové mračno*

#### 4.4 Klasifikace

Existují dva způsoby, kterými lze přiřazovat jednotlivé segmenty do tříd klasifikace – tzv. fuzzy klasifikace a metoda rozhodovacího stromu. Každá z nich má své výhody, a proto se využívají oba způsoby.

Fuzzy klasifikace patří mezi tzv. měkké klasifikátory a umožňuje vyjádřit neurčitost zařazení segmentu do třídy. Každá třída je popsána pomocí fuzzy výrazů, které jsou určeny na základě trénovacích ploch, a vyjadřují podmínky, za kterých je objekt zařazen do dané třídy.

Fuzzy klasifikace by se měla používat v případech, že neexistuje přesná hranice mezi třídami, což nastává v případě reálných dat velmi často. Podle Benz et al. (2004) totiž vede použití prahových hodnot k idealizaci reálného světa a způsobuje problémy při klasifikaci.

Vzhledem k výpočetní náročnosti fuzzy klasifikace však musela být v této práci zvolena metoda rozhodovacího stromu, při které probíhá klasifikace právě na základě určování prahových hodnot a jedná se tedy o tzv. tvrdou klasifikaci. Na začátku stromu je množina všech dat, která jsou rozdělena do homogenních skupin podle toho, jestli danou podmínku splňují nebo ne. Každá z nově vzniklých skupin se může opět dělit podle dalších podmínek (Mallinis et al. 2008). Největší výhodou této klasifikace je nezávislost na rozložení dat a rychlé zpracování multidimenzionálních datových sad obsahujících mnoho různých příznaků (Ke, Quackenbush a Im 2010).

Poměrně důležité je výsledné hodnocení přesnosti klasifikace, při kterém jsou výsledky klasifikace porovnávány s referenčními daty, která jsou většinou pořízena při terénním průzkumu nebo převzata z jiných zdrojů. Existuje opět několik metod, nejčastěji však bývá používána tzv. chybová matice, případně různé korelační koeficienty (Platt a Schoennagel 2009). V této práci byla využita metoda chybové matice, která u všech tříd porovnává vztah mezi referenčními daty a výsledky klasifikace. Pro každou třídu se poté určuje přesnost z hlediska uživatele (user's accuracy) a z hlediska zpracovatele (producer's accuracy). Uživatelská přesnost definuje pravděpodobnost, s jakou objekt skutečně reprezentuje třídu, do které je zařazen. Zpracovatelská přesnost dává do poměru počet správně klasifikovaných objektů a celkový počet objektů, který byl použit pro testování dané třídy.

Ke, Quackenbush a Im (2010) však upozorňují na problémy při hodnocení přesnosti objektové klasifikace. Při klasické pixelové klasifikaci se hodnotí správnost zařazení jednotlivých pixelů, v případě objektové klasifikace však celých objektů, které ale mají různou velikost. Špatná klasifikace velkého objektu by tak logicky měla mít větší váhu než špatná klasifikace objektu malého, a do přesnosti klasifikace se tak dostává určitá míra ovlivnění (Radoux et al. 2008). Přesto bývá tato metoda pro hodnocení přesnosti objektové klasifikace využívána – např. Ozdemir et al. (2005).

Celková přesnost klasifikace je poté hodnocena pomocí Kappa koeficientu. Kappa koeficient porovnává výslednou klasifikaci s klasifikací, která by vznikla při čistě náhodném zařazování objektů do tříd. Hodnota Kappa koeficientu se pohybuje od 0 do 1 a hodnota 0,9 znamená například, že při klasifikaci bylo odstraněno 90 % chyb, které by vznikly náhodným zařazením objektů do tříd. Kappa koeficient se tak liší od všeobecného koeficientu přesnosti, který pouze porovnává počet správně zařazených objektů s celkovým počtem objektů použitým k testování a nezabývá se prvky, které leží mimo hlavní diagonálu chybové matice (Moskal a Franklin 2002, Coburn a Roberts 2004, Ozdemir et al. 2005).

## 5 VÝSLEDKY

Cílem práce bylo rozdělit lesní porosty do kategorií podle jejich hustoty a výsledky vizualizovat pomocí mapy. Nejdříve byla provedena klasifikace s využitím texturálních příznaků. Výsledek klasifikace je v příloze 3, rozhodovací strom, na základě kterého probíhalo rozdělování segmentů do jednotlivých kategorií, v příloze 4. Druhá klasifikace byla provedena pomocí texturálních příznaků a informace o počtu odrazů z dat LLS. Mapa s výsledkem této klasifikace je v příloze 5, rozhodovací strom v příloze 6. Výsledky obou klasifikací byly na závěr porovnány a zhodnoceny jejich největší rozdíly, které jsou vizualizovány pomocí mapky v příloze 7.

### 5.1 Výsledky GLCM

Pro každý segment klasifikovaného snímku byly určeny hodnoty tří zvolených měř GLCM – kontrastu, entropie a korelace. Výpočet ve všech směrech byl proveden v programu eCognition. Výsledné hodnoty pro plochy, na kterých byl proveden terénní průzkum, shrnuje tabulka 2. Tyto hodnoty byly použity pro určení prahových hodnot klasifikace, na základě kterých byly segmenty přiřazovány do jednotlivých kategorií hustoty lesního porostu.

*Tabulka 2: Výpočty textur*

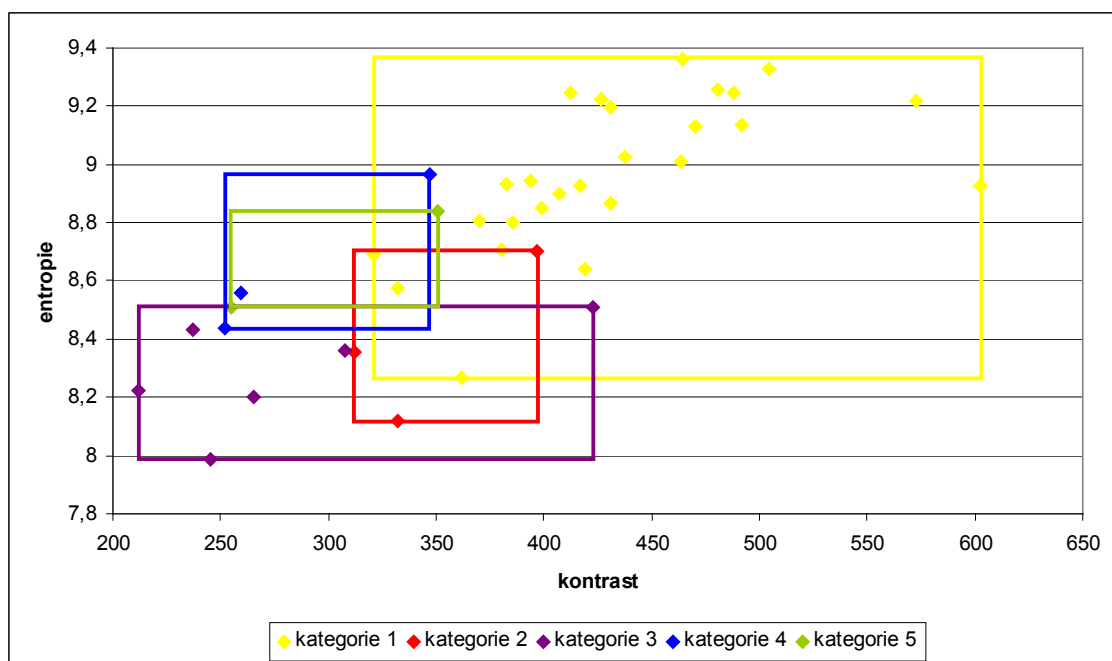
Plocha	Kateg.	Kontrast	Entropie	Korelace	Plocha	Kateg.	Kontrast	Entropie	Korelace
1	5	350,91	8,841	0,9364	16	3	265,47	8,203	0,9431
2	4	251,86	8,436	0,9371	17	1	382,87	8,931	0,9409
3	1	430,91	9,197	0,9382	18	1	320,75	8,688	0,9427
4	1	602,61	8,927	0,8939	19	2	311,92	8,354	0,9428
5	1	504,36	9,329	0,9268	20	1	332,23	8,573	0,9512
6	1	470,10	9,129	0,9444	21	1	407,11	8,902	0,9420
7	1	399,31	8,851	0,9296	22	1	394,04	8,946	0,9266
8	3	245,22	7,987	0,9536	23	1	416,64	8,928	0,9196
9	1	572,51	9,220	0,9113	24	1	463,39	9,010	0,9192
10	1	419,31	8,643	0,9318	25	1	488,14	9,244	0,9222
11	5	254,88	8,511	0,9335	26	3	237,23	8,432	0,9495
12	1	385,75	8,801	0,9393	27	1	431,26	8,867	0,9166
13	1	437,55	9,026	0,9182	28	1	380,31	8,707	0,9362
14	4	346,86	8,966	0,9440	29	2	332,28	8,119	0,9191
15	1	361,54	8,266	0,9360	30	1	464,45	9,361	0,9333

5. Výsledky

Plocha	Kateg.	Kontrast	Entropie	Korelace	Plocha	Kateg.	Kontrast	Entropie	Korelace
31	1	412,43	9,244	0,9409	36	2	397,02	8,701	0,9400
32	1	480,65	9,258	0,9305	37	3	307,40	8,359	0,9328
33	1	426,15	9,224	0,9385	38	3	422,93	8,509	0,9231
34	1	370,32	8,804	0,9429	39	4	259,39	8,559	0,9390
35	1	491,94	9,138	0,9250	40	3	211,64	8,225	0,9531

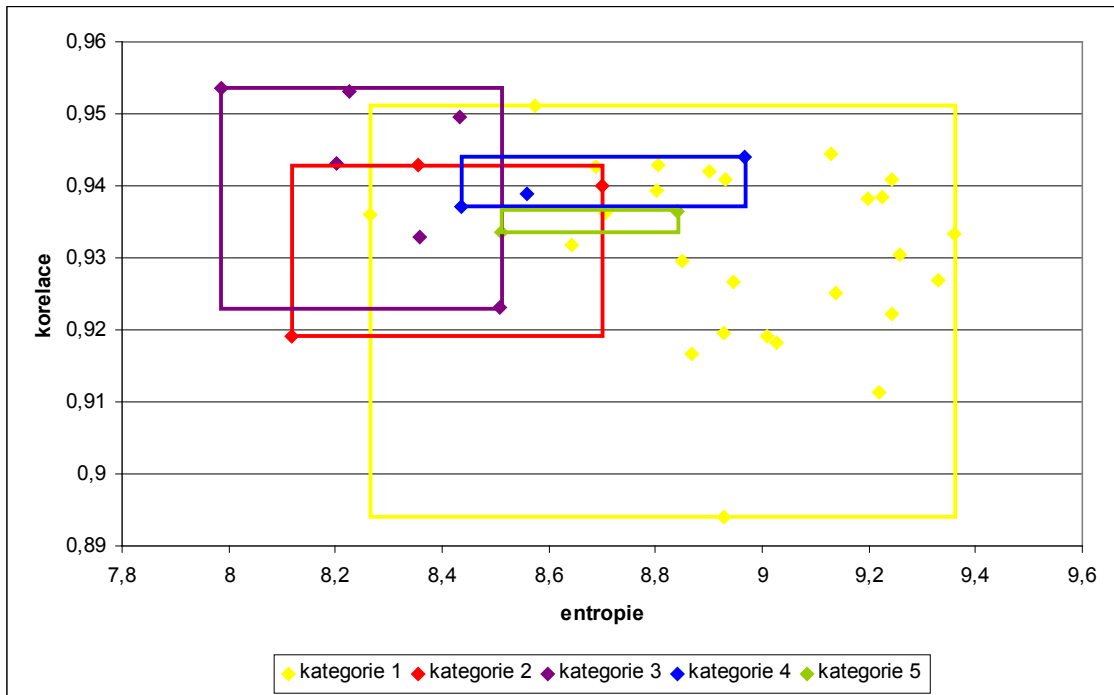
Pro větší názornost byly jednotlivé míry textury zobrazeny pomocí bodových grafů, ve kterých je možno hledat závislost hodnot textur na hustotě porostu. Protože vizualizace všech tří měř ve vícozměrném grafu by byla nepřehledná, byly grafy vytvořeny pro každou dvojici GLCM textur. Graf 1 zobrazuje vztah kontrastu a entropie, Graf 2 vztah entropie a korelace a Graf 3 kontrastu a korelace. Okolo každé třídy byl vytvořen obdélník s minimálním obsahem, který pomohl hledat hranice hodnot pro danou třídu.

**Graf 1: GLCM kontrast × entropie**




5. Výsledky

Graf 2: GLCM entropie × korelace



Graf 3: GLCM kontrast × korelace



Z grafů 1–3 je jasné, že výsledek klasifikace bude slabý vzhledem k překryvu jednotlivých tříd v příznakovém prostoru. Není tak možné stanovit přesné hranice pro každou kategorii hustoty lesního porostu. Nejmenší rozptyl hodnot má kategorie 5, reprezentující nejhustší lesy. Hodnoty textur pro tuto kategorii jsou částečně obsaženy v kategoriích 4 a 2. Kategorie 1 a 3 mají největší rozptyl hodnot a zahrnují v sobě body spadající téměř do všech tříd. Z těchto

## 5. Výsledky

důvodů bylo rozhodnuto klasifikovat třídy v následujícím pořadí: kategorie 5, kategorie 4, kategorie 2, kategorie 1, kategorie 3.

Kategorie 5 má nejmenší rozptyl hodnot a kdyby byla klasifikována až po dalších kategoriích, nezbyly by na ni téměř žádné segmenty, protože hodnoty GLCM textur této kategorie jsou z velké míry obsaženy i v ostatních třídách. Kategorie 2 a 4 se vždy alespoň částečně překrývají. Rozptyl hodnot kategorie 4 je však menší, a to především v případě GLCM korelace. Z tohoto důvodu byla kategorie 4 klasifikována jako druhá, kategorie 2 jako třetí.

