

**UNIVERZITA KARLOVA V PRAZE**

**Přírodovědecká fakulta**

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie (navazující magisterské studium)

Studijní obor: Kartografie a geoinformatika



Bc. Petra KOLEŠOVÁ

**URČOVÁNÍ SKLADBY NEHOMOGENNÍHO LESNÍHO  
POROSTU Z DRUŽICOVÝCH DAT**

**HETEROGENEITY IN FOREST VEGATION MONITORING  
WITH REMOTE SENSING**

Diplomová práce

Vedoucí diplomové práce: doc. Ing. Jan Kolář, CSc

Praha 2015

**Vysoká škola:** Univerzita Karlova v Praze

**Fakulta:** Přírodovědecká

**Katedra:** Aplikované geoinformatiky a kartografie

**Školní rok:** 2014/2015

# Zadání diplomové práce

**pro** Petru Kolešovou

**obor** Kartografie a geoinformatika

**Název tématu:** *Určování skladby nehomogenního lesního porostu z družicových dat*

## Zásady pro vypracování

Určování skladby lesního porostu patří k úkolům řešeným dálkovým průzkumem od jeho počátku. V této práci půjde o analýzu možností družicových dat pro rozpoznání druhově nehomogenních území v lesním porostu, které jsou ale významově vázány na definici habitatů přenašečů virových onemocnění. Dosavadní výzkumy se hlavně soustředily na použití dat družice Landsat a jejich spektrální příznaky. Výsledky jsou však omezeny spektrálním i prostorovým rozlišením skeneru TM na družici Landsat 5 a 7. Práce bude zpracována z družicových snímků Landsat 8 OLI. Práce by měla hledat požadavky na takové spektrální příznaky, které by definované botanické třídy umožnily rozpoznat s větší přesností. Dále bude na zájmovém území statistickými metodami zkoumána heterogenita lesního porostu.

**Rozsah grafických prací:** dle potřeby

**Rozsah průvodní zprávy:** 60 – 70 stran – diplomová práce

**Seznam odborné literatury:**

GLOSOVÁ, P. 2013. *Zjištění prostorové struktury typologických snímků lesní vegetace*. Brno, 2013. 57 s. Bakalářská práce na Přírodovědecké fakultě Masarykovy univerzity.

READ, J. M. ...[et al.] 2002. Spatial methods for characterising land cover and detecting land/cover changes for the tropics. *Int. J. Remote Sensing* [online]. vol. 23, issue 12 [cit 2014-04-04]. p. 2457-2474. Dostupné z URL:

<<http://www.tandfonline.com/doi/abs/10.1080/01431160110106140#.U2amfld18Sg>>.

WOLTER, P. T. ...[et al.] 1995. Improved Forest Classification in the Northern Lake States Using Multi-Temporal Landsat Imagery. *Photogrammetric Engineering & Remote Sensing* [online].

vol. 61 issue 9 [cit 2015-05-20]. p. 1129-1143. Dostupné z URL:<

[http://eserv.asprs.org/PERS/1995journal/sep/1995\\_sep\\_1129-1143.pdf](http://eserv.asprs.org/PERS/1995journal/sep/1995_sep_1129-1143.pdf) >.

Vedoucí diplomové práce: *doc. Ing. Jan Kolář, CSc.*

Konzultant diplomové práce:

Datum zadání diplomové práce: 15. 1. 2015

Termín odevzdání diplomové práce: 31. 7. 2015

.....  
Vedoucí diplomové práce

.....  
Vedoucí katedry

V Praze dne

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.

Ve Vodňanech dne 29. července 2015

.....

Petra Kolečová

## **Poděkování**

Z prvé řady děkuji svému vedoucímu práce doc. Ing. Janu Kolářovi, CSc. za cenné rady, věcné připomínky a vstřícnost při konzultacích a vypracování diplomové práce. Dále pak své rodině, která mě psychicky i finančně podporovala během studií a vypracování práce.

## Určování skladby nehomogenního lesního porostu z družicových dat

### Abstrakt

Práce si bere za cíl prozkoumání možností klasifikace lesní vegetace pomocí snímků z družice Landsat 8. Nejvhodnějšími kandidáty pro zpracování se staly dva snímky. Pořízeny byly ve vegetačním období (8. března 2014 a 27. července 2013). Cílem je zjistit, zda využitím statistických metod můžeme získat informace o heterogenitě lesa na zájmovém území. Modelové území zahrnuje správní území vybraných obcí z Jihočeského a Středočeského kraje, které se nachází na území pěti ORP (Blatná, Milevsko, Písek, Příbram, Sedlčany). Provedeny byly neřízené i řízené klasifikace na základě získaných trénovacích ploch z terénu a ortofota. Tyto třídy (jehličnaté lesy, smíšené lesy, ekotony, strukturně homogenní listnaté lesy a strukturně heterogenní listnaté lesy) odpovídaly definičním kategoriím použitým v projektu NT 11425-5/2010 Mapování přírodních ohnisek zoonóz přenosných na člověka v ČR a jejich změny ovlivněné modifikacemi klimatu. Díky trénovacím množinám získaným v terénu a ortofota a podobností spektrálních vlastností se získalo větší množství trénovacích pixelů, které vstupovaly do řízené klasifikace. U klasifikací byly provedeny kontroly přesnosti pomocí chybové matice. Řízená klasifikace s účastí prvních osmi spektrálních pásem z obou snímků a aplikovaným algoritmem Maximum Likelihood byla zvolena za nejvhodnější. Klasifikovaná lesní vegetace byla rozřezána dle území obcí. Na těchto územních jednotkách byly vyzkoušeny dvě metody statistické analýzy pro zkoumání heterogenity. Prostorová autokorelace byla vypočtena pomocí Moranova indexu a Getis – Ord General G analýzy na globální a lokální úrovni. V této analýze se provádělo porovnání rozloh lesní vegetace dané obce pouze v rámci samotných tříd. Dále pak byla vypočtena prostorová autokorelace Shannonova indexu. Na globální úrovni vykazovala ve všech případech velmi slabou pozitivní autokorelaci. Na lokální úrovni byly nalezeny lokality, kde se vyskytovaly shlukové oblasti podobných hodnot. Getis – Ord General G analýza také zobrazila některá místa shluků podobných hodnot na modelovém území. Shannonův index biodiverzity zachytil pestrost a vyrovnanost dané obce. Do výpočtu vstupovaly vždy všechny třídy. Nejvyšší hodnota Shannonova indexu byla vypočtena u obce Kozlí a nejnižší u obce Bratronice. Prostorová autokorelace Shannonova indexu ukázala na oblasti, které jsou homogenního a heterogenního charakteru. V jižní části ORP Písek se nachází lesní porost, jenž je dle výsledků velmi heterogenní. Naopak homogenním se stala oblast v ORP Příbram na území obce Brdy a okolí, kde převažuje jehličnatý les.