Kategorie 1 a 3 mají naopak největší rozptyl hodnot a obecně se dá říci, že hodnoty jejich textur jsou opačné. Kategorie 1 se vyznačuje vysokými hodnotami kontrastu a entropie, korelace je nízká. Kategorie 3 naopak má vysokou korelaci a nízké hodnoty kontrastu a entropie. Tyto kategorie tedy byly klasifikovány až jako poslední a zahrnuly do sebe v podstatě všechny zbývající neklasifikované segmenty.

Hranice pro jednotlivé třídy byly odečteny z grafů, v průběhu klasifikace byly ale ještě upravovány, až do výsledných hodnot, které shrnuje tabulka 3.

**Tabulka 3: Prahové hodnoty pro rozhodovací strom klasifikace s využitím textur**

Kategorie	Kontrast		Entropie		Korelace	
	min	max	min	max	min	max
5	254,88	350,91	8,511	8,885	0,9335	0,9488
4	222,50	351,13	8,281	8,966	0,9205	0,9571
2	253,99	411,06	8,052	8,905	0,9298	0,9610
1	320,75	bez om.	8,266	bez om.	bez om.	0,9512
3	100	422,93	bez om.	8,996	bez om.	bez om.

Poznámka: bez om. = bez omezení

Protože program eCognition neumožňuje při přiřazování segmentů do tříd použít více jak dvě podmínky najednou, muselo být postupováno podle rozhodovacího stromu, jehož grafické znázornění je v příloze 4. Nejdříve byly do kategorie 5 zařazeny segmenty splňující kritéria kontrastu. V dalším kroku byly na tyto segmenty aplikovány prahové hodnoty entropie, a pokud klasifikované segmenty to daného intervalu nespádaly, byly z kategorie 5 přesunuty zpět do neklasifikovaných segmentů. Stejně bylo postupováno v případě prahových hodnot korelace. Do kategorie 5 tak byly zařazeny pouze segmenty, které splňovaly všechny tři podmínky (kontrast, entropii i korelaci). Na zbývající neklasifikované segmenty byly aplikovány prahové hodnoty kontrastu příslušející kategorii 4 a postup se pro zbylé kategorie opakoval.

Postup klasifikace byl tedy pro všechny třídy stejný – segmenty, které nesplňovaly všechny podmínky pro zařazení do dané třídy, byly vráceny do kategorie neklasifikovaných a byly použity pro klasifikaci následující třídy. Jedinou výjimkou byla klasifikace poslední kategorie 3. Segmenty, jejichž entropie byla vyšší než 8,997, nebyly vráceny zpět do kategorie neklasifikovaných segmentů, ale byly zařazeny do kategorie 1. Jednalo se o poslední podmínku rozhodovacího stromu a o tomto zařazení segmentů bylo rozhodnuto na základě jejich

## 5. Výsledky

vizuálního hodnocení. V kategorii neklasifikováno tak zůstalo jenom několik málo segmentů, jejichž kontrast byl nižší než 100.

### 5.2 Klasifikace na základě GLCM textur

Klasifikace s využitím GLCM textur kontrast, entropie a korelace byla provedena metodou rozhodovacího stromu v programu eCognition. Výsledek klasifikace je v příloze 3, grafické znázornění rozhodovacího stromu v příloze 4. Do kategorie 1 bylo zařazeno 585 segmentů, do kategorie 2 110 segmentů, kategorie 3 a 4 obsahovaly každá 160 segmentů a kategorie 5 získala 57 segmentů (viz Tab. 9).

Vyklasifikovány byly téměř všechny segmenty. Neklasifikované zůstaly pouze plochy, které pokrývala drobná oblačnost. Tyto segmenty se vyznačovaly velmi nízkou hodnotou kontrastu (menší než 100), mohly tedy být dobře odlišeny.

Přesnost klasifikace byla hodnocena pomocí chybové matice (viz Tabulka 6), ve které byly srovnávány výsledky klasifikace s hodnotami zapojenosti zjištěnými během terénního průzkumu. Z celkem 40 zaměřených ploch jich bylo 26 klasifikováno správně. Celková přesnost klasifikace, hodnocená pomocí kappu indexu, byla 0,45, což značí průměrnou přesnost klasifikace.

Tabulka 4: Chybová matice klasifikace s využitím textur

		Referenční data						Uživatelská přesnost
		kategorie 1	kategorie 2	kategorie 3	kategorie 4	kategorie 5	$\Sigma$	
Klasifikace	kategorie 1	19		1			20	<b>95,00</b>
	kategorie 2	5	1	1			7	<b>14,29</b>
	kategorie 3		1	2			3	<b>66,67</b>
	kategorie 4	1	1	2	2		6	<b>33,33</b>
	kategorie 5	1				1	2	<b>50,00</b>
	$\Sigma$	26	3	6	3	2	40	
Zpracovatelská přesnost		<b>73,08</b>	<b>33,33</b>	<b>33,33</b>	<b>66,67</b>	<b>100,00</b>		

Nejvyšší přesnost klasifikace vykazuje kategorie 1 zahrnující plochy s nejnižší hustotou lesního porostu. Uživatelská přesnost klasifikace této třídy dosáhla dokonce hodnoty 95 %, kdy z 20 ploch, které byly klasifikovány jako tato plocha, byla pouze jedna zařazena špatně. Zpracovatelská přesnost klasifikace kategorie 1 je 73 %, nejvíce špatně zařazených ploch však spadlo do kategorie 2, která představuje plochy s druhou nejnižší úrovní zapojenosti porostů.

Klasifikace kategorie 2 naopak dosáhla nejhorších výsledků jak v uživatelské, tak zpracovatelské přesnosti. Ze tří referenčních ploch byla pouze jedna klasifikována správně, což dává zpracovatelskou přesnost cca 33 %. Ještě horší je uživatelská přesnost s 14 %. Tento výsledek způsobilo hlavně pět špatně klasifikovaných ploch z kategorie 1.

## 5. Výsledky

Kategorie 3 dosahuje podobně špatných výsledků ve zpracovatelské přesnosti jako kategorie 2. Z šesti referenčních ploch byly dvě klasifikovány správně. Uživatelská přesnost dosahuje poměrně dobrých výsledků (66,7 %), počet vzorků v této kategorii je však nízký.

Kategorie 4 i 5, které reprezentují nejhustší lesní plochy, vykazují vyšší zpracovatelskou přesnost. Byly však klasifikovány jako první, proto kategorie 5 dosáhla 100% přesnosti. Zpracovatelská přesnost kategorie 4 je 66,67 %, protože jedna z referenčních ploch kategorie 4 byla již v klasifikaci zařazena do kategorie 5, což je ovšem hned sousední kategorie.

Uživatelská přesnost kategorií 4 a 5 je průměrná. V případě kategorie 4 dosáhla cca 33 %, ze šesti ploch byly čtyři klasifikovány špatně. Uživatelská přesnost kategorie 5 je 50 %. Dvě plochy byly klasifikovány správně, jedna měla patřit do kategorie 4 a jedna do kategorie 1, tedy do kategorie na opačném konci žebříčku hodnot zapojenosti. Hodnoty textur této plochy však splňovaly všechny podmínky pro zařazení do kategorie 5, která byla klasifikována jako první.

### 5.3 Výsledky dat LLS

Zpracovaná data LLS byla v programu eCognition použita k určení počtu odrazů v každém segmentu. Protože segmenty jsou různě velké, byl pro porovnatelnost celkový počet odrazů vydělen počtem pixelů v segmentu a určen tak počet odrazů na pixel. Výsledné hodnoty ale byly poměrně nízké, bylo proto rozhodnuto určovat počet odrazů na 100 pixelů. Výsledný podíl odrazů se tak pohyboval od hodnoty téměř žádných do přibližně 20 odrazů na 100 pixelů segmentu. Výsledky pro jednotlivé plochy terénního průzkumu shrnuje tabulka 5. Pro přehlednost byly hodnoty seřazeny podle kategorií a vzestupně.

*Tabulka 5: Výpočty odrazů dat LLS pro plochy terénního průzkumu (počet odrazů na 100 pixelů)*

Kategorie	Počet odrazů	Kategorie	Počet odrazů	Kategorie	Počet odrazů
1	1,05	1	3,36	2	5,05
1	1,36	1	3,41	2	7,37
1	1,42	1	3,90	2	7,53
1	1,55	1	3,93	3	8,59
1	1,71	1	3,98	3	9,83
1	2,07	1	4,06	3	10,09
1	2,48	1	4,18	3	10,10
1	2,56	1	4,37	3	11,55
1	2,62	1	4,58	3	11,75
1	3,05	1	4,63	4	15,49
1	3,22	1	4,64	4	16,92
1	3,24	1	4,67	4	19,24
1	3,25	1	4,96	5	15,07
				5	17,36

Z tabulky 5 je zřejmé, že údaje z dat LLS velmi dobře korespondují se zařazením plochy do kategorie zapojenosti. Plochy kategorie 1, tj. kategorie s nejnižší hustotou lesních porostů, se

## 5. Výsledky

pohybují v intervalu 1 až 5 odrazů na 100 pixelů. Plochy kategorie 2 na tyto výsledky navazují a do kategorie 2 je tak možné zařadit plochy s 5 až 8 odrazy na 100 pixelů. Do kategorie 3 spadají plochy s 8 až 12 odrazy na 100 pixelů. Mezi kategoriemi 3 a 4 je poměrně velká mezera, údaje pro kategorii 4 začínají až na hodnotě 15 odrazů na 100 pixelů. Počet odrazů už ale není úplně dobře použitelný pro oddělení kategorií s nejvyšší hustotou lesa. Počty odrazů pro kategorii 4 a 5 se totiž překrývají a pohybují se v rozmezí 15 až 20 odrazů na 100 pixelů.

Při začlenění informace o počtu odrazů do rozhodovacího stromu klasifikace nemohly být zcela převzaty prahové hodnoty z první části klasifikace pomocí textur. Při snaze o dodržení prahových hodnot jednotlivých textur i podmínky počtu odrazů zůstávalo velmi mnoho neklasifikovaných segmentů. Proto bylo rozhodnuto změnit pořadí klasifikace jednotlivých tříd a také u některých změnit prahové hodnoty. Konkrétně se jednalo o kategorie 1 a 2, které reprezentují lesní porosty s nejnižší hustotou a které jsou velmi dobře popsány počtem odrazů dat LLS. Klasifikace tak začala kategorií 1, u které nebyly použity žádné texturní příznaky a do kategorie 1 byly zařazeny všechny segmenty s počtem odrazů na 100 pixelů menším než 5. Druhá určovaná kategorie 2 byla stejně tak klasifikována pouze za použití kritéria počtu odrazů, který musel spadat do intervalu 5 až 8 odrazů na 100 pixelů.

Protože u kategorií s vyšší hustotou již informace z dat LLS nebyly tak jednoznačné, byly použity texturní příznaky s prahovými hodnotami z první části klasifikace a pořadí klasifikace jednotlivých tříd bylo také v podstatě zachováno – nejdříve kategorie 5, poté kategorie 4 a nakonec kategorie 3. K původním prahovým hodnotám byly přidány podmínky počtu odrazů, který u kategorií 4 a 5 musel být vyšší než 12 odrazů na 100 pixelů a v případě kategorie 3 se musel nacházet v intervalu 8 až 15 odrazů na 100 pixelů (viz Tab. 5).

**Tabulka 6: Prahové hodnoty pro rozhodovací strom klasifikace s využitím textur a dat LLS**

Kategorie	Kontrast		Entropie		Korelace		Odrazů na 100 px	
	min	max	min	max	min	max	min	max
1	100	bez om.	bez om.	bez om.	bez om.	bez om.	bez om.	5
2	100	bez om.	bez om.	bez om.	bez om.	bez om.	5	8
5	254,88	350,91	8,511	8,885	0,9335	0,9488	12	bez om.
4	222,50	351,13	8,281	8,966	0,9205	0,9571	12	bez om.
3	100	422,93	bez om.	8,996	bez om.	bez om.	8	15

**Poznámka:** bez om. = bez omezení

Při použití těchto prahových hodnot zůstalo 66 z celkového počtu cca 1000 segmentů neklasifikovaných. Tyto zbývající segmenty byly na základě vizuálního zkoumání rozděleny do kategorií 3 a 4. Do kategorie 3 byly zařazeny segmenty s počtem odrazů nižším než 14 odrazů na 100 segmentů. Všech 26 těchto segmentů vykazovalo poměrně vysokou hodnotu kontrastu a entropie a v předchozí klasifikaci byly zařazeny do kategorie 1. Většina z těchto ploch představovala slatě, které jsou pokryté specifickou vegetací a hodnoty textur jsou tak odlišné od běžného lesního porostu. Zbýlých 40 segmentů bylo zařazeno do kategorie 4. Neklasifikováno

tak zůstalo opět jen několik segmentů s velmi nízkou hodnotou kontrastu. Finální rozhodovací strom druhé klasifikace je graficky znázorněn v příloze 6.

Z výpočetních důvodů také nemohla být druhá část klasifikace provedena v programu eCognition, protože program nevládal určovat hodnoty textur a počet odrazů laserových dat najednou. Segmenty z programu eCognition tak byly vyexportovány do polygonové vrstvy ve formátu shapefile s hodnotami textur a podílem odrazů jako atributy. Výsledná klasifikace pak byla provedena v programu ArcGIS, kde je možno rozhodovací strom klasifikace velmi dobře napodobit výběrem podle atributů.

## 5.4 Klasifikace s využitím dat LLS

Výsledek druhé části klasifikace s využitím texturních příznaků a dat LLS je v příloze 5, grafické znázornění rozhodovacího stromu v příloze 6. Vyklasifikovány byly opět všechny segmenty kromě několika málo segmentů pokrytých oblačnostmi, ačkoli na základě dat LLS by jejich zařazení možné bylo. Pro porovnatelnost obou klasifikací však bylo rozhodnuto ponechat tyto plochy neklasifikované. Do kategorie 1 bylo tentokrát zařazeno 538 segmentů, do kategorie 2 145 segmentů, kategorie 3 si polepšila na 243 segmentů, naopak kategorie 4 klesla na 119 segmentů a do kategorie 5 připadlo pouhých 27 segmentů (viz Tab. 9).

Přesnost klasifikace byla opět hodnocena pomocí chybové matice (viz Tab. 7). Hodnoty zapojenosti zjištěné během terénního průzkumu byly porovnávány s hodnotami získanými z klasifikace. Ze 40 ploch jich tentokrát 39 bylo zařazeno správně. Přesnost klasifikace tak byla velmi vysoká, kappa index dosáhl hodnoty 0,95.

**Tabulka 7: Chybová matice klasifikace s využitím textur a dat LLS**

		Referenční data					Σ	Uživatelská přesnost
		kategorie 1	kategorie 2	kategorie 3	kategorie 4	kategorie 5		
Klasifikace	kategorie 1	26					26	100
	kategorie 2		3				3	100
	kategorie 3			6			6	100
	kategorie 4				2		2	100
	kategorie 5					1	2	66,67
	Σ	26	3	6	3	2	40	
Zpracovatelská přesnost		100	100	100	66,67	100		

Přesnost zařazení prvních tří kategorií, tedy kategorií s nižší úrovní zapojenosti, dosáhla 100% úspěšnosti jak z hlediska zpracovatelského, tak uživatelského. Jediná špatně zařazená plocha byla místo kategorie 4 zařazena do kategorie 5. V kategoriích s vysokou úrovní zapojenosti se již nedaly plně využít informace z dat LLS, protože hodnoty se zejména pro kategorie 4 a 5 překrývaly. Klasifikace tak byla založena především na informaci z GLCM textur a tato špatně klasifikovaná plocha splňovala všechny podmínky pro zařazení do

kategorie 5, která byla klasifikována jako první. Zpracovatelská přesnost kategorie 4 a uživatelská přesnost kategorie 5 tak byly sníženy na hodnotu 66,67 %.

## 5.5 Porovnání klasifikací

Zatímco klasifikace s využitím texturálních příznaků dosáhla přesnosti hodnocené pomocí kappa indexu pouze 0,45, při klasifikaci se zapojením informace o počtu odrazů z dat LLS se přesnost zvýšila až na hodnotu 0,95. Mezi oběma provedenými klasifikacemi tedy byly zjištěny rozdíly, které byly někdy i poměrně výrazné. Graficky jsou tyto rozdíly znázorněny v mapce v příloze 7, histogram výskytu jednotlivých rozdílů zachycuje Graf 4.

**Graf 4: Histogram výskytu rozdílů mezi klasifikacemi**



Rozdíl mezi klasifikacemi byl určen odečtením čísla kategorie z druhé klasifikace od čísla kategorie z klasifikace první. Kladná čísla rozdílů tedy znamenají, že v klasifikaci pomocí textur byly segmenty zařazeny do vyšší kategorie zapojenosti, než v klasifikaci provedené pomocí kombinace texturálních a laserových příznaků, a naopak. Hodnota rozdílu 1, resp.  $-1$  zase znamená, že rozdíl mezi zařazením segmentů v klasifikaci jedné oproti klasifikaci druhé byl pouze 1 kategorie.

Z celkem 1072 hodnocených segmentů nedošlo u 697 (65 %) z nich ke změně kategorie mezi klasifikacemi. 190 segmentů bylo v první klasifikaci zařazeno do vyšší kategorie zapojenosti, než v klasifikaci druhé. U 185 segmentů tomu bylo obráceně, nedá se tedy říci, že by jedna klasifikace měla oproti druhé klasifikaci tendenci hustotu podceňovat, nebo naopak přeceňovat. Počet rozdílně klasifikovaných segmentů také klesal s rostoucí vzdáleností kategorií zapojenosti. Zatímco segmentů, u kterých byl rozdíl mezi kategoriemi pouze 1, bylo 198, u rozdílu 2 počet klesl na 124, u rozdílu 3 už na 48 a pouze 5 segmentů bylo zařazeno do naprosto opačných kategorií hustoty lesních porostů. Všechny tyto segmenty byly v první klasifikaci zařazeny do kategorie 5, zatímco v klasifikaci druhé byly na základě údajů o počtu

## 5. Výsledky

odrazů z dat LLS zařazeny do kategorie 1, která byla i na základě vizuálního hodnocení snímků, resp. terénního průzkumu, označena za správnou.

Obě dvě klasifikace byly také porovnány formou chybové matice (viz Tab. 8). Z té vyplývá, že rozdíly mezi klasifikacemi se vyskytovaly nejčastěji v případě kategorií 2 a 3. Záměna kategorie 2 za kategorii 1 byla vůbec nejčastějším jevem (54krát) a ve vztahu k spíše nízkému výskytu segmentů kategorie 2 je také nejpravděpodobnější chybou. V případě kategorie 3 byly rozdílně klasifikované segmenty rovnoměrně (po cca 45) rozloženy mezi kategorie 1, 2 a 4. Výsledné přesnosti se jinak velmi podobají hodnotám z tabulky 6, která hodnotila přesnost první klasifikace.

**Tabulka 8: Porovnání klasifikací formou chybové matice**

		Klasifikace 2					Σ	Přesnost
		kategorie 1	kategorie 2	kategorie 3	kategorie 4	kategorie 5		
Klasifikace 1	kategorie 1	464	54	47	20	0	585	<b>79,32</b>
	kategorie 2	23	31	44	12	0	110	<b>28,18</b>
	kategorie 3	32	23	97	8	0	160	<b>60,63</b>
	kategorie 4	14	23	45	78	0	160	<b>48,75</b>
	kategorie 5	5	14	10	1	27	57	<b>47,37</b>
	Σ	538	145	243	119	27	1072	
Přesnost		<b>86,25</b>	<b>21,38</b>	<b>39,92</b>	<b>65,55</b>	<b>100,00</b>		

Zajímavým číslem je kappa index této „chybové matice“, ve které jsou jako referenční data uvažovány hodnoty druhé klasifikace. Dosáhl totiž hodnoty 0,47, tedy téměř stejné, jako kappa index přesnosti klasifikace pomocí GLCM textur. Na základě tohoto faktu je možné se domnívat, že klasifikace s využitím dat LLS skutečně odpovídá reálnému stavu hustoty lesních porostů a že terénní průzkum byl proveden na reprezentativních plochách.

V obou klasifikacích proběhlo také zařazení segmentů, které nereprezentují čistě lesní plochy. Jedná se především o louky a další travní porosty na Březníku a v Luzenském údolí, okolo potoka Rokytky nebo o obec Modrava. Louky na Březníku, okolo Luzenského potoka a potoka Rokytky byly při klasifikaci pomocí texturálních příznaků až na několik výjimek úspěšně zařazeny do kategorie 1, tj. hustota lesa 0 až 20 %. Hůře dopadla oblast Modravy. Segmenty zahrnující obec a přilehlé travní porosty byly označeny za kategorii 3, ačkoli stromů se zde nachází minimum. Při druhé klasifikaci se zapojením dat LLS již byly tyto segmenty správně zařazeny do kategorie 1 i díky faktu, že při filtraci dat LLS byly odstraněny odrazy od budov. Pomocí dat LLS byly také správně zařazeny všechny segmenty představující již zmiňované luční porosty v ostatních částech zájmového území.

Ačkoli mezi klasifikacemi byly zaznamenány místy i poměrně výrazné rozdíly a přesnost klasifikace s využitím kombinace texturálních a laserových příznaků byla mnohem vyšší, podíl ploch, které byly zařazeny do jednotlivých kategorií hustoty lesních porostů je podobný. V obou případech bylo přes polovinu ploch zařazeno do nejnižší kategorie, kam spadají plochy se zapojeností nižší než 20 %. Ostatní plochy vykazují mnohem nižší procentuální zastoupení

## 5. Výsledky

v počtu segmentů. Podobné rozložení vyplynulo i z výsledků terénního průzkumu, kde byla více než polovina hodnocených ploch zařazena do kategorie 1. Vzhledem k různé velikosti jednotlivých segmentů tento výsledek neříká nic o skutečném rozložení jednotlivých kategorií hustoty lesních porostů v zájmové oblasti.

**Tab. 9: Podíl kategorií hustoty lesních porostů na počtu segmentů**

Kategorie	Textury		Textury + LiDAR		Terénní průzkum	
	počet	%	počet	%	počet	%
1	585	54,57	538	50,19	26	65
2	110	10,26	145	13,53	3	7,5
3	160	14,93	243	22,67	6	15
4	160	14,93	119	11,10	3	7,5
5	57	5,32	27	2,52	2	5

### 5.6 Hustota lesních porostů v zájmové oblasti

Zájmová oblast se na základě hustoty lesních porostů dá rozdělit na dvě poloviny. Zatímco velmi řídké lesní porosty se vyskytují v jižní polovině zájmového území, v severní části je jejich zapojenost výrazně vyšší (viz přílohy 3 a 5). Toto rozložení souvisí s historickým vývojem oblasti, kdy se kůrovec rozšířil z německé strany Šumavy a napadl nejdříve oblast v okolí Březníku. Protože tato oblast byla v roce 1995 vyhlášena bezzásahovou zónou, kůrovec se začal šířit dále do českého vnitrozemí a způsoboval usychání dalších stromů. Při terénním průzkumu v roce 2012 byla zaznamenána řada dalších rozsáhlých ploch napadených stromů, které se přibližují k obci Modrava na severu území.

Protože mezi oběma provedenými klasifikacemi byly zaznamenány rozdíly v zařazení segmentů do jednotlivých kategorií lesa, liší se i celková rozloha ploch jednotlivých kategorií (viz Tab. 10). V případě kategorie 1 nedošlo k výrazným rozdílům a v obou klasifikacích byla do této kategorie zařazena třetina území. Kategorie 2 zabírala podle první klasifikace mnohem více území (13,26 %) především kvůli plochám v severní části území. Na základě informace z dat LLS byly tyto segmenty v druhé klasifikaci zařazeny do kategorií 3 nebo 4, rozloha těchto ploch tak klesla na 7,51 % zájmového území. V souladu s těmito změnami vzrostla rozloha kategorie 3 z 15,71 % podle první klasifikace na 26,95 % podle klasifikace druhé. Porosty s hustotou 40,1 – 60 % jsou tak druhou plošně nejvíce zastoupenou kategorií lesa. Z kategorie 4 v první klasifikaci bylo nejvíce ploch přesunuto do kategorie 3 v druhé klasifikaci, ale zároveň tato kategorie obdržela rozsáhlé plochy z kategorie 2. Podíl na rozloze zájmového území se tak v obou klasifikacích příliš neliší a činí asi čtvrtinu území. Patří sem především ještě stále zdravé lesy na severu území. Nej hustší lesní porosty z kategorie 5 jsou v obou klasifikacích nejméně zastoupenou třídou, a to jak počtem segmentů, tak jejich celkovou rozlohou. Podíl na rozloze se v druhé klasifikaci snížil v souladu s tím, že do této klasifikace nebyly zařazeny žádné nové plochy, naopak na základě informace o počtu odrazů byla téměř polovina segmentů z této třídy odstraněna.

## 5. Výsledky

V roce 2010 tak na základě provedených klasifikací pokrýval třetinu území velmi řídký až žádný les zabírající především jižní polovinu území. Asi 7 % území bylo zařazeno do kategorie 2, která zaujímá menší roztroušené plochy především na okrajích kategorie 1. Lesní porosty kategorie 3 jsou rozmístěny po celém území především díky tomu, že do této kategorie spadají porosty slatí a rašelinišť, které kůrovci velmi dobře odolávají. Husté lesy z kategorie 4 se nacházejí především v severní části území, občas ale tvoří i osamocené ostrůvky v území napadeném kůrovcem. Jedná se především o mladé lesy, které jsou schopné se kůrovci ubránit. Kategorie 5 zaujímá několik větších ploch přibližně v polovině území, její rozlišení od kategorie 4 je však spíše nejisté.

**Tab. 10: Rozloha kategorií hustoty lesních porostů v zájmové oblasti**

Kategorie	Textury		Textury + LiDAR	
	rozloha	%	rozloha	%
1	1759,32	33,24	1751,79	33,09
2	701,91	13,26	397,59	7,51
3	831,37	15,71	1426,98	26,95
4	1469,45	27,76	1335,46	25,22
5	531,25	10,04	382,47	7,22

## 6 DISKUZE

Lesní porosty na Šumavě v oblasti Březníku a Modravských slatí byly rozděleny do kategorií podle jejich hustoty. Vzhledem k tomu, že se jedná o lesy silně poničené kůrovcovou kalamitou, bylo rozhodnuto hustotu porostů hodnotit jako zapojenost, tedy jako vzájemný dotyk a prolínání větví stromů. Kromě zdravých stromů se totiž v území vyskytují také usychající stromy napadené kůrovcem. Některé mají ještě jehličí, jiné už jenom holé větve, z některých stromů zbyly pouze kmeny. Kromě vzrostlých stromů se zde nachází také řada ploch, na kterých dochází k pozvolné obnově lesa, a jsou tak pokryty nižšími mladými stromky (viz Obr. 8).



**Obr. 8: Obnova lesa ve starých kůrovcových oblastech**

Jiné metody určování hustoty porostů, jako je například počet stromů na určité ploše nebo velikost jejich korun, tak nejsou pro toto území vhodné. V případě určování počtu stromů by bylo nutné definovat, co je možné považovat za strom. Hodnotit by tak bylo třeba nejrůznější kritéria včetně výšky stromu a jeho zdravotního stavu. Stejně tak je obtížné stanovit velikost bazální plochy koruny stromu bez jehličí. Zapojenost lesního porostu bývá používána

především pro hodnocení vhodnosti prostředí pro výskyt různých druhů zvířat a rostlin nebo pro určování úrovně zastínění lesního porostu. I uschlé stromy tak mohou mít na tyto charakteristiky vliv.

Výsledky klasifikace mohou být ovlivněny řadou faktorů. Určitou roli sehrálo již úvodní terénní měření a jeho vyhodnocení. Velmi důležitá byla segmentace snímku, která sloužila jako základ pro klasifikace. Vliv na výsledky mají také vybrané míry GLCM textur, použitá data LLS včetně způsobu jejich zpracování a metoda klasifikace segmentů. V neposlední řadě přesnost klasifikace ovlivnily také samotné snímky WorldView, které byly pro zpracování diplomové práce použity.