**Klíčová slova:** Landsat, klasifikace, lesní vegetace, Shannonův index, prostorová autokorelace

## **Heterogeneity in forest vegetation monitoring with remote sensing**

### **Abstract**

The main aim of this diploma thesis is to examine the suitability of various classification approaches for forest vegetation categorization using Landsat 8 satellite imagery. Two satellite images acquired during vegetative period (8th March, 27th July 2013) were chosen. The overall goal of the study is to explore the potential of using statistical methods to obtain information about forest heterogeneity in a given territory. Chosen study sites are defined by administrative boundaries of selected municipalities from South and Central Bohemia located within following municipalities with extended powers - Blatná, Milevsko, Písek, Příbram and Sedlčany. Supervised and unsupervised classifications were used based on obtained training areas and orthophoto. The definition of chosen classes (coniferous forests, mixed forests, ecotones, structurally homogeneous deciduous forests and structurally heterogeneous deciduous forests) was identical with the categories used in "Project MT 11425-5/2010 The Mapping of Natural Zoonoses Focal Points, Transferable on Humans in the Czech Republic and Their Changes Affected by the Modification of Climate". Due to large amount of training datasets obtained from field survey, orthophoto and spectral analysis, significant number of training pixels was available as input to supervised classification. The accuracies of the classifications were assessed using error matrix. The best results were obtained using supervised classification of the first eight spectral bands from both satellite images and Maximum Likelihood algorithm. The heterogeneity was assessed for each municipality separately using two different methods of statistical analysis. Spatial autocorrelation was computed by using Moran index and Getis-Ord General G analysis – on the global as well as on the local level. In this analysis the comparison of forest vegetation areas was made in each class separately. Furthermore, the spatial autocorrelation of Shannon's Index was calculated. In this method the spatial autocorrelation showed only very low positive values on global level. On local level localities with clusters of similar values were found. These localities proved that the analysis can be used for such research. Getis - Ord General G analysis showed there are multiple areas with similar values in the model area. Shannon Biodiversity Index captured the diversity and evenness in each municipality. All classes were inserted into the evaluation. The highest value of Shannon's Index was observed in the municipality Kožlí and the lowest one in the municipality Bratronice. Spatial autocorrelation of Shannon's index showed the areas which have homogeneous and heterogeneous character. Based on the results, the forest situated in the southern part of the municipality with extended powers Písek is significantly heterogeneous. Conversely homogeneous area is situated in the municipalities with extended powers Příbram and Brdy where coniferous forest is dominant.

**Keywords :** Landsat, Classification, Forest canopy, multispectral data, Shannon's Index, Spatial autocorrelation

## OBSAH

<b>OBSAH</b> .....	<b>9</b>
<b>SEZNAM OBRÁZKŮ A TABULEK</b> .....	<b>11</b>
<b>SEZNAM POUŽITÝCH ZKRATEK</b> .....	<b>12</b>
<b>1 ÚVOD</b> .....	<b>13</b>
<b>2 REŠERŠE LITERATURY</b> .....	<b>15</b>
2.1 Heterogenita lesní vegetace.....	15
2.1.1 Heterogenita a biodiverzita.....	15
2.2 Využití družicových snímků při studiu lesní vegetace.....	16
2.3 Klasifikované třídy lesní vegetace.....	17
2.4 Klasifikace.....	19
2.4.1 Posuzování přesnosti klasifikace .....	19
2.4.2 Klasifikace vegetačního povrchu v praxi.....	20
2.4.2.1 Klasifikace s použitím TM a MSS senzoru.....	20
2.4.2.2 Klasifikace v tropických oblastech .....	21
2.4.2.3 Další klasifikace s využitím družicového systému Landsat.....	22
2.5 Prostorové analýzy .....	24
2.5.1 Teorie prostorové autokorelace .....	24
2.5.2 Základní informace o prostorové autokorelace.....	24
2.5.3 Bodové a plošné prvky prostorové autokorelace.....	26
2.5.4 Indexy pro výpočet prostorové autokorelace.....	26
2.5.4.1 Join Count statistika .....	26
2.5.4.2 Moranův index .....	27
2.5.4.3 Gearyho index .....	28
2.5.4.4 Getis – Ord General G.....	28
2.5.5 Variogram, korelogram a kartogram .....	29
2.6 Biodiverzita a indexy .....	30
2.6.1 Biodiverzita v dálkovém průzkumu Země.....	30
2.6.2 Shannonův diverzitní index .....	31
2.7 Metody prostorové autokorelace a krajinných metrik v DPZ.....	32
2.7.1 Prostorové metody pro charakterizaci land cover a detekci změn v tropech .....	32
2.7.1.1 Fraktální dimenze.....	33
2.7.1.2 Prostorová autokorelace .....	33
2.7.1.3 Krajinné metriky .....	34
2.7.1.4 Porovnání výsledků prostorových analýz a krajinných indexů.....	34
2.7.2 Další příklady využití prostorové autokorelace.....	35
2.7.3 Další příklady Shannonova diverzitního indexu.....	35
<b>3 DATA A METODIKA</b> .....	<b>36</b>

3.1	Výběr analýz při výzkumu vztahů v prostoru.....	36
3.2	Modelové území .....	37
3.3	Snímky LANDSAT .....	38
3.4	Použité softwarové programy (ArcGIS, ENVI, Geomatica) .....	40
3.4.1	Geomatica .....	40
3.4.2	SW ARCGIS.....	40
3.4.3	ENVI.....	40
3.5	Předzpracování dat.....	41
3.6	Trénovací plochy a kontrolní body .....	42
3.7	Řízená klasifikace .....	43
3.8	Postklasifikační úpravy .....	44
3.9	Statistické metody.....	45
3.9.1	Metoda Shannonova diverzitního indexu .....	45
3.9.2	Analýzy prostorové autokorelace .....	46
3.9.2.1	Moranův index .....	46
3.9.2.2	Getis – Ord General G.....	47
<b>4</b>	<b>VÝSLEDKY.....</b>	<b>48</b>
4.1	Klasifikace a její přesnost.....	48
4.2	Rozlohy lesní vegetace v ORP.....	50
4.3	Výsledky Shannonova diverzitního indexu .....	52
4.4	Výsledky prostorové autokorelace.....	52
4.4.1	Výsledky Moranova indexu.....	52
4.4.2	Výsledky Getis – Ord General G.....	54
4.4.3	Aplikování prostorové autokorelace na Shannonův index .....	56
<b>5</b>	<b>DISKUZE.....</b>	<b>58</b>
<b>6</b>	<b>ZÁVĚR.....</b>	<b>62</b>
	<b>POUŽITÉ ZDROJE INFORMACÍ.....</b>	<b>64</b>
	<b>POUŽITÉ DATOVÉ ZDROJE .....</b>	<b>68</b>
	<b>SEZNAM PŘÍLOH.....</b>	<b>69</b>

## SEZNAM OBRÁZKŮ A TABULEK

Obr. 1	Prostorová autokorelace
Obr. 2	Binární a řádkově standardizovaná matice
Obr. 3	Empirický variogram
Obr. 4	Zájmové území
Obr. 5	Lesní vegetace ve vybraných ORP
Obr. 6	Procentuální zastoupení lesní vegetace v ORP
Obr. 7	Porovnání rozlohy lesní vegetace s nelesní za ORP
Tab. 1	Spektrální pásma u družice Landsat 8 – senzor OLI
Tab. 2	Charakteristiky vybraných scén
Tab. 3	Nová pásma a jejich prezentace
Tab. 4	Trénovací plochy a kontrolní body
Tab. 5	Výsledky přesnosti řízené klasifikace algoritmem Maximum Likelihood multitemporálního snímku Brez_cerv.tif při účasti všech spektrálních pásem
Tab. 6	Chybová matice multitemporálního snímku z Landsat 8
Tab. 7	Přesnost řízených klasifikací snímku z Landsat 8
Tab. 8	Charakteristiky globálního Moranova indexu lesní vegetace na úrovni obcí
Tab. 9	Charakteristiky lokálního Moranova indexu
Tab. 10	Charakteristiky globální General G analýzy lesní vegetace
Tab. 11	Z – skóre lokální varianty Getis – Ord General G klasifikovaných tříd lesní vegetace
Tab. 12	Globální Moranův index Shannonova indexu
Tab. 13	Getis – Ord General G analýza Shannonova indexu