## 6.1 Terénní průzkum a jeho vyhodnocení

Určení zapojenosti lesního porostu v terénu je poměrně složitou záležitostí. Použitá metoda hemisférických fotografií sice nepatří k těm nejjednodušším přístupům, jedná se však o běžně využívanou metodu a její výsledky mohou být i velice přesné. Při terénním průzkumu, který byl proveden v rámci této diplomové práce, bohužel nepanovaly úplně ideální povětrnostní podmínky. Následné vyhodnocování některých snímků tak bylo komplikované především kvůli nedostatečnému kontrastu mezi vegetací a oblohou, kterou pokrývaly tmavé mraky. Pro větší přesnost bylo snímků z jedné zájmové plochy pořízeno více a při vyhodnocování bylo experimentováno s různými prahovými hodnotami. Pro účely klasifikace tak bylo rozhodnuto hodnotit zapojenost lesních porostů v intervalech po 20 %, což je přesnost, kterou vyhodnocované snímky pohodlně splňovaly. Ještě širší intervaly pro hodnocení hustoty lesa použili například Platt a Schoennagel (2009), kteří les rozdělili do čtyř tříd při využití intervalu 25 %. Menší intervaly po 10 % použili při určení zapojenosti lesa pomocí hemisférických fotografií například Joshi et al. (2006).

Terénní průzkum byl komplikován i charakterem zájmového území. Oblast kompletně spadá do NP Šumava a kvůli ochraně ohrožených živočichů se zde nachází řada nepřístupných 1. zón. Z velké části je území také pokryto rašeliništi a slatěmi (viz. mapa v příloze 2), terénní průzkum tak musel být proveden pouze v blízkosti cest. Nadmořská výška zájmového území zase omezila výběr vhodného termínu pro snímkování. Prvotním záměrem bylo provést průzkum ještě před začátkem vegetačního období v souladu s termínem pořízení snímku WorldView i dat LLS. Bohužel ještě koncem dubna pokrývala zájmové území silná vrstva sněhu. Větší část terénního průzkumu tak byla provedena až v červnu. V případě jehličnatých lesů naštěstí roční doba nehraje v zapojenosti porostů tak výraznou roli, jako by tomu bylo v případě porostů smíšených nebo listnatých.

Místa pro provedení terénního průzkumu byla vybrána na základě vizuálního hodnocení snímku, některé plochy však byly odstraněny nebo naopak přidány podle reálného stavu v terénu. Pořizovat fotografie v místech polomů nemá smysl. Bohužel je v terénu poměrně obtížné odhadnout výslednou hodnotu zapojenosti, tj. do které kategorie bude asi plocha

zařazena. Rozdíl je těžko určitelný například v případě mladých porostů, které mohou spadat do kategorie 1 nebo 2. Stejně tak je v terénu téměř nemožné rozlišit mezi kategoriemi 4 a 5. Výsledkem je velmi vysoký počet vzorků pro kategorii 1, která byla na snímku WorldView vizuálně nejrozmanitější. Kategorie 4 a 5 naopak působily homogenně a potřeba pořídit větší množství snímků na těchto plochách tak nebyla velká.

Na základě tabulky 9 je počet vzorků pořízený pro jednotlivé plochy přibližně stejný, jako je celkové zastoupení těchto ploch ve výsledcích klasifikace. Poměrně obtížné je se při terénním průzkumu trefit do nejméně zastoupených ploch 2 a 5, k tomu by bylo pravděpodobně třeba znát již alespoň předběžné výsledky klasifikace. Že je velmi obtížné v terénu nalézt lesní porosty s hustotou vyšší než 80 % potvrzují také výsledky terénních průzkumů provedených Lévesque a Kingem (1999) nebo Franklinem et al. (2000), kteří na svých vzorových plochách ve většině případů naměřili hustotu v rozmezí 40 – 60 %.

## 6.2 Segmentace

Segmentace byla provedena pomocí metody zvané multiresolution segmentation v programu eCognition. Tato metoda patří k sofistikovanějším a k objektové klasifikaci bývá využívána v naprosté většině případů. K různým klasifikacím ji použili například Ozdemir et al. (2005), Mallinis et al. (2008), Ozdemir et al. (2008), Platt a Schoennagel (2009) nebo Ke, Quackenbush a Im (2010).

Jako nejvhodnější pro segmentaci byla z důvodů uvedených v kapitole 4.1 vybrána kombinace parametrů barva 0,3, tvar 0,7, kompaktnost 0,5 a hladkost 0,5. Poměr parametrů barva/tvar, který musí dát dohromady hodnotu 1, je ale opačný, než ve většině použité literatury (viz Tab. 11). Větší důraz bývá totiž kladen na parametr barva. Podobné problematice, tedy hodnocení hustoty lesa, se věnovali například Platt a Schoennagel (2009).


**Tabulka 11: Použité kombinace parametrů při multiresolution segmentation**

Autoři	Barva	Tvar	Kompaktnost	Hladkost
Mallinis et al. (2008)	1	0	0	0
Ozdemir et al. (2008)	0,8	0,2	0,5	0,5
Platt, Schoennagel (2009)	0,8	0,2	0,5	0,5
Ke, Quackenbush, Im (2010)	0,9	0,1	0,5	0,5
použito v této práci	0,3	0,7	0,5	0,5

Hodnota měřítkového parametru 900 se již s použitou literaturou shoduje více. Platt a Schoennagel (2009) použili při segmentaci lesa na leteckých snímcích s velikostí pixelu 1 m měřítkový parametr 1000. Ke, Quackenbush a Im (2010) sice jako nejvhodnější určili měřítkový parametr 250, použili však snímky QuickBird s prostorovým rozlišením 2,44 m. Snímky QuickBird použili také Mallinis et al. (2008), kteří les rozdělili do dvou kategorií hustoty s využitím měřítkového parametru 400.

Při segmentaci vznikly relativně velké objekty, které sice nezachytí jednotlivé stromy, ale dobře se hodí k popisu lesa na úrovni porostů. Velké objekty také odpovídají velkým vyhledávacím oknům pro výpočet textury, které podle Rodrigueze-Galiana et al. (2012) lépe reprezentují spíše homogenní vzhled hustých jehličnatých lesů. Výsledná segmentace, která byla provedena na základě pouze spektrálních příznaků snímku WorldView, však není úplně ideální. V některých místech došlo k promíchání různých typů lesa (viz Obr. 9). Na některých ze zmíněných ploch byl proveden i terénní průzkum, po bližším prozkoumání snímku WorldView a aktuálních ortofot musely být tyto plochy z hodnocení vyřazeny.

Někteří autoři, např. Ke, Quackenbush a Im (2010), použili při segmentaci také informace z dat LLS. V jejich případě byly použity rastrové vrstvy reprezentující digitální model terénu, výšky a hodnoty intenzity, které byly z dat LLS odvozeny. Při hodnocení výsledků dospěli k závěru, že vrstvy odvozené z dat LLS odlišily jehličnaté a listnaté lesy, které měly podobné spektrální vlastnosti, nebo druhy stromů se specifickými výškovými vlastnostmi. V této práci by segmentace s využitím informace o výšce stromů získané z dat LLS mohla být přesnější například v místech, ve kterých došlo k prolnutí lesa se slatěmi (viz Obr. 9), ačkoli jsou oba dva typy ploch pokryty výškově rozdílnou vegetací.



*Obr. 9: Příklad špatně vytvořených segmentů – na obrázku vlevo došlo k promíchání lesa a slatí, na obrázku vpravo různě hustého lesa*

### 6.3 Textury

Lesní porosty na Šumavě byly hodnoceny na základě panchromatického snímku z družice WorldView pořízeného 27. 10. 2010. Vzhledem k tomu, že hustota lesních porostů byla určována pomocí textur, nízké spektrální rozlišení snímku nebylo překážkou. Naopak výhodou bylo vysoké prostorové rozlišení, které je možné právě díky širokému spektrálnímu pásmu zahrnujícímu celé viditelné spektrum. Velikost jednotlivých pixelů snímku tak byla 0,5 m, což umožňuje rozlišit jednotlivé koruny stromů a hodnotit tak texturu lesních porostů v dostatečné podrobnosti. Navíc je to prostorové rozlišení, které Lévesque a King (2003), kteří také zkoumali

zapojenost lesních porostů s pomocí textur, označili za nejvhodnější. K podobnému závěru došli také Moskal a Franklin (2002), podle nichž je vztah mezi lesní strukturou a texturou snímků silnější, pokud je velikost pixelu těchto snímků 1 m nebo méně.

Texturu snímků lze hodnotit různými způsoby, nejčastěji používanými jsou metody statistické, především GLCM a semivariance, které pro zpřesnění různých klasifikací lesních porostů využila řada autorů. Carr a Pelon de Miranda (1998) však označili GLCM v případě použití optických dat za metodu nejvhodnější. Pro svou relativní jednoduchost a podporu programem eCognition byla tato metoda použita také v této práci. Při výpočtu textur však nehrálo žádnou roli velmi vysoké 16bitové radiometrické rozlišení snímku. V programu eCognition jsou totiž při výpočtu GLCM data přepočítávána na 8 bitů. Každá GLCM tak má 256 řádků a 256 sloupců. Z nutnosti výpočtu této matice pro každý segment zájmového území plynou i vysoké nároky na používaný hardware.

Na základě rešerše literatury byly vybrány nejčastěji používané míry GLCM a podle informací o jejich nezávislosti bylo rozhodnuto použít kontrast, entropii a korelaci. Očekávalo se tedy, že každá z nich ponese jinou část informace a umožní rozlišení jednotlivých tříd. V programu eCognition byla hodnota uvedených textur pro každý segment vypočtena ve čtyřech hlavních směrech, což je metoda používaná i ve většině dalších výzkumů. Sice se tak výrazně zvyšují výpočetní nároky na software, zároveň je ale zajištěna nezávislost na rozložení hodnot jednotlivých pixelů, které je v případě přírodního krajinného pokryvu spíše náhodné (Narasimha Rao et al. 2002).

Na základě hodnot v místech, ve kterých byl proveden terénní průzkum, bylo zjištěno, že les s velmi nízkou hustotou porostů (0 – 20 %, tj. kategorie 1) se vyznačuje vyšší hodnotou kontrastu a entropie a nízkou hodnotou korelace, zatímco u hustého lesa (60,1 – 100 %, tj. kategorie 4 a 5) byla korelace spíše vysoká, kontrast nízký a hodnoty entropie průměrné. Poněkud komplikované bylo zařazení kategorie 2, protože hodnoty všech GLCM měř byly průměrné a rozptyl hodnot navíc poměrně velký. Kategorie 3 s průměrnou hustotou lesa se obecně vyznačovala nízkými hodnotami kontrastu a entropie, zatímco korelace byla vysoká. S využitím textur lze tedy velmi dobře odlišit od ostatních především kategorii s porosty s nejnižší zapojeností. Uživatelská přesnost této klasifikace byla dokonce 95 %, zpracovatelská přesnost sice jen 73 %, ale k největší záměně došlo s kategorií 2, která zahrnuje porosty s druhou nejnižší hustotou. V případě potřeby odlišení pouze velmi řídkých lesů by mohla představená metoda poskytovat velmi dobré výsledky.

Otázkou však je, jaký vliv na hodnoty textur měl sníh, který pokrýval hlavně jižní polovinu snímku, a patrný byl především na plochách s velmi nízkou hustotou lesa. Pravděpodobně mohl způsobit vysoký kontrast těchto ploch. Vysoký kontrast (> 600) však vykazaly také travnaté plochy podél potoka Rokyta v severozápadní části snímku, kde sníh nebyl žádný. Velmi vysokými hodnotami kontrastu a entropie se však kromě ploch s nízkou hustotou lesa vyznačovaly také některé segmenty, které byly v druhé části klasifikace zařazeny do kategorií s vyšší zapojeností lesa (např. do kategorie 4) a které bílých pixelů obsahovaly velmi málo nebo

vůbec žádné. Vysoký kontrast, entropie a nízká korelace byla charakteristické i pro některé plochy, které odpovídaly slatím pokrytým homogenně působící vegetací. Ty byly na základě odrazů z laserových dat zařazeny do kategorie 2 nebo 3.

Hodně odlišné byly výsledky pro severovýchodní část snímku, kam zasahovala obec Modrava. Na základě laserových dat byly tyto segmenty zařazeny do kategorie 1, texturami ale splňovaly parametry pro zařazení do kategorie 3. Tyto plochy měly totiž extrémně nízké hodnoty kontrastu (často méně než 200) a naopak velmi vysoké hodnoty korelace. Pokud by tedy při klasifikaci byla vytvořena kategorie zastavěných ploch, bylo by pravděpodobně možné tyto plochy odlišit.

## 6.4 Data leteckého laserového skenování

Použitá data LLS mají malou hustotu bodů, průměrná vzdálenost mezi jednotlivými odrazy na rovinatém terénu je cca 1,5 m. Pouze v nejhustších lesních porostech se tak hustota odrazů blíží hodnotě 1 bod/m<sup>2</sup>. Ačkoli jsou tato data nevhodná pro určování parametrů pro jednotlivé stromy, pro výzkum na úrovni porostů jsou tato data dostatečná. Například Ke, Quackenbush a Im (2010) použili pro klasifikaci druhů stromů data LLS s hustotou 0,16 bodu/m<sup>2</sup> (vzdálenost mezi jednotlivými odrazy 3 m), a zvýšili tak přesnost klasifikace i segmentace multispektrálních snímků QuickBird.

Přidání dat LLS do klasifikace výrazně zvýšilo její přesnost. Zvláště u ploch s nízkou zapojeností porostů (do 60 %) jsou data LLS vhodná k použití i sama o sobě. U hustších porostů se jejich vypovídací schopnost snižuje. Kategorie 4 a 5 už pomocí dat LLS nejsou oddělitelné. Důvodem může být, že příliš husté porosty nepropouští laserové pulsy a počet odrazů se tak snižuje. V důsledku tak mohou ty nejhustší porosty vykazovat méně odrazů než porosty řidší, ve kterých dojde k odrazům i od nižších vrstev vegetace. K podobnému závěru došli např. Richardson a Moskal (2011), kteří tvrdí, že průchod laserových pulzů omezuje především nižší hustá vegetace a skutečná hustota porostů je tak podceňována.

Potvrzuje se také závěr Korhonen et al. (2011), kteří uvádějí, že LiDAR s malou hustotou bodů se nehodí pro hodnocení uzavřenosti vegetace, protože nezaznamená mezery v korunách stromů. To je obzvláště patrné v případě hustších lesů a může to způsobit rozdíly v určení výsledné zapojenosti mezi počtem odrazů a použitím hemisférické fotografie, která mezery uvnitř koruny zachytí.

## 6.5 Metody klasifikace

Objektová klasifikace měla být stejně jako segmentace provedena kompletně v programu eCognition. Z výpočetních důvodů však musela být druhá klasifikace s využitím textur i dat LLS provedena v programu ArcGIS, což ale na získané výsledky nemá žádný vliv, především kvůli skutečnosti, že metodu rozhodovacího stromu lze snadno provést i v tomto programu.

Při výpočtu texturních parametrů byly zjištěny také rozdíly mezi dvěma používanými verzemi programu eCognition. První klasifikace pomocí textur byla provedena ve verzi 8. Druhá klasifikace s využitím dat LLS musela být provedena ve verzi 8.7, protože teprve od této verze program podporuje data ve formátu *las*. Při výpočtu textur však vyšlo najevo, že hodnoty pro segmenty na okrajích zájmového území se v jednotlivých verzích programu liší. Jelikož byla druhá klasifikace zpracovávána v programu ArcGIS, nezpůsobil tento rozdíl žádné problémy ve vyhodnocování segmentů, protože hodnoty textur byly z verze 8 vyexportovány jako atributy jednotlivých objektů a v programu ArcGIS byly zkombinovány do jedné vrstvy s počtem odrazů dat LLS získaným z verze 8.7.

Segmenty byly do jednotlivých kategorií klasifikovány metodou rozhodovacího stromu, která musela být využita z výpočetních důvodů. Vzhledem k spojitému charakteru hodnot zapojenosti by pravděpodobně lepší výsledky měla poskytovat metoda fuzzy klasifikace, která umožní vyjádřit pravděpodobnost zařazení objektu do jednotlivých tříd. Výpočet textur je však pro výpočetní techniku poměrně náročný, hodnocení s využitím těchto metod tedy při použití družicových snímků velmi vysokého prostorového rozlišení není vhodné pro rozsáhlá území.

## 6.6 Výsledky klasifikace

V této práci byly provedeny dvě klasifikace. Jedna proběhla s využitím pouze texturních příznaků panchromatických snímků WorldView, druhá klasifikace zkombinovala texturní příznaky a informace z dat LLS. Výsledky obou klasifikací byly prostřednictvím chybové matice a kappa koeficientu srovnány s výsledky terénního průzkumu a porovnány také mezi sebou. Vzhledem k použité metodě rozhodovacího stromu není příliš problematické použití údajů z terénního průzkumu jak pro určení prahových hodnot, tak pro hodnocení přesnosti klasifikace. Při stanovování prahových hodnot byly výsledky terénního průzkumu použity pouze pro rámcovou představu o hodnotách textur, resp. počtu odrazů jednotlivých tříd. Prahové hodnoty byly během klasifikace iterativně upravovány a k výsledkům terénního průzkumu již nebylo přihlíženo.

Výsledky jsou silně ovlivněny především pořadím, ve kterém probíhala klasifikace jednotlivých tříd. Změna pořadí v rozhodovacím stromu by způsobila rozdílné zařazení mnoha segmentů a v některých případech by se klasifikace stala nepoužitelnou. Z tohoto hlediska je použitá metoda značně subjektivní a nedá se bez hlubšího prozkoumání vstupních dat použít i v jiných výzkumech. Řešením by opět mohlo být využití fuzzy klasifikace, ve které na pořadí tříd při klasifikaci nezáleží.

Konečná přesnost klasifikace s využitím hodnot GLCM textur kontrast, entropie a korelace byla průměrná, kappa koeficient dosáhl hodnoty 0,45. Výsledek byl očekáván vzhledem k překryvu jednotlivých tříd v příznakovém prostoru. Výsledek klasifikace bez použití dalších datových zdrojů by se mohl zvýšit výběrem jiných texturních měr. Kontrast, entropie a korelace však byly vybrány na základě jejich častého používání v různých výzkumech a také na základě

## *6. Diskuze*

informací o jejich nekorelovanosti. Kromě texturálních příznaků je možné do klasifikace přidat také samotné spektrálních příznaky, které se v různých výzkumech také často vyskytují a v jejich kombinaci s texturálními příznaky bývá dosahováno nejvyšší přesnosti klasifikace. Obrazová data ale bývají většinou multispektrální s třemi až čtyřmi spektrálními pásmy. Použitá panchromatická data se příliš nehodí k rozlišení jednotlivých typů lesa, případně jejich stavu, na základě spektrální informace. Pravděpodobně by ale bylo možné odlišit lesní porosty od ostatních ploch, které v této klasifikaci byly pro velmi nízký výskyt v podstatě zanedbány.

## 7 ZÁVĚR

Výsledky práce prokázaly, že s využitím textur panchromatických snímků velmi vysokého prostorového rozlišení lze určit hustotu lesních porostů. Přesnost klasifikace na základě pouze těchto příznaků sice není ideální, přesto se potvrdil závěr řady dalších autorů, že textury jsou využitelné pro určování nejrůznějších parametrů lesa. Slabý výsledek klasifikace způsobil především překryv jednotlivých tříd v příznakovém prostoru, který komplikoval jejich odlišení. Dobře klasifikovatelná byla na základě textur pouze kategorie obsahující porosty s hustotou 0 až 20 %. Jako možnost řešení se nabízí přidání dalších příznaků, buď jiných texturálních měr, nebo i příznaků spektrálních. Velký potenciál se v tomto ohledu skrývá v metodě objektové klasifikace, která kromě vlastních hodnot jednotlivých pixelů umožňuje využít i řadu prostorových vztahů mezi třídami.

Prokázána byla i schopnost dat LLS poskytovat přímý přístup ke strukturním parametrům vegetace. V této práci však byla použita data s malou hustotou bodů určená primárně pro topografické účely. Sama o sobě se tedy hodí pro hodnocení především řídkého porostu, v případě silně zapojených porostů se jejich vypovídací schopnost snižuje, protože nejsou schopna zaznamenat malé mezery v korunách stromů. Při kombinaci dat LLS a textur však bylo dosaženo velmi vysoké přesnosti klasifikace, protože textury pomohly odlišit jednotlivé kategorie hustých porostů.

Vliv na přesnost klasifikace měla pravděpodobně také segmentace snímku WorldView. V některých částech zájmového území nebyla zcela ideální a došlo ke smíchání někdy i zcela odlišných typů vegetace. Výsledek by mohlo zlepšit začlenění ještě dalších datových zdrojů do procesu segmentace, v tomto případě například informace o výšce porostů z dat LLS.

Vzhledem k výpočetní náročnosti výzkumu, který je způsoben jak výpočtem GLCM textur, tak velmi vysokým prostorovým i radiometrickým rozlišením snímku, musela být klasifikace provedena metodou rozhodovacího stromu a stanovením prahových hodnot pro jednotlivé kategorie lesa. Zapojenost lesních porostů je však veličina spojitá, tudíž by se pro její hodnocení měla lépe hodit metoda fuzzy klasifikace, která by vyjádřila pravděpodobnost zařazení segmentů do jednotlivých tříd. Stejně tak by fuzzy klasifikace vyřešila problém s pořadím klasifikace jednotlivých tříd v rozhodovacím stromu.

Představená metoda je použitelná pouze pro malá zájmová území pokrytá jehličnatými lesy. Její využití v jiných typech lesa, ať už listnatých nebo smíšených, by mělo být předmětem

## *7. Závěr*

dalšího výzkumu. V praxi se metoda může hodit pro monitoring lesních porostů vzhledem k jejich náchylnosti k polomům nebo lesním požárům, hodnocení podmínek pro výskyt rostlin a živočichů i pro sledování obnovy lesa po hmyzích nebo větrných kalamitách, včetně sledování rozdílů mezi porosty ponechanými přirozené obnově a uměle osázenými plochami.

Úskalí této metody spočívá v potřebě kombinování více datových zdrojů, které si především časově musí odpovídat. Pro požadovaný okamžik tak nemusí být k dispozici oba typy dat zároveň a to zejména v případě dat LLS, která jsou zatím pro území Česka k dispozici pouze pro jeden časový horizont a v případě produktu DMR 4G pouze pro dvě třetiny území.

## POUŽITÉ ZDROJE A LITERATURA

- BAATZ, M., SCHÄPE, A. (2000): Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. In: Strobl, J., Blaschke, T., Griesebner, G. (Editoři), *Angewandte Geographische Informations-Verarbeitung XII*. Wichmann Verlag, Karlsruhe, s. 12–23. Dostupný z WWW: <[http://www.ecognition.cc/download/baatz\\_schaepe.pdf](http://www.ecognition.cc/download/baatz_schaepe.pdf)>.
- BALAGUER, A., et al. (2010): Definition of a comprehensive set of texture semivariogram features and their evaluation for object-oriented image classification. *Computers & Geosciences*. 2010, roč. 36, s. 231-240.
- BENZ, U. et al. (2004): Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry & Remote Sensing*. 2004, roč. 58, s. 239-258.
- BHARATI, M. H., LIU, J. J., MacGREGOR, J. F. (2004): Image texture analysis: methods and comparisons. *Chemometrics and Intelligent Laboratory Systems*. 2004, roč. 72, s. 57-71.
- CARR, J.R., PELLON DE MIRANDA, F. (1998). The semivariogram in comparison to the co-occurrence matrix for classification of image texture. *IEEE Transactions on Geoscience and Remote Sensing*. 1998, roč. 36, č. 6, s. 1945-52.
- COBURN, C. A., ROBERTS, A., C., B. (2004): A multiscale texture analysis procedure for improved forest stand classification. *International Journal of Remote Sensing*. 2004, roč. 25, č. 20, s. 4287-4308.
- DONOGHUE, D. N. M., et al. (2007): Remote sensing of species mixtures in conifer plantations using LiDAR height and intensity data. *Remote Sensing of Environment*. 2007, roč. 110, s. 509-522.
- eCognition Developer 8.7: Reference Book*. München, Germany: Trimble Germany GmbH, 2011, 438 s.
- FRANKLIN, S. E. et al. (2000): Incorporating texture into classification of forest species composition from airborne multispectral images. *International Journal of Remote Sensing*. 2000, roč. 21, č. 1, s. 61-79.

- FRANKLIN, S. E., MAUDIE, A. J., LAVIGNE, M. B. (2001): Using Spatial Co-Occurrence Texture to Increase Forest Structure and Species Composition Classification Accuracy. *Photogrammetric Engineering & Remote Sensing*. 2001, roč. 67, č. 7, s. 849-855.
- FRAZER, G. W., et al. (2001): A comparison of digital and film fisheye photography for analysis of forest canopy structure and gap light transmission. *Agricultural and Forest Meteorology*. 2001, roč. 109, s. 249-263.
- GLCM Texture Tutorial. HALL-BEYER, M. *GLCM Texture Tutorial* [online]. 2.10. c2007, 21. 2. 2007 [cit. 2012-03-14]. Dostupné z: <http://www.fp.ucalgary.ca/mhallbey/tutorial.htm>
- HAIŠ, M. (2009): Využití dálkového průzkumu země pro monitoring lesů na Šumavě. *Životní prostředí*. 2009, roč. 43, č. 4, s. 216-219.
- HAIŠ, M., et al. (2009): Comparison of two types of forest disturbance using multitemporal Landsat TM/ETM+ imagery and field vegetation data. *Remote Sensing of Environment*. 2009, č. 113, s. 835-845.
- HÁJEK, F. (2006): Object-oriented classification of Ikonos satellite data for the identification of tree species composition. *Journal of Forest Science*. 2006, roč. 52, č. 4, s. 181-187.
- HÁJEK, F., SVOBODA, M. (2007): Vyhodnocení odumírání horského smrkového lesa na Trojmezí (NP Šumava) metodou automatizované klasifikace leteckých snímků. *Silva Gabreta*. 2007, roč. 13, č. 1, s. 69-81.
- HARALICK, R. M. et al. (1973): Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*. 1973, roč. 3, č. 6, s. 610-621.
- HEURICH, M. (2008): Automatic recognition and measurement of single trees based on data from airborne laser scanning over the richly structured natural forests of the Bavarian Forest National Park. *Forest Ecology and Management*. 2008, roč. 255, s. 2416-2433.
- HEURICH, M., et al. (2010): Object-orientated image analysis for the semi-automatic detection of dead trees following a spruce bark beetle outbreak. *European Journal of Forest Research*. 2010, roč. 129, č. 3, s. 313-324.
- HUDAK, A. T., et al. (2006): Regression modeling and mapping of coniferous forest basal area and tree density from discrete-return lidar and multispectral satellite data. *Canadian Journal of Remote Sensing*. 2006, roč. 32, č. 2, s. 126-138.
- HYYPPÄ, J., et al. (2000): Accuracy comparison of various remote sensing data sources in the retrieval of forest stand attributes. *Forest Ecology and Management*. 2000, č. 128, s. 109-120.
- CHEN, G., HAY, G. J. (2011): An airborne lidar sampling strategy to model forest canopy height from Quickbird imagery and GEOBIA. *Remote Sensing of Environment*. 2011, roč. 115, č. 1532-1542.