## **SEZNAM POUŽITÝCH ZKRATEK**

**CLC** – Corine Land Cover

**ČR** – Česká republika

**ČÚZK** – Český úřad zeměměřický a katastrální

**DP** – Diplomová práce

**DPZ** – Dálkový průzkum Země

**ETM+** - Enhanced Thematic Mapper Plus

**GPS** - Global Positioning System (Globální polohovací systém)

**IDL** – Interactive Data Language

**LISA** – Local Indicators of Spatial Autocorrelation

**MSS** – Multispectral Scanner System

**NDSI** – Normalized Difference Snow Index

**NDVI** – Normalized Difference Vegetation Index – Normovaný poměrový vegetační index

**NIR** – Near Infrared Radiation – blízké infračervené záření

**NP** – Národní park

**OLI** – Operational Land Imager

**ORP** – Obec s rozšířenou působností

**RED** – Pásmo v červeném viditelném světle

**REDD+** - Reducing Emissions from Deforestation and Degradation

**SPOT** - Satellite Pour l'Observation de la Terre (Satellite for observation of Earth)

**SW** - software

**TM** – Thematic Mapper

**USGS** – U.S. Geological Survey – Geologický výzkum Spojených států

**UTM** – Universal Transvers Mercator

**WBDI** – Wetness – Brightness Difference Index

**WGS** – World Geodetic System

# KAPITOLA 1

## 1 Úvod

V dnešní uspěchané době je díky technickému pokroku možné vnímat krajinu mnohem komplexněji. Družicové a letecké snímky ukazují dříve neznámý pohled na krajinu, a proto ji díky nim můžeme lépe analyzovat. Snímky se často využívají pro hodnocení změn land cover a land use. Výzkum v terénu dohromady s dálkovým průzkumem Země je vhodnou metodou, na jejíž výsledky můžeme aplikovat různé statistické výpočty.

Hlavním cílem je zjistit, zda pomocí spektrálních příznaků lze zkoumat strukturu lesa a zda existují některé souvislosti s jeho prostorovým rozdělením. Je zde snaha o zobrazení rozložení tříd lesního porostu na územních jednotkách. Zda existuje mezi jednotlivými typy lesní vegetace určitá závislost v uspořádání a fragmentaci. Důležitou roli zde hrají spektrální pásma z družice Landsat 8. Díky trénovacím množinám nasbíraným v terénu a ortofotu bude provedena řízená klasifikace, na jejímž základě se provedou prostorové analýzy.

Tato diplomová práce bude popisovat heterogenitu lesní vegetace na vybraných územích obcí s rozšířenou působností. Konkrétně se jedná o ORP na hranici Středočeského a Jihočeského kraje (Sedlčany, Příbram, Blatná, Milevsko, Písek). Prostorové analýzy budou provedeny také na nižších územních jednotkách administrativního členění – správních území obcí. Tyto oblasti byly vybrány z důvodu větší rozlohy lesního porostu, které ale nezahrnují pouze monokultury smrkových lesů, jež se nachází například v NP Šumava. Dalším důvodem bylo provedení terénního průzkumu na tomto území při projektu *Mapování přírodních ohnisek zoonóz přenosných na člověka v ČR a jejich změny ovlivněné modifikacemi klimatu*. V rámci terénního průzkumu byly nasnímány zájmové oblasti lesní vegetace a zaznamenány jejich souřadnice. Tato data byla využita i pro tuto práci. Jelikož ale nebylo nasbíráno dostatečné množství zájmových bodů, byly ještě některé body zaznamenány z ortofota pomocí WMS služby z geoportálu ČÚZK.

Mezi zpracovávané prostorové charakteristiky patří prostorová autokorelace, která bude vypočtena Moranovým indexem a analýzou Getis - Ord General G. Dále bude vypočten index biodiverzity - Shannonův index, jenž představuje rozmístění jednotlivých druhů, tak i jejich dominantnost.

Odděleně bude porovnávána každá třída lesního porostu v rámci zájmového území. Tím se zjistí, zda existuje v některých kategoriích prostorová závislost. Výpočtem Shannonova indexu pro jednotlivé územní celky vyjádříme, které oblasti jsou třídami zastoupeny pestřeji a která ne. Na tyto výsledky aplikujeme ještě prostorovou autokorelaci, díky čemuž zahrneme do analýzy všechny definované struktury lesního porostu.

Hypotéza tvrdí, že v rámci jednotlivých tříd, ale i z výpočtu Shannonova indexu, se bude vyskytovat pozitivní prostorová autokorelace. V rámci zájmového území bude docházet ke shlukování oblastí s podobnou hodnotou. Budou také nalezeny oblasti s homogenním a heterogenním charakterem.

Díky výpočtům Shannonova indexu a prostorové autokorelace budeme odpovídat na otázky typu: Proč dvě odlišné třídy vytvářejí shluky na stejných územích? Které ORP či správní území obce je nejvíce heterogenní v rámci tříd lesní vegetace? Proč se v daném ORP vyskytuje více struktur jednoho typu než toho druhého? Vysvětlení bude následovat ve správném zpracování a interpretaci výsledků analýzy.

Tento výzkum může posloužit k hodnocení struktur lesní vegetace v uvedených oblastech. Ve větší míře se tyto analýzy mohou vztáhnout na celou Českou republiku. V konfrontaci s jinými vědními obory (geologie, hydrologie) můžeme výsledek klasifikace zkoumat z hlediska životního prostředí. Samotná prostorová autokorelace a Shannonův index napoví, které oblasti jsou strukturně pestře složené a které mají spíše homogenní strukturu. To může posloužit k dalšímu výzkumu z biologického hlediska, kdy se botanikové mohou zaměřit na ORP, kde se vyskytuje strukturně heterogennější lesní vegetace.

# KAPITOLA 2

## 2 Rešerše literatury

### 2.1 Heterogenita lesní vegetace

Lesy jsou důležitým prostorem ovlivňující společenstva živočichů, která jsou ve většině případů závislá na diverzitě prostředí a vegetaci. Heterogenita podporuje vyšší druhové bohatství s ohledem na abiotické a biotické faktory.

Heterogenita je vlastnost, kterou se označuje skutečnost, že určitý celek je složen z rozdílných částí. To znamená, že například v problematice krajinné ekologie se nachází více typů krajiny v dané oblasti či v oboru dálkového průzkumu Země více tříd krajinných pokryvů.

Prostorovou heterogenitou se rozumí plošná mozaika prostředí, kde jsou vzájemně propojeny určité lokality, na kterých spolu žijí konkurenční druhy (rostliny, živočichové) (Lipský, 1998). Vyšší heterogenita prostředí znamená větší rozmanitost zdrojů. Zdroji myslíme větší množství živočišných druhů nebo také typů vegetace. Lesní vegetace může být chápána jako jeden určitý typ krajiny, který je porovnáván s jinými land cover druhy. Zkoumat ji také můžeme z hlediska jednoho celku složeného z dílčích částí. Měřítko a prostorové uspořádání jsou nejdůležitějšími prvky pro pochopení změn v prostoru. Studie v malém měřítku má rozdílné výsledky než ty z velkých měřítek, všechno pak vede k nekonzistenci výsledků.

Na heterogenitu lesa se lze dívat z různých úhlů pohledů. V prvním případě vnímáme heterogenní les jako vegetaci s více druhy stromů a v druhém pak můžeme brát heterogenní les jako vegetaci s jedním typem stromů obsahující hustá křovinná a bylinná patra. Druhý případ se zaměřuje na jeho strukturu. Jiné faktory jako je stáří stromů či lidské zásahy do přírody mohou mít také vliv na heterogenitu prostředí. Území s více stromy různého stáří je více heterogenní než oblast se stejně starými borovicemi z hlediska věku. Z uvedených příkladů vyvozujeme, že prostorová heterogenita může mít mnoho definic a záleží pouze na nás, jak jí pojmem.

V této diplomové práci se zabývám heterogenitou lesní vegetace z pohledu jejího strukturního složení. Prostorová heterogenita se zde projeví v zastoupení definovaných tříd, které vzniknou díky řízené klasifikaci z trénovacích množin získaných terénním průzkumem a ortofotomapy. Díky klasifikaci se zde projeví vliv spektrálních pásem. Kontrolní body poslouží k ověření přesnosti klasifikace.

#### 2.1.1 Heterogenita a biodiverzita

Biodiverzita je významná z ekonomického, kulturního a vědeckého hlediska. Je na ní postavena ekologická stabilita, což je schopnost ekosystému udržovat rovnováhu narušovanou vnějšími vlivy, a tak si zachovat přirozené vlastnosti. Pokud dojde k zásahu zvenčí, může se rozjet řetězec nevratných negativních změn (snížení či vymizení druhů). Dejme si příklad hmyzu. Čím

vyšší je heterogenita prostředí, tím vyšší počet druhů hmyzu se v dané oblasti vyskytuje. V heterogenním prostředí je umožněno se lépe vyhnout predaci, konkurenci a disturbancím, ale záleží na konkrétním prostředí, protože nemusí všude fungovat stejně (Biodiverzita, 2014).

Diverzita lesního porostu nemusí vždy znamenat vysokou rozmanitost druhu. Například u hnízdících ptáků v severní Americe toto kritérium platí, avšak v jižní Americe nikoliv. „*Strukturované porosty jsou zde příliš vzácné na to, aby se zde ptáci specializovali na jednotlivá patra. K rozdělení zdrojů došlo především v rámci méně vzácných (a méně heterogenních) typů prostředí (Schluter a Ricklefs, 1993).*“ Vysoká fragmentace stanovišť může znamenat snížení počtu druhů v dané oblasti. Fragmentací se rozumí rozdělení přírodních územních celků v krajině na menší izolovanější oblasti (Biodiverzita, 2014).

Heterogenita může ovlivňovat organismy na genetické úrovni, úrovni druhu nebo na vyšší než druhové. To znamená ve společenstvech a ekosystémech, v nichž jednotlivé druhy žijí (Biodiverzita, 2014).

## 2.2 Využití družicových snímků při studiu lesní vegetace

S objevem satelitních zařízení šla technika a výzkum zemského povrchu značně dopředu. Hlavně v posledních desetiletích se rozmohlo velké komerční využití, díky těmto přístrojům nejen u státních firem, ale i privátních. Díky satelitním snímkům můžeme získat informace o land cover/land use.

S vývojem techniky se vylepšuje image processing a jiné metody pro zpracování dat. Většina výzkumů land cover a detekcí změn je primárně založena na spektrálních charakteristikách dat dálkového průzkumu Země. Důležité je rozpětí a počet spektrálních pásem. Hlavními metodologickými problémy bývá přerozdělování pixelů spektrálně nezřetelných krajinných povrchů a jejich změn. Pomocí rozlišovacích technik se snažíme zachytit rozdíly v povrchových podmínkách. Dále se kontrolují změny spektrální přírody land cover v průběhu času (Read, 2001).

Výhodou mapování fragmentované krajiny ze satelitních snímků je záběr širšího území, než je tomu z leteckých snímků, a proto je družicové snímkování bráno jako významný pokrok v technologii mapování. (Rodriguez, 2011). Snímky poskytují informace o povrchu, které nejsou pouhým okem pozorovatelné. Jednotlivé typy pokryvu jsou rozčleněny dle spektrálních charakteristik do kategorií.

Multitemporální snímky z družicových dat se využívají při stanovení vegetačních typů a jejich charakteristik například pomocí vegetačních indexů (Gond, 2013). Kombinací snímků z různých ročních dob lze odlišit jednotlivé kategorie lesního porostu kvůli jejich individuálnímu fenologickému chování během roku. Například Liang et al. (2009) ve své studii

použil pro rozlišení listnatých, jehličnatých lesů a nevegetačního povrchu multitemporální snímek QuickBird. Použil dva snímky, kde se na prvním listy nacházely a na druhém nikoliv. Následovalo spojení těchto snímků a provedla se klasifikace.

Každá scéna družicového snímku je složena z pixelů, které dávají dohromady objekty na zemském povrchu. Pixely s podobnou hodnotou odrazivosti vytvářejí společně krajinný pokryv. Lesní vegetace bývá tvořena širokou škálou digitálních spektrálních hodnot. Při porovnávání skupiny pixelů lesní vegetace s ostatními povrchy jsou si pixely lesní vegetace podobné. (Helmer, 2012).

Nevýhodou družicových snímků při zkoumání zemského povrchu je oblačnost. V některých oblastech Země se vyskytuje velmi často a je složité zjistit stav land cover v dané oblasti. Proto se využívá scén stejného území jiného období, aby se tyto oblasti, které jsou zakryty mraky a stíny, vyplnily (Helmer, 2012).

### **2.3 Klasifikované třídy lesní vegetace**

K vytvoření 5 strukturních tříd lesní vegetace jsem se inspirovala díky projektu, na kterém spolupracovala Univerzita Karlova v Praze a Státní zdravotní ústav. Rozdělení do těchto pěti kategorií využila již ve své diplomové práci Červená (2012). Vycházela z práce Daniela, Koláře a Beneše (1999), kteří se již dříve podíleli na projektu týkajícího se výzkumu rizika nákazy klíšťovou encefalitidou v rámci celého území České republiky. V tomto projektu byla nejdříve celá scéna klasifikována do 7 tříd, kde lesní vegetace byla zahrnuta ve 3 třídách (jehličnaté lesy, listnaté lesy a smíšené lesy). Nad těmito třídami byla vytvořena maska lesní vegetace a na zájmovém území provedena neřízená klasifikace, kdy vzniklo 9 tříd. Byly prozkoumány v terénu a botanikem definovány (1. Strukturně homogenní smrkové kultury, 2. Strukturně a druhově heterogenní jehličnaté porosty, 3. Smíšené porosty, většinou vysoké (kmeniny) a s převahou jehličnanů, 4. Listnaté křoviny s drobným zrnem porostní mozaiky, 5. Smíšené porosty, většinou nízké (mlázi a tyčoviny) a s převahou listnáčů, 6. Strukturně silně heterogenní mladé listnaté porosty a prostní rozhraní (ekotony), 7. Strukturně homogenní listnaté tyčoviny, 8. Strukturně homogenní listnaté kmenoviny, 9. Strukturně heterogenní listnaté kmenoviny). Klasifikované území pak posloužilo jako trénovací množina při řízené klasifikaci vztaženou na celou Českou republiku. Kvůli překryvům tříd v klasifikační legendě byly některé třídy sloučeny a upraveny jejich definice (Červená, 2012). Tak vzniklo 5 klasifikačních tříd.

Klasifikační legenda je založena na strukturním rozdělení lesního porostu, nikoliv na druhovém. Toto rozdělení může posloužit k již zmíněnému mapování nákazy rizika klíšťovou encefalitidou či lymfskou boreliózou. Třídy mohou posloužit ke sledování jiných živočichů a

druhů organizmů, kteří jsou úzce spjati s těmito kategoriemi, jejichž výskyt ovlivňuje právě struktura lesní vegetace.

Zájmové území se nachází na rozmezí Středočeského a Jihočeského kraje. Třídy jsou rozlišitelné na snímcích družice Landsat 8. Při vyšším počtu tříd by nemusela být správně provedena klasifikace z důvodu omezených možností družice Landsat 8, a to hlavně kvůli prostorovému rozlišení senzoru OLI (30 m – všechna pásma kromě panchromatického).

Prvotní trénovací množiny byly odebrány průzkumem v terénu. Jelikož jich byl nedostatek, tak některé byly získány z pozorování ortofotomapy geoportálu ČÚZK. Vizuelní porovnání korun stromů a sledování spektrálních vlastností pásem bylo metodou pro sběr dat z ortofota. Níže jsou popsány a definovány třídy v klasifikační legendě.