- Inventarizace lesů, Metodika venkovního sběru dat*. Brandýs nad Labem: Ústav pro hospodářskou úpravu lesů, 2003. Dostupný z URL: <http://www.uhul.cz/il/metodika.php>.
- JONÁŠOVÁ, M., PRACH, K. (2004): Central-European mountain spruce forests: Regeneration of tree species after a Bark Beetle outbreak. *Ecological Engineering*. 2004, p. 23, 15-27.
- JOSHI, C., et al. (2006): Remotely sensed estimation of forest canopy density: A comparison of the performance of four methods. *International Journal of Applied Earth Observation and Geoinformation*. 2006, roč. 8, s. 84-95.
- KAYITAKIRE, F., HAMEL, C., DEFOURNY, P. (2006): Retrieving forest structure variables based on image texture analysis and IKONOS-2 imagery. *Remote Sensing of Environment*. 2006, roč. 102, s. 390-401.
- 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*. 2010, roč. 114, s. 1141-1154.
- KNÍŽEK, M., et al. (2010): Výskyt lesních škodlivých činitelů v Česku v roce 2009. In *Aktuálne problémy v ochrane lesa 2010 : Zborník referátov z medzinárodného seminára*. 1. vyd. Zvolen : Národné lesnícke centrum, 2010. s. 152. ISBN 978-80-8093-108-7.
- KORHONEN, L., et al. (2011): Airborne discrete-return LIDAR data in the estimation of vertical canopy cover, angular canopy closure and leaf area index. *Remote Sensing of Environment*. 2011, roč. 115, s. 1065-1080.
- LÉVESQUE, J., KING, D. J. (1999): Airborne Digital Camera Image Semivariance for Evaluation of Forest Structural Damage at an Acid Mine Site. *Remote Sensing of Environment*. 1999, roč. 68, č. 2, s. 112-124.
- LÉVESQUE, J., KING, D. J. (2003): Spatial analysis of radiometric fractions from high-resolution multispectral imagery for modelling individual tree crown and forest canopy structure and health. *Remote Sensing of Environment*. 2003, roč. 84, č. 4, s. 589-602.
- LIM, K., et al. (2003): LiDAR remote sensing of forest structure. *Progress in Physical Geography*. 2003, roč. 27, č. 1, s. 88-106.
- MALLINIS, G., et al. (2008): Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. *ISPRS Journal of Photogrammetry & Remote Sensing*. 2008, roč. 63, s. 237-250.
- MIURA, N., JONES, S. D. (2010): Characterizing forest ecological structure using pulse types and heights of airborne laser scanning. *Remote Sensing of Environment*. 2010, roč. 114, s. 1069-1076.
- MOSKAL, L. M., FRANKLIN, S. E. (2002): Multi-layer Forest Stand Discrimination with Spatial Co-occurrence Texture Analysis of High Spatial Detail Airborne Imagery. *Geocarto International*. 2002, roč. 17, č. 4, s. 55-67.

- NARASIMHA RAO, P. V., et al. (2002): Textural analysis of IRS-1D panchromatic data for land cover classification. *International Journal of Remote Sensing*. 2002, roč. 23, č. 17, s. 3327-3345.
- OZDEMIR, I. et al. (2005): Comparison of QuickBird-2 and Landsat-7 ETM+ data for mapping of vegetation cover in Fethiye-Kumluova coastal dune in the Mediterranean region of Turkey. *Fresenius Environmental Bulletin*. 2005, roč. 14, č. 9, s. 823-831.
- OZDEMIR, I. et al. (2008): Estimation of Tree Size Diversity Using Object Oriented Texture Analysis and Aster Imagery. *Sensors*. 2008, roč. 8, s. 4709-4724.
- OZDEMIR, I., KARNIELI, A. (2011): Predicting forest structural parameters using image texture derived from WorldView-2 multispectral imagery in a dryland forest, Israel. *International Journal of Applied Earth Observation and Geoinformation*. 2011, roč. 13, s. 701-710.
- PIROTTI, F. (2011): Analysis of full-waveform LiDAR data for forestry applications: a review of investigations and methods. *iForest*. 2011, roč. 4, s. 100-106.
- PLATT, R. V., SCHOENNAGEL, T. (2009): An object-oriented approach to assessing changes in tree cover in the Colorado Front Range 1938-1999. *Forest Ecology and Management*. 2009, roč. 258, č. 7, s. 1342-1349.
- RADOUX, J. et al. (2008): Comparison of pixel- and object-based sampling strategies for the thematic accuracy assessment. Proceedings of International conference GEOBIA, 2008 – Pixels, Objects, Intelligence: Geographic-Object Based Image Analysis for the 21st Century, August 5-8, 2008, Calgary, Alberta, Canada.
- REITBERG, J., KRZYSZEK, P., STILLA, U. (2009): Benefit of airborne full waveform lidar for 3D segmentation and classification of single trees. ASPRS 2009 Annual Conference Baltimore, Maryland.
- RICHARDSON, J. J., MOSKAL, M. (2011): Strengths and limitations of assessing forest density and spatial configuration with aerial LiDAR. *Remote Sensing of Environment*. 2011, roč. 115, s. 2640-2651.
- RODRIGUEZ-GALIANO, V. F. et al. (2012): Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. *Remote Sensing of Environment*. 2012, roč. 121, s. 93-107.
- SARKER, L. R., NICHOL, J. E. (2011): Improved forest biomass estimates using ALOS AVNIR-2 texture indices. *Remote Sensing of Environment*. 2011, roč. 115, s. 968-977.
- TOMPO E., et al. (2008): Combining national forest inventory field plots and remote sensing data for forest databases. *Remote Sensing of Environment*. 2008, roč. 112, s. 1982-1999.
- TONOLLI, S., et al. (2011): Fusion of airborne LiDAR and satellite multispectral data for the estimation of timber volume in the Southern Alps. *Remote Sensing of Environment*. 2011, roč. 115, s. 2486-2498.

- TREITZ, P. M., HOWARTH, P. J. (1999): Hyperspectral remote sensing for estimating biophysical parameters of forest ecosystems. *Progress in Physical Geography*. 1999, roč. 23, č. 3, s. 359-390.
- TRIMBLE (2010): ECognition Developer 8.64.0 Reference book. München : Trimble Gemanty GmbH, 2010. 410 s.
- WALTER, V. (2004): Object-based classification of remote sensing data for change detection. *ISPRS Journal of Photogrammetry & Remote Sensing*. 2004, č. 58, s. 225-238.
- WERNEROVÁ, V. (2007): *Vliv světla na druhové složení lesního podrostu na příkladu Milovického lesa* [rukopis]. Brno : Masarykova univerzita v Brně. Přírodovědecká fakulta. Ústav botaniky a zoologie, 2007. 75 s., 11 s. příl. Vedoucí bakalářské práce Mgr. MgA. Radim Hédl, Ph.D.
- WUNDERLE, A. L., FRANKLIN, S. E., GUO, X. G. (2007): Regenerating boreal forest structure estimation using SPOT-5 pan-sharpened imagery. *International Journal of Remote Sensing*. 2007, roč. 28, č. 19, s. 4351-4364.
- YU, X., et al. (2011): Predicting individual tree attributes from airborne laser point clouds based on the random forests technique. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2011, roč. 66, s. 28-37.
- ZEMEK, F., HEŘMAN, M., KLOUDA, Z. (1999): Bark beetle calamity assessment from remotely sensed data. *Silva Gabreta*. 1999, vol. 3, s. 161-172.
- ZHAO, K., et al. (2011): Characterizing forest canopy structure with lidar composite metrics and machine learning. *Remote Sensing of Environment*. 2011, roč. 115, s. 1978-1996.

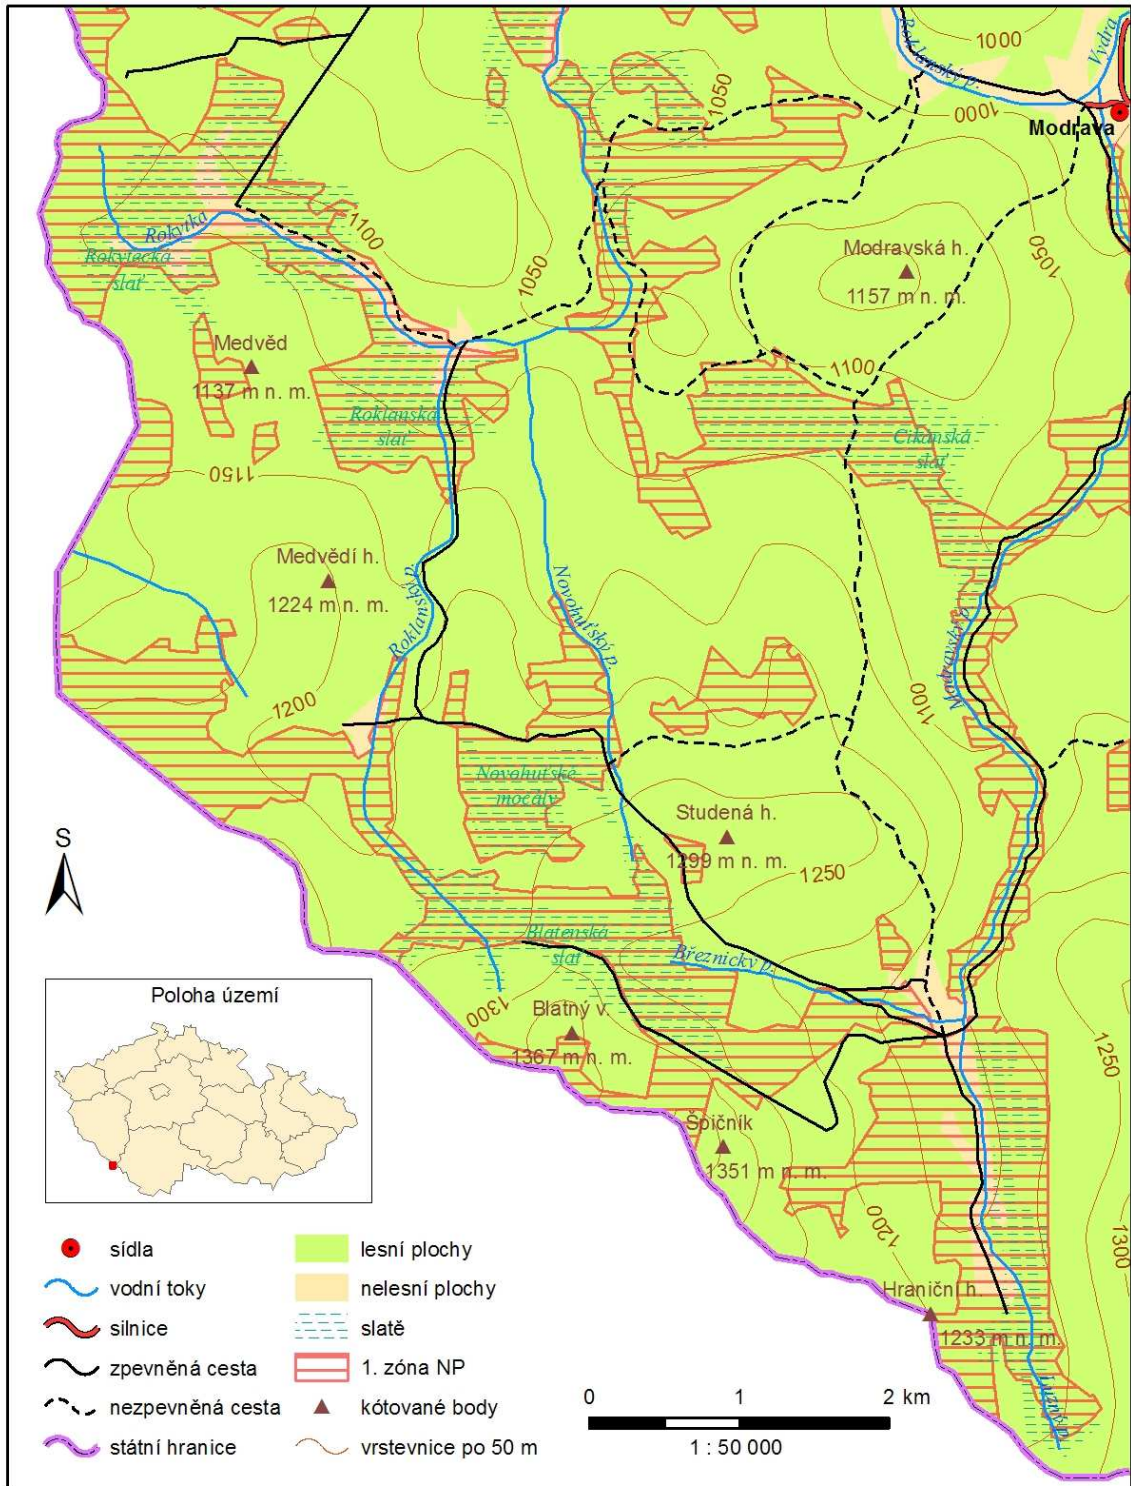
## **SEZNAM PŘÍLOH**

Příloha 1	CD s elektronickou verzí práce	
Příloha 2	Přehledová mapa zájmového území .....	I
Příloha 3	Hustota lesních porostů na základě texturálních příznaků .....	II
Příloha 4	Rozhodovací strom klasifikace na základě texturálních příznaků .....	III
Příloha 5	Hustota lesních porostů na základě texturálních a laserových příznaků .....	V
Příloha 6	Rozhodovací strom klasifikace na základě texturálních a laserových příznaků .....	VI
Příloha 7	Rozdíly mezi klasifikacemi .....	VIII