- 1. Třída – Jehličnaté lesy.** Do této skupiny patří vzrostlé lesy smrkové, borovicové, jedlové a modřínové. Zástupci skupiny mohou být i mladé jehličnaté stromy, nikoliv však lesní školky. Zda se jedná o les smrkových monokultur či les se smíšenými druhy jehličnatých lesů, na tom nezáleží. Určitě je možné, že tyto stromy budou mít trochu odlišnou spektrální odrazivost, ale předpokládá se, že na základě trénovacích množin budou zařazeny do této skupiny.
- 2. Třída – Smíšené lesy.** Jde o vysoké kmeny stromů, které zahrnují jak listnaté, tak jehličnaté. Pestrá druhová skladba se může místo od místa lišit. Vždy by se mělo jednat o lesy, kdy je minimální složka jednoho typu (jehličnaté x listnaté) zastoupena 30 %. To znamená, že hranice pro uznání této kategorie je 30 % listnatých lesů a 70 % jehličnatých nebo obráceně.
- 3. Třída – Ekotony.** Struktury tohoto typu nejsou jednotné. Většinou se nacházejí na porostních rozhraních a převažují zde keřové druhy. Může se jednat o zarostlé sady, lesní školky či okraje lesů k polím nebo loukám. Tato kategorie je strukturně silně heterogenní a vyskytují se zde mladé listnaté porosty (mladé břízy, traviny, maliníky).
- 4. Třída – Strukturně homogenní listnaté lesy.** Skupina obsahuje převážně dospělé listnaté porosty, stromové patro je velmi husté a keřové není příliš výrazné. Většinou se jedná o udržované lesní kultury. Homogenní listnaté kmenoviny reprezentují dospělé listnaté stromy s velkou pokryvností stromového patra, pod nimiž není rozvinut keřový podrost.
- 5. Třída – Strukturně heterogenní listnaté lesy.** Jedná se o kategorii s vysokými listnatými porosty a nízkou pokryvností stromového patra. Mají mezi sebou velkoplošné porostní mezery, kde prosvítá keřové patro (Červená, 2012).

## 2.4 Klasifikace

Klasifikace krajinného pokryvu umožňuje dostupnost informací pro předpověď stavu rozmanitosti krajiny. Satelitní snímky jako téměř jediný zdroj nabízí průběžné údaje o vlastnostech odrazivosti Země a o pokrytí půdy na větších územích. Klasifikace se provádí na základě spektrálních pásem (kanálů) snímacích senzorů. Každý senzor obsahuje různý počet spektrálních pásem a každá družice zachycuje odlišné rozpětí elektromagnetického záření. Satelitní snímky mohou pomoci při interpretaci rozdílů v krajinném pokryvu a využití půdy, které porovnávají rozdíly v odrazivosti různých spektrálních vlnových délek (NRMED, 2014). Existuje několik typů klasifikací (řízená, neřízená, objektová). Řízené a neřízené klasifikace mají nespočet možných algoritmů, podle kterých jsou data zpracovávána. Většinou se neřízená klasifikace využívá k přípravě dat, zatímco řízená již k samotné klasifikaci. Mnohem sofistikovanější metodou, kdy jsou třeba vlastní trénovací množiny, je řízená klasifikace.

### 2.4.1 Posuzování přesnosti klasifikace

Po samotném zařazení jednotlivých pixelů do tříd by se měla ještě ověřit kvalita klasifikace. Přesnost klasifikace se ověřuje tak, že jsou vybrány náhodné vzorky, které zhodnotí přesnost tříd odvozených od interpretace satelitního snímku. Většinou se hodnotí celková přesnost a vypočítá se Kohenova Kappa statistika, jež patří mezi nejběžnější metody ověřování (NRMED, 2014).

Celková přesnost se vypočítá jednoduše vydělením počtu správně klasifikovaných pixelů do tříd celkovým počtem vzorově odebraných pixelů. Celková přesnost  $AC_O$ :

$$AC_O = \left( \frac{SQ_{CC}}{SQ_{TOT}} \right),$$

kde  $SQ_{CC}$  je celkový počet správně klasifikovaných pixelů

a  $SQ_{TOT}$  je celkový počet vzorkově odebraných pixelů

Kohenova Kappa statistika měří přebytky mezi mapou a skutečností. Pokud se Kappa index bude blížit jedné, dojde zde k dokonalé shodě. Hodnoty okolo nuly naopak předpovídají náhodnost (NRMED, 2014):

$$K = \frac{(d - q)}{(N - q)},$$

$d$  – celková hodnota správně zařazených v %

$q$  – odhadnutá hodnota správně zařazených v %

$N$  – celkový počet případů

Hodnota kappa indexu 0.5 představuje, že mapování je významné na 50% hladině spolehlivosti. Je důležité určit užitečnost mapovaných tříd pro interpretaci diverzitních indexů. V odborné literatuře se udává, že hodnota nižší než 0.7 bývá v DPZ neuspokojivá a tedy i nereprezentativní (NRMED, 2014).

## **2.4.2 Klasifikace vegetačního povrchu v praxi**

Heterogenita byla již dříve studována metodami dálkového průzkumu Země. Nemusí se jednat pouze o výzkum lesní vegetace, ale některé studie se zabývají celým povrchem na zájmovém území či se specializují na úplně jiný krajinný povrch. V této kapitole budou rozebrány některé již dříve publikované studie, které se podílely na klasifikacích z různých družicových systémů.

### **2.4.2.1 Klasifikace s použitím TM a MSS senzoru**

Moore a Bauer (1990) se zabývali heterogenitou lesa v severní Minnesotě pomocí snímků Landsat ze senzoru MSS, kde výsledky nebyly příliš detailní, jak zmiňuje Wolter et. al. (1995). Způsobilo to hlavně nízké prostorové a spektrální rozlišení. Prostorové rozlišení činí u MSS senzoru 80 m a spektrum záření je rozděleno do 4 kanálů. V té době se již na Landsatu 4 a 5 nacházel senzor TM s vyššími rozlišovacími schopnostmi, který je pro klasifikaci vhodnější. Thematic Mapper obsahuje 7 spektrálních pásem s prostorovým rozlišením 30 m. Pouze termální pásmo má 120 m.

Jak ještě vysvětluje Wolter et al. (1995), inspirovan prací Meda a Meyerse (1977), tak využití pouze jedné scény z družice Landsat MSS pro klasifikaci lesního porostu není dostačující.

Wolter et al. (1995) se snažil vytvořit co nejpřesnější klasifikaci lesa dominantních druhů a přehodnotit užitečnost snímků MSS senzoru. Proto ve své práci využil multispektrálního snímku družice Landsat TM v kombinaci se čtyřmi scénami Landsat MSS pořízenými v různých dnech na začátku léta. V této době dochází každý rok k největším fenologickým změnám individuálně u každého druhu jinak. Rozdíly ve spektrální odrazivosti lesa je způsobeno fenologickými odlišnostmi mezi druhy stromů. Rozlišit je můžeme díky pigmentům, jako jsou anthocyany (červenání listů), karotenoidy (oranžovění až žloutnutí listů), tanniny (hnědnutí) a xantophylly (žloutnutí) (Wolter et al., 1995).

Klasifikace byla provedena na 83 % scény Landsat na území státu Wisconsin v USA. Nejdůležitějšími spektrálními pásmy pro odlišení lesů a nelesů byly tři: 3., 4. a 5. Nejprve se povrch rozdělil do 22 krajinných typů, ale díky multitemporálním snímkům byly některé skupiny sloučeny a vzniklo výsledných 13 tříd. Celková přesnost klasifikace dosáhla 83.2 % a přesnost klasifikace lesa činila 80.1 %. (Wolter et al., 1995).

#### **2.4.2.2 Klasifikace v tropických oblastech**

Složitě rozlišitelné byly vzácné typy vegetací z družice Landsat 7 ETM+ v odborné práci Helmera et al. (2012). V tomto případě šlo o území tropických ostrovů Trinidad a Tobago o rozloze 5 133 km<sup>2</sup>. Hlavním důvodem vytvoření mapy pro společnost REDD+ (Reducing Emissions from Deforestation and Degradation) byl vzestupný proces odlesňování a jejich degradace na ostrovech Trinidad a Tobago. Tato organizace se zabývá distribucí lesa a dává finanční prostředky na ochranu biodiverzity.

Jednotlivé struktury lesní vegetace byly rozděleny podle hierarchického klasifikačního systému Bearda (1944), který již dříve klasifikoval přirozené lesy na těchto ostrovech. Třídy byly rozlišeny na základě fyziognomických vlastností. Pro málo se vyskytující třídy často chybí dostatek trénovacích množin. Každá trénovací data by správně měla reprezentovat spektrální rozpětí každé třídy a k tomu je potřeba tisíce potřebných trénovacích bodů. Ale vše záleží na velikosti modelového území a počtu klasifikovaných tříd. Zde bylo nasbíráno 241 trénovacích množin (Helmer, 2012).

Díky kombinaci více snímků byly odstraněny mezery nad oblastmi, kde se vyskytovala oblačnost a nahrazeny daty z jiných snímků. Bohužel nebyl nalezen žádný snímek s nulovou oblačností, a proto byla vytvořena maska lesa v programu IDL pomocí algoritmu, který ji dokázal identifikovat (Helmer, 2012).

Na klasifikaci aplikoval snímky z více ročních dob a různých let, čímž se pokusil rozlišit jednotlivé druhy stromů. Hlavním důvodem odlišení druhů byla různá doba opadání listů. Využil snímků z období sucha (odlišení lesů a nelesů) a dešťů (odlišení mokřadů). Díky snímku z 80. let byly rozeznány staré a mladé stromy. Klasifikace se zúčastnila všechna spektrální pásma a dalších šest vypočítaných spektrálních indexů (Tasseled cap - brightness, greenness, wetness, NDVI, NDSI a WBDI). Díky těmto charakteristikám vstupujícím do klasifikace bylo v tropických lesích rozlišeno několik kategorií a v rámci kontroly přesnosti klasifikace vyšly výsledky velmi dobře. Přesnost klasifikací se většinou pohybovala kolem 90 % (Helmer, 2012).

Problémem klasifikace lesního porostu byla přítomnost bylinného patra, které zde představovalo velké množství zeleně a kvůli němu docházelo k záměně s mladým lesem. (Helmer, 2012).

Gond et al. (2013) mapoval jinou tropickou oblast, a to africké lesy v povodí řeky Kongo. Lesy jsou strukturně velmi složité a rozličné, a proto byly špatně rozpoznatelné. Rozlišení opadavých stromů od hustých vždyzelených lesů nacházejících se na západě studované oblasti bylo největším problémem. Lesní typy se klasifikovaly dle spektrálních charakteristik v multitemporálním a multispektrálním snímku. Díky těmto pásmům pořízeným v různé době, a o různé vlnové délce, lze vytvořit třídy vegetací o určité typické charakteristice dané třídy. K diferenciaci mohou také napomáhat jiná environmentální data (topografická, geologická atd.), jak cituje Gond (2013) vědeckou práci Bohlmana (1998). Nebyly zde klasifikovány pouze lesy, ale celkově se pracovalo s 22 vegetačními typy (6 savan, 2 bažiny a 14 lesů). Neřízená klasifikace byla provedena na datech zachycených spektrometrem MODIS.

Kovacs et al. (2011) se ve své studii zabýval mangrovými lesy v okolí Teacapanu v Mexiku. Z klasifikovaného území pak ověřoval statistickými metodami její přesnost. Tato oblast již dříve byla mapována ze satelitního snímku dle jednoduššího klasifikačního schématu. Mapování probíhalo za účelem ochrany těchto lesů, protože mangrové stromy jsou jedním z nejohroženějších ekosystémů na Zemi. Dřívější studie mapování mangrových lesů byly řešeny na scénách Landsat a SPOT XS při prostorovém rozlišení 10 – 30 m. Bohužel kvůli jednodušším klasifikačním metodám v tehdejší době se neodlišily jednotlivé druhy mangrových stromů. Díky vývoji využil ve své práci složitějších klasifikačních systémů. Cílem bylo zdůvodnit degradaci mangrových lesů a osvětlit jejich strukturu a vliv změn v hydrologickém režimu. K tomu posloužila dříve provedená klasifikace degradovaných lesů při mapování ostrova La Palma pomocí scény Landsat 5 TM. Díky této klasifikaci byl navržen předběžný plán sběru dat v terénu. Mapování v terénu probíhalo během ledna 2007 a května 2008. Sběr dat byl zrealizován na 61 vzorkových oblastech. Na rozdíl od původní klasifikace, která prezentovala pouze jednu třídu mangrových lesů, byly nyní nově vytvořeny čtyři třídy - zdravý vzrostlý porost (17 oblastí), zdravé malé stromy (15), mangrovníky ve špatném stavu (13) a mrtvé mangrové lesy (16). Všechny stromy, vyskytující se v určité vzorkovací oblasti, patřily vždy do stejné třídy. V terénu se pak zaznamenala bazální plocha, průměrná výška stromů a průměr kmene. Navíc u každého stromu byl zjištěn druh (černé, červené či bílé mangrovníky) a byla zachycena i jeho poloha nástrojem GPS.

#### **2.4.2.3 Další klasifikace s využitím družicového systému Landsat**

Další příklad klasifikace vegetačního pokryvu je z práce Rodrigueze (2011), jenž použil klasifikátor Random Forest. Díky vlivu ročních období extrahoval objekty ze scény Landsat TM. Cílem práce bylo zjistit, zda pomocí klasifikátoru a vícesezónních snímků lze dojít k vyšší přesnosti klasifikace. Zájmovým územím byla oblast Granady (Španělsko). Celý proces by měl ale být aplikovatelný i na jiné oblasti v blízkosti Středozemního moře kvůli podobnému podnebí

a flóře. Problémem zájmového území je vysoké množství různých povrchů a jejich nízká odlišnost na družicovém snímku. Mapování fragmentované krajiny z Landsatu TM je proto velmi náročné. Rodriguez (2011) opakovaně kombinoval ve svém výzkumu více klasifikací z náhodných vzorků trénovacích množin při užití základního klasifikátoru. V nejlepším případě vyšla hodnota kappa koeficientu při užití Random Forest klasifikátoru 0.92 a při Maximum Likelihood 0.83. Přesnost klasifikace při aplikování multitemporálního snímku vyšla tedy velmi uspokojivě.

Zmíněný klasifikátor Random Forest by měl být přesnější než jiné algoritmy podobného typu, tvrdí Rodriguez et al. (2011), který čerpal z Breimana (1996). Breiman tento algoritmus představil v roce 2001 a nazval ho Random Forest. Algoritmus zvládne tisíce vstupních proměnných a odhaduje důležitost proměnných v klasifikaci. Pracuje na mechanismu, kdy máme soubor klasifikačních stromů, z nichž se každý podílí jedním „hlasem“ za postoupení nejčastější třídy vstupních dat.

Klasifikaci z multitemporálního snímku Landsat TM/+ETM také studoval Ionnis et al. (2011). Pracoval se snímky z letního období let 1986, 1999 a 2008 zachycující okolí města Thessaloniki. Použil řízenou klasifikaci a algoritmus Maximum Likelihood s 832 trénovacími množinami. Povrch byl klasifikován do 9 krajinných typů, mezi něž patřily i tři třídy lesů (jehličnaté, smíšené a listnaté). Byl zde proveden i výzkum změn land cover mezi lety 1986 a 2008. Kontrolní body zaměřené z GPS, nasbírané v zájmové oblasti, byly použity k ověření přesnosti navržených tříd. Celková přesnost dosáhla 85 %. Ukázalo se, že kombinace snímků z pozdního května s vrcholícím létem vykazuje nejvyšší přesnost klasifikace (Ionnis, 2011).