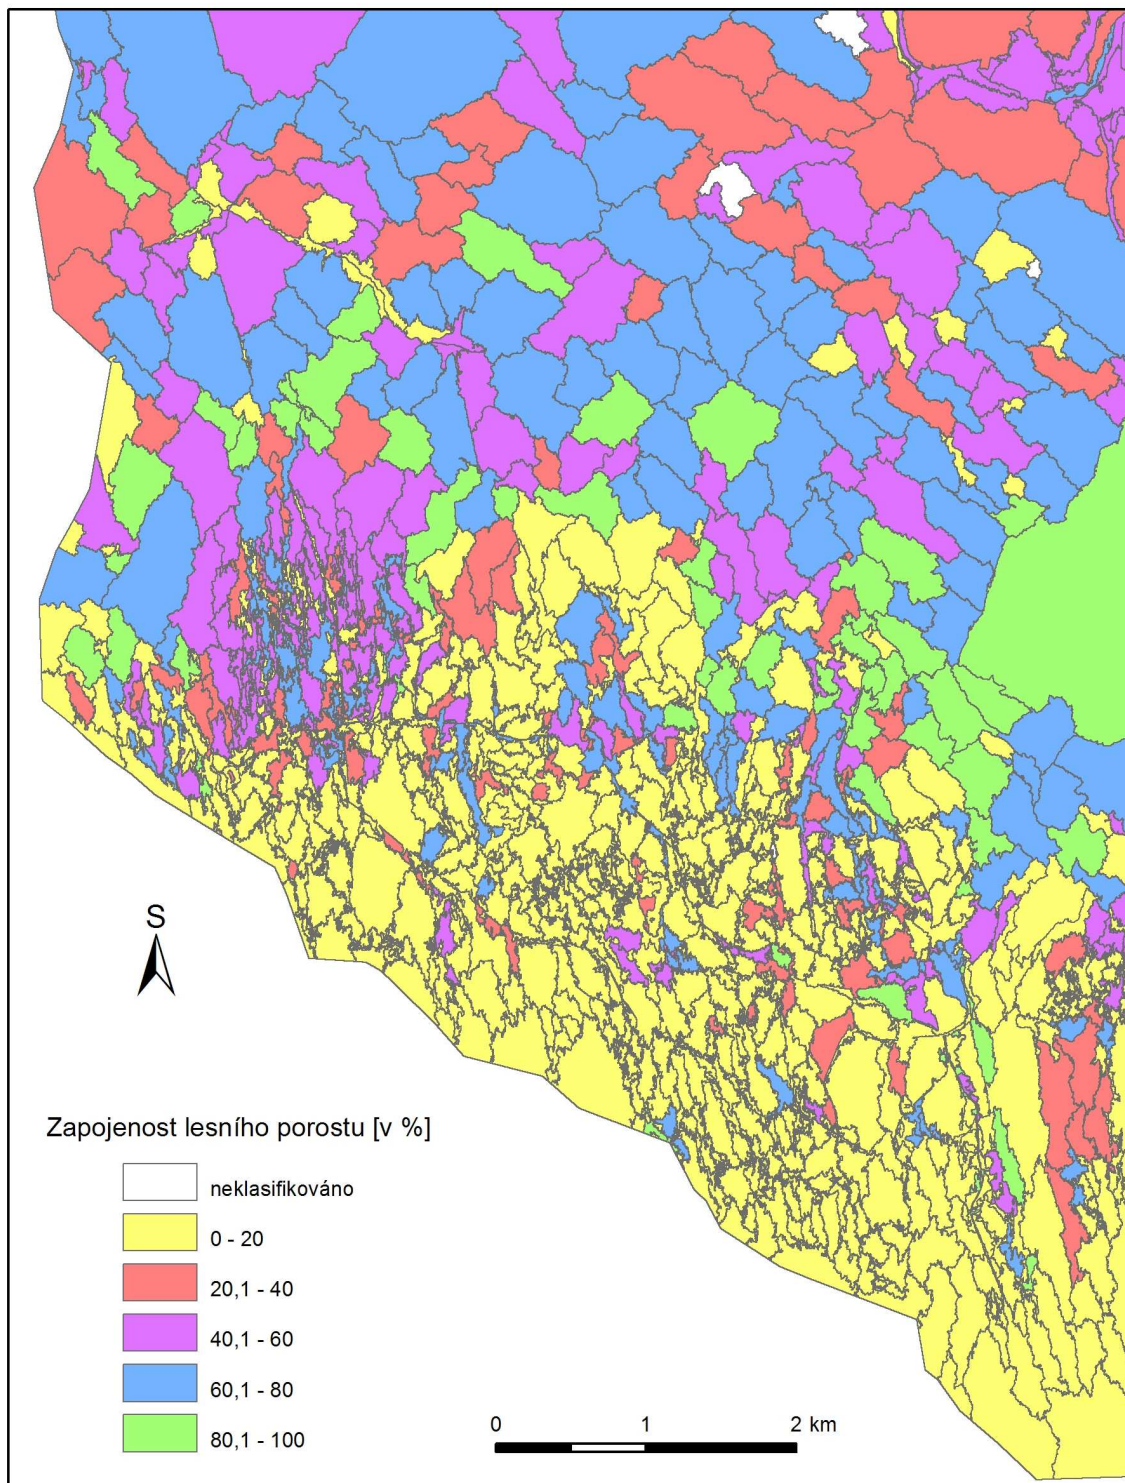
## Příloha 2

Přehledová mapa zájmového území

# BŘEZNÍK A MODRAVSKÉ SLATĚ

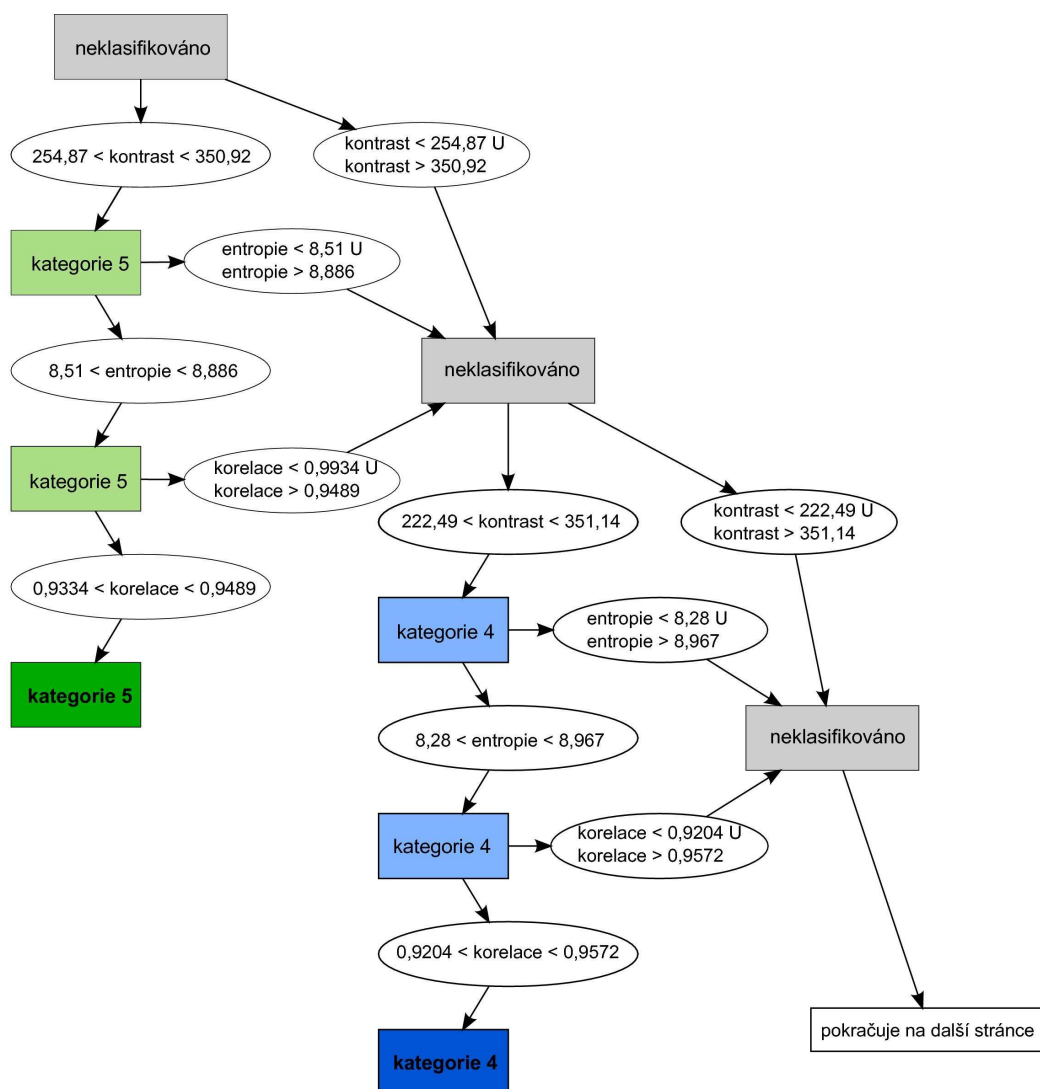


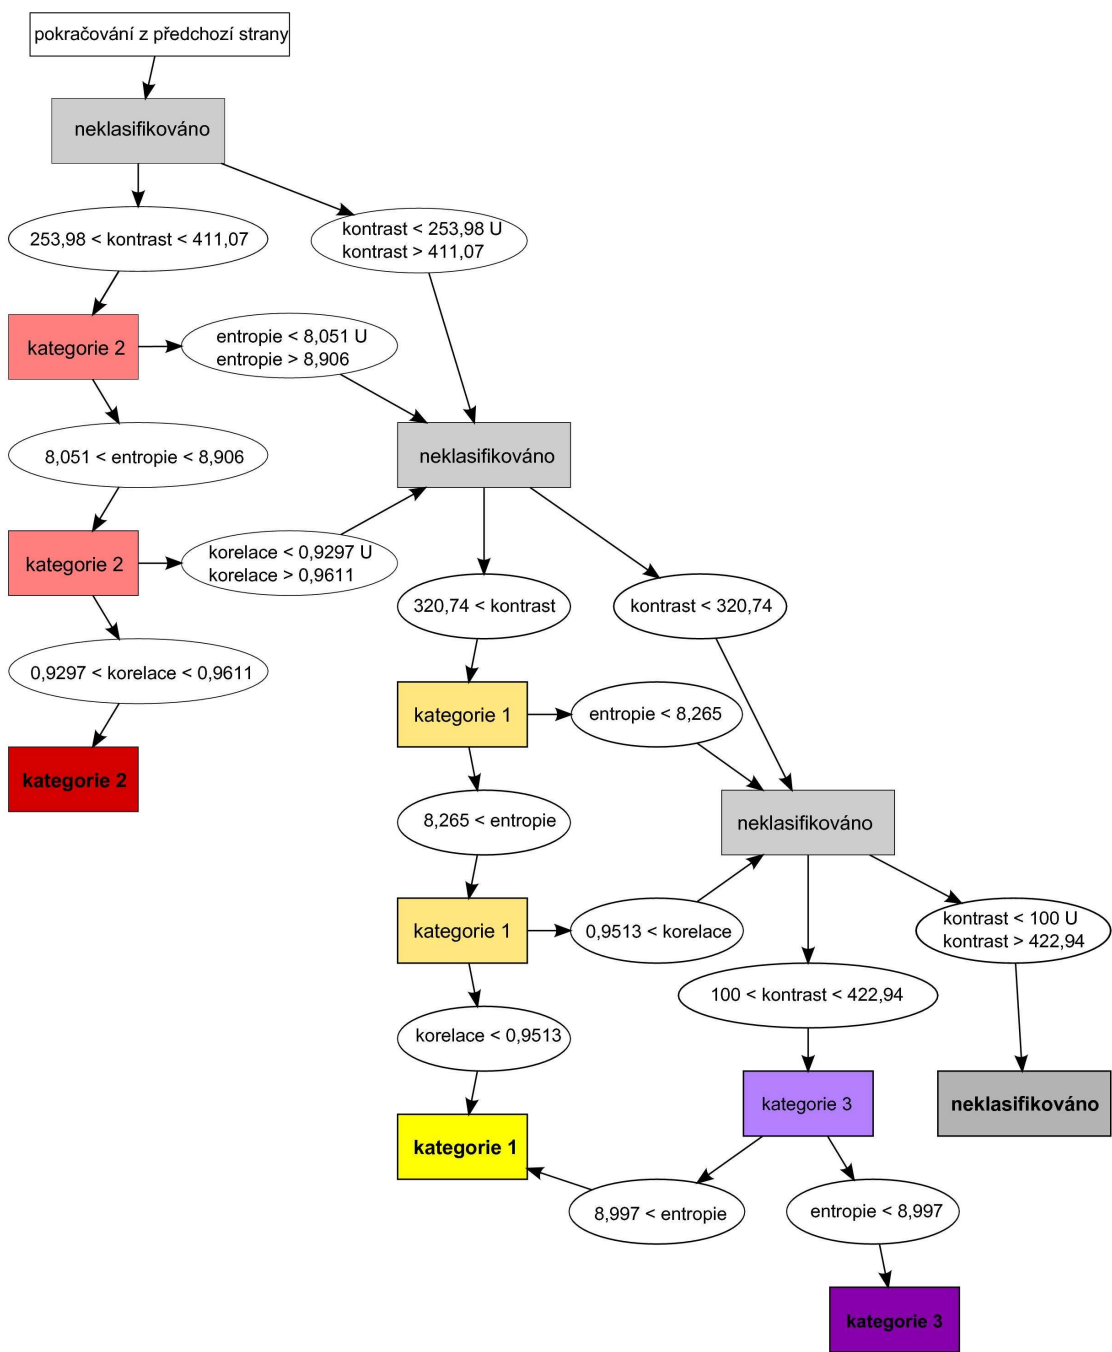
## HUSTOTA LESNÍCH POROSTŮ s využitím texturálních příznaků