Neřízenou klasifikaci snímku Landsat TM použil ve své práci Read et al. (2011) při zjišťování změn land cover v oblasti nížin na Costa Rice. Využil snímky z let 1986, 1996 a 1997. Výsledkem klasifikace bylo 24 tříd zahrnujících 10 kategorií lesa, 9 pastvin, 3 orné půdy a 2 křoviny. Díky tomu byly vytvořeny třídy krajinného pokryvu. Následující prostorové analýzy byly aplikovány na neklasifikovaná data u každého spektrálního pásma a krajinného povrchu odděleně. Byla vypočtena prostorová autokorelace, fraktální dimenze, Shannonův diverzitní index, contagion index a fraktální dimenze z poloměr/plocha. Díky deskriptivní statistice bylo zjištěno, že nejmenší rozdíly mezi hodnotami pixelů se vyskytují v rámci lesa. Zatímco u zbylých 3 tříd jsou velké variace. Pixely, prezentující lesní vegetaci, představují homogennější prostředí než ostatní kategorie.

Tato kapitola uvedla několik publikovaných prací, které se zabývaly klasifikací zemského povrchu, převážně lesní vegetace. Je zjevné, že ve většině odborných studií převažovala řízená klasifikace se sběrem dat v terénu, s daty ze starších prací či sběrem trénovacích množin z ortofotomap. Tvorba tříd lesní vegetace byla pojata různými způsoby. Například mangrové lesy v případě Kovace et al. (2011) byly nejdříve stratifikovány na základě jejich zdravotního stavu. Až při samotném terénním průzkumu se zjišťovalo, o jaký druh stromu šlo. Helmer et al.

(2012) naopak provedl klasifikaci na základě fyziogomických vlastností (např. jehličnaté x listnaté).

Většina případů zpracovávala snímky z družice Landsat. Byly uvedeny některé příklady při užití MSS, TM a +ETM senzoru. Jak uvádějí autoři, tak lepší výsledky vzešly ze senzorů s vyšším prostorovým a spektrálním rozlišením. Z výše popsaného je užití jednoho či více snímků rozhodujícím faktorem. Proto budou klasifikace v této práci provedeny na základě obou možností.

## 2.5 Prostorové analýzy

Velké množství oborů využívá ve svém výzkumu analýzy prostoru. Slouží ke stanovení vlastností, které závisí na rozmístění jednotlivých územních celků. Aplikovat tyto metody můžeme například v ekologii pro získání informace o složení druhů jednotlivých organismů v oblasti. Právě tyto prostorové statistiky poskytují nástroje, s kterými se dají tyto vzorky analyzovat. Prapůvod prostorových analýz sahá k důlnímu inženýrovi z Jihoafrické republiky D. W. Krigemu, který poprvé použil metodu interpolace kriging.

V této kapitole budou teoreticky popsány možné metody prostorových analýz a jejich praktické využití v oblasti dálkového průzkumu Země.

### 2.5.1 Teorie prostorové autokorelace

První zákon geografie říká: „*Všechno se vztahuje k něčemu, ale bližší věci jsou si blíže než vzdálenější věci.*“ (Tobler, 2014). Tato fráze souvisí s prostorovou autokorelací, která je založena na vzdálenosti. Například u vegetace je obvyklé, že výskyt rostlin je podobnější na místech prostorově si bližších. Prostorová autokorelace nabývá hodnot -1 až 1 a rozumí se jí vztah proměnné, která je v korelaci se sebou samou. A je prostorová, protože je postavena do prostoru (Zuur, 2005).

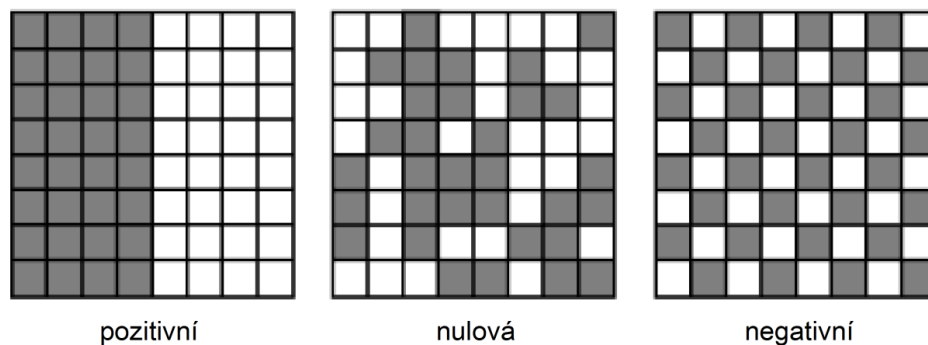
Prostorová autokorelace se může vypočítat u bodových i u plošných dat. U bodových je důležitá přesná poloha každé jednotky, zatímco plošná data jsou zaznamenána v určitých pravidelných či nepravidelných formacích. Klíčovými komponenty prostorových dat jsou atributy, které obsahují neprostorové informace, a polohová data (nesou informace o poloze) (Root, 2011).

### 2.5.2 Základní informace o prostorové autokorelaci

„*Prostorová autokorelace je závislost výskytu určitého jevu v prostoru na výskytu tohoto jevu v blízkém okolí – porušení základního předpokladu obecného lineárního modelu a řady standardních parametrických statistických testů, že jednotlivá pozorování jsou navzájem nezávislá či nekorelovaná*“ (Spurná, 2008). Otázkou je, zda výskyt nějakého určitého jevu

v jednotce plochy dokáže ovlivnit výskyt tohoto jevu v jeho blízkém okolí. Chceme zjistit, zda je mezi daty prostorová závislost, tedy jestli vykazují prostorovou autokorelaci (Spurná, 2008). Všechny definice ale vycházejí z 1. Toblerova zákona.

Mohou existovat tři základní projevy prostorové autokorelace. Na *obrázku 1* se nachází rastr s jejím možným uspořádáním (ve shlucích, náhodně či rozptýleně). Většinou když jsou prvky ve shlucích, tak se jedná o pozitivní prostorovou autokorelaci. Pokud jde o uspořádání, kdy sousední hodnoty jsou odlišné, a prostorové rozložení se podobá šachovnicovému vzoru, pak se zde projevuje negativní prostorová autokorelace. U náhodného uspořádání se nevyskytuje žádná prostorová autokorelace.



**Obr. 1: Prostorová autokorelace**

(Zdroj: vlastní tvorba v programu ArcGIS 10.2)

Její výpočet se provádí pomocí matic (binární nebo stochastické), kdy každá jednotka představuje 1 řádek a 1 sloupec. Binární matice je nejjednodušším typem diskrétní matice, která obsahuje v řádku počty sousedů dané plochy. Jsou zde zaznamenány hodnoty 0 (nesousedí - bez společných hranic) a 1 (přímo sousedí) (Langer, 2007). U stochastické matice jsou standardizované řádkové vazby a jedničky jsou nahrazeny vahou, která je určena poměrem mezi hodnotou a počtem sousedů. A jaký je rozdíl mezi binární a řádkově standardizovanou maticí? Na *obrázku 2 a)* je zobrazena binární matice a na *2 b)* řádkově standardizovaná matice (Root, 2011).