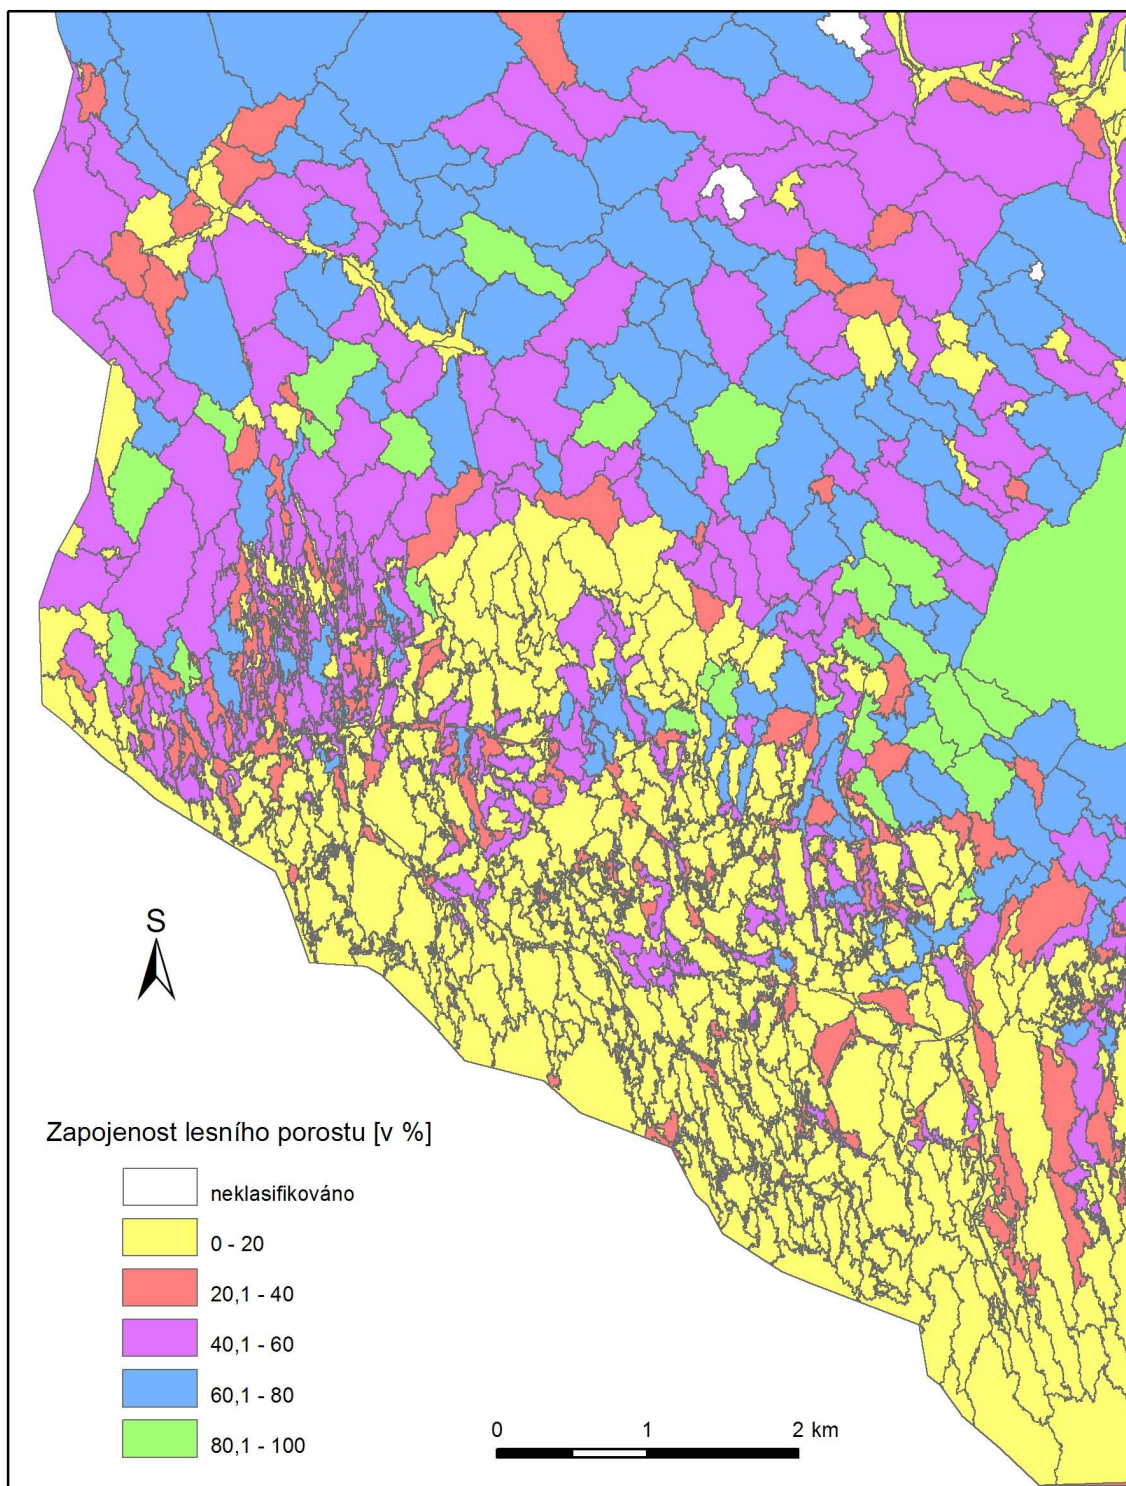
## Příloha 4

### Rozhodovací strom klasifikace na základě texturálních příznaků



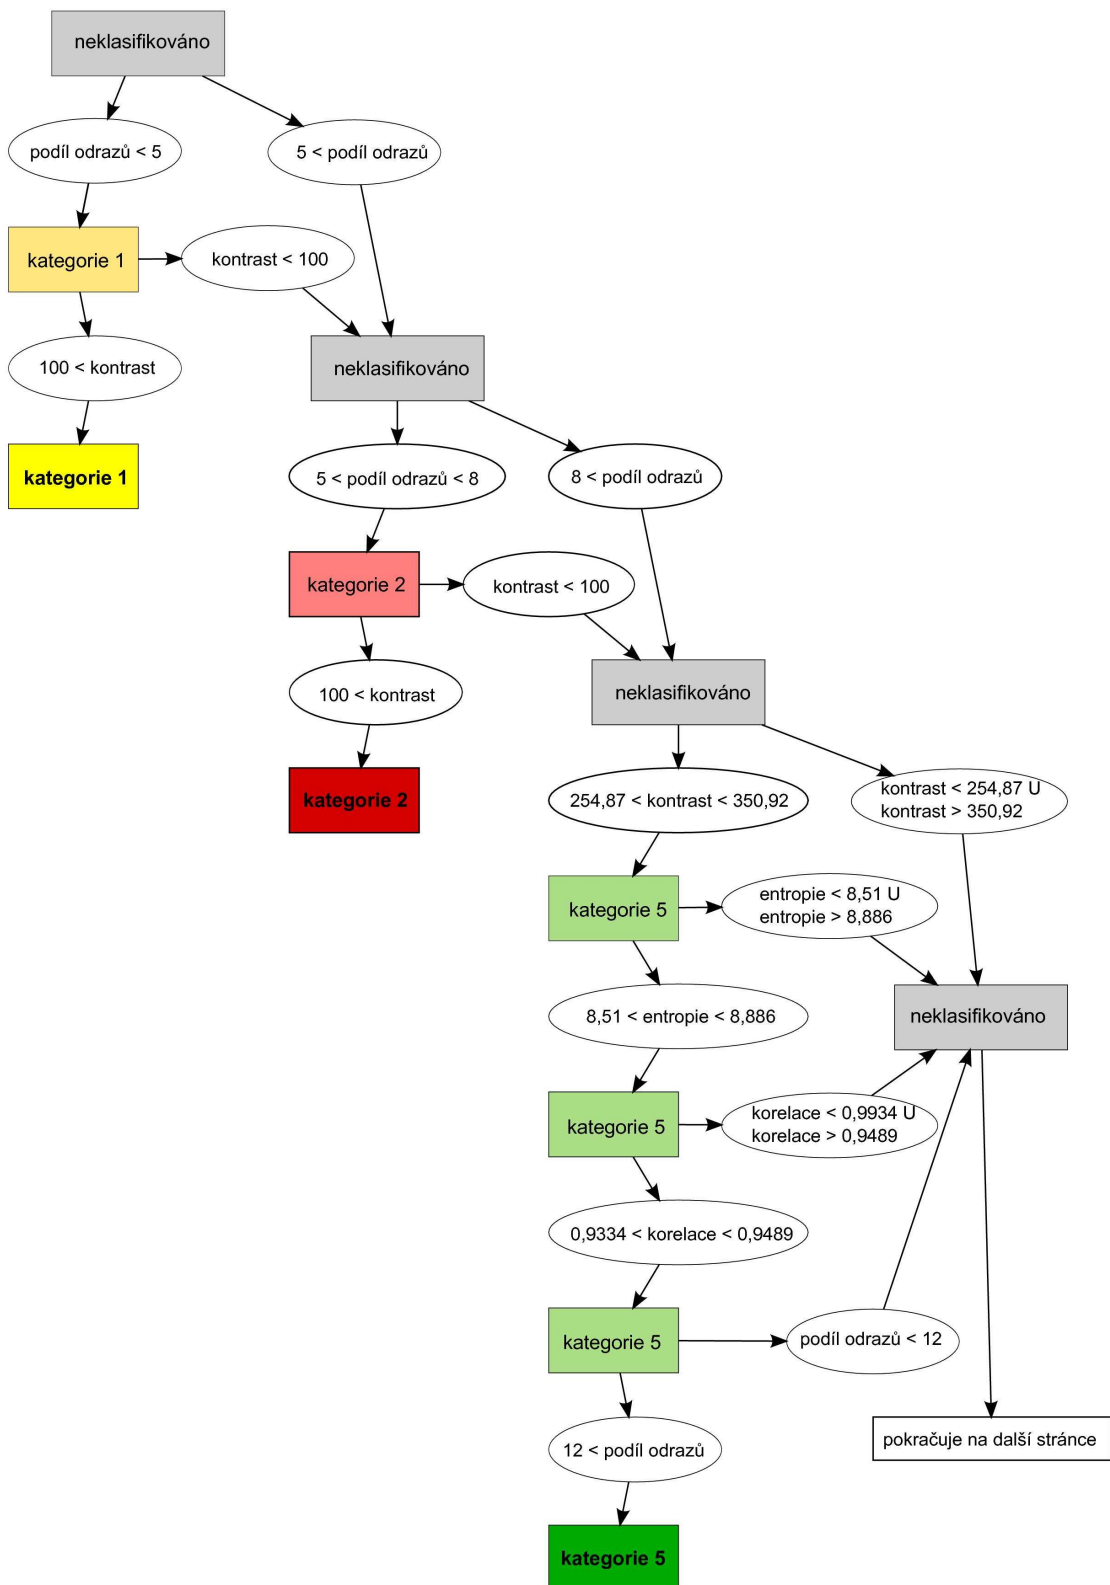


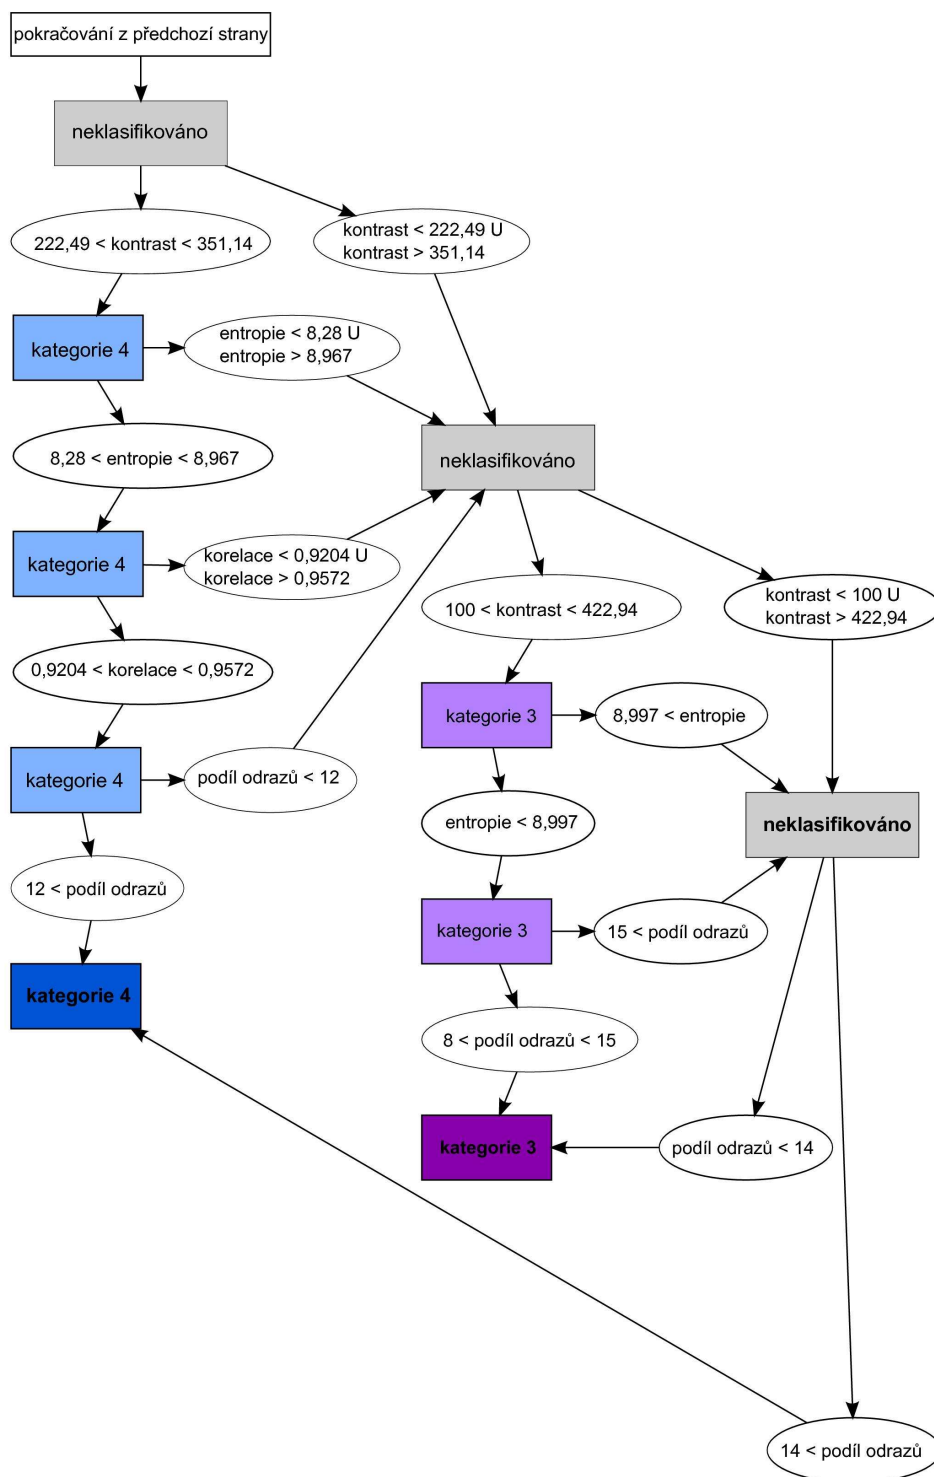
## HUSTOTA LESNÍCH POROSTŮ s využitím texturálních a laserových příznaků



## Příloha 6

Rozhodovací strom klasifikace na základě texturálních a laserových příznaků





## ROZDÍL HUSTOTY LESNÍCH POROSTŮ

určený klasifikací pomocí texturních příznaků  
a klasifikací pomocí texturních a laserových příznaků