Pozorování 1 má souseda 2  
 Pozorování 2 má sousedy 3 a 4  
 Pozorování 3 má sousedy 1 a 2  
 Pozorování 4 má sousedy 2, 3 a 4

0	1	0	0
0	0	1	1
1	1	0	0
0	1	1	1

0	1	0	0
0	0	.5	.5
.5	.5	0	0
0	.33	.33	.33

**Obr. 2 a)**

**b)**

**Binární a řádkově standardizovaná matice**

(Zdroj: vlastní tvorba v programu ArcGIS 10.2)

### 2.5.3 Bodové a plošné prvky prostorové autokorelace

Již zde bylo zmíněno, že prostorová autokorelace se může provádět u bodových i plošných prvků. Blízké body k výchozímu bodu jsou ty, které jsou blíže než ostatní. Většinou se stanoví určitá vzdálenost, do které jsou si body blízké. Plošné ekvivalenty využívají topologie, kdy jsou si blízké pouze ty jednotky, které spolu přímo sousedí. Vzdálenost je vhodnou vahou (nejčastěji euklidovská vzdálenost) pro definování prostorových vztahů, ale existuje mnoho metod pro určení vzdálenosti (např. pomocí centroidů) (Langer, 2007).

V této práci se bude pracovat s plošnými prvky, které reprezentují území obce či ORP. Prostorovou autokorelaci můžeme zkoumat skrze globální a lokální míry. U globálních měr je vypočtena 1 hodnota pro celé studované území, zatímco u lokálních se vyčísluje více hodnot pro menší územní celky. V druhém případě chceme zjistit, kde je prostorová autokorelace silnější.

### 2.5.4 Indexy pro výpočet prostorové autokorelace

Možností pro měření míry prostorové autokorelace je hned několik. Mezi nejznámější metody patří Moranův a Gearyho index. Dnes se ještě využívá Join Count analýzy nebo Getis - Ord General G statistiky. Díky těmto globálním analýzám získáme celkový pohled na daný region. Nejčastěji se vyjadřuje právě Moranovým indexem, kde v globální variantě mohou zmizet významné rozdíly mezi dílčími územími (Spurná, 2008).

Proto se v dnešní době ale prakticky více využívají lokální varianty autokorelačních statistik LISA (Local Indicators of Spatial Autocorrelation) – lokální Moran I a Geary G. V případě globální úrovně je výstupem pouze jedna hodnota statistického ukazatele, která platí pro celou zkoumanou oblast. Metoda LISA je přínosnější z hlediska zřetelnějšího zobrazení oblastí s vyššími a nižšími hodnotami, které můžeme vizualizovat v kartogramu (Spurná, 2008).

Lokální ekvivalent Moranova indexu prezentuje součet všech indikátorů, který je úměrný globální variantě. Podává nám podrobnější a přesnější informace než globální analýzy. V sociální geografii se využívá například při určování cen nemovitostí, zkoumání kriminálních činů či výzkumu sítí školských zařízení (Root, 2011).

#### 2.5.4.1 Join Count statistika

Tuto metodu lze aplikovat pouze na binární data, kde polygon buď má či nemá danou vlastnost (např. kandidát vyhrál/prohrál volby). Je založena na porovnávání vlastností polygonů, které vzájemně sdílejí hranice. To vylučuje všechny nesousedící polygony, a proto je prostorová autokorelace limitována. Proto se využívá Moranova indexu, který porovnává hodnoty mezi dvojicemi polygonů do stanovené vzdálenosti.

### 2.5.4.2 Moranův index

Moranův index je jeden z nejstarších indikátorů prostorové autokorelace, jenž vyvinul P. A. P. Moran v roce 1950. Porovnává hodnotu rozptylu určité vlastnosti v oblasti s hodnotami v jejím okolí. U Moranova indexu se zjišťuje, zda existuje statisticky významný rozdíl mezi hodnotou indexu a hodnotou očekávanou. Globální varianta se vypočítá (Spurná, 2008):

$$I = \frac{\sum_i \sum_j w_{ij} c_{ij}}{s^2 \sum_i \sum_j w_{ij}}$$

$$c_{ij} = (z_i - \bar{z}) \cdot (z_j - \bar{z}) \quad a \quad s^2 = \frac{\sum_i (z_i - \bar{z})^2}{n}$$

$i, j$  – indexy charakterizující nějaké 2 jednotky

$z_i$  - hodnota proměnné v jednotce  $i$

$z_j$  – hodnota proměnné v jednotce  $j$

$\bar{z}$  - aritmetický průměr sledovaných proměnných

$n$  – počet analyzovaných jednotek

$w_{ij}$  – váhy aplikované k porovnání mezi oblastí  $i$  a oblastí  $j$

Moranův index je mírně upravená varianta Pearsonova korelačního koeficientu, kde se hodnota indexu pohybuje mezi -1 a 1. Pokud hodnota korelačního koeficientu roste, zvyšuje se i hodnota indexu. Hodnota -1 znamená velký stupeň rozdílnosti a negativní prostorovou autokorelaci, zatímco 1 reprezentuje shluky, kde je zkoumaná charakteristika dané oblasti stejná jako v jeho okolí. Při hodnotách blízkých 0 nejde o prostorovou autokorelaci (Spurná, 2008).

Lokální varianta Moranova indexu se vypočítá:

$$I_i = \frac{n \cdot (y_i - \bar{y})}{\sum_i (y_i - \bar{y})^2} \sum_j w_{ij} (y_j - \bar{y}),$$

$$pak I = \sum_i \frac{I_i}{n}$$

$I$  – míra Moranova indexu na globální úrovni

$I_i$  - míra Moranova indexu na lokální úrovni

$n$  – počet jednotek v mapě

### 2.5.4.3 Gearyho index

Gearyho index je inverzní k Moranovu indexu. Byl objeven o 4 roky později R. C. Gearym. Pro jeho výpočet se užívá stochastické nebo binární matice. Na rozdíl od Moranova indexu porovnává přímo hodnoty atributů mezi sebou. Hodnoty Gearyho indexu se teoreticky pohybují od nuly do nekonečna, v reálu je to však rozpětí 0 až 2. Vyjde vždy pozitivní z důvodu výskytu druhé mocniny v čitateli. Pokud jsou hodnoty indexu blízké 0, jde o pozitivní prostorovou autokorelaci. Naopak když se hodnoty pohybují kolem 2, jedná se o negativní. (Arthur, Lembo, 2008). V případě hodnot blízkých 1 nemají oblasti mezi sebou žádný prostorový vztah a autokorelace je nulová.

$$C = \frac{(n - 1) \left[ \sum_i \sum_j w_{ij} (x_i - x_j)^2 \right]}{2 \left[ \sum_i \sum_j w_{ij} (x_i - \bar{x})^2 \right]}$$

$C$  – Gearyho index

$x_i$  - hodnota proměnné v ploše  $i$

$x_j$  – hodnota proměnné v ploše  $j$

$\bar{x}$  – aritmetický průměr sledovaných proměnných

$w_{ij}$  - váhy

Moranův index je více globálního charakteru, zatímco Gearyho koeficient je citlivý na rozdíly v sousedství (Arthur, Lembo, 2008).

### 2.5.4.4 Getis – Ord General G

Getis – Ord General G analýza vyjadřuje prostorovou charakteristiku na globální úrovni, která je nástrojem v SW ArcGIS. Díky této analýze lze rozpoznat, zda se v dané oblasti shlukují vysoké nebo nízké hodnoty. Existuje i lokální varianta v ArcGIS nazývaná *Hot Spot Analysis*, která zdůrazňuje místa lokálního shlukování. Místo hot spot prezentuje místo s vysokou hodnotou, které je obklopeno také vysokými hodnotami, cold spot představuje to samé jen s nízkými číselnými údaji (ArcGIS Resources, 2014).

$$G = \frac{\sum_{i=1}^n \sum_{j=1}^n w_{i,j} x_i x_j}{\sum_{i=1}^n \sum_{j=1}^n x_i x_j}$$

kde  $i \neq j$

$G$  – Getis – Ord General

$w_{ij}$  – váhy

$x_i$  - hodnota proměnné v ploše  $i$

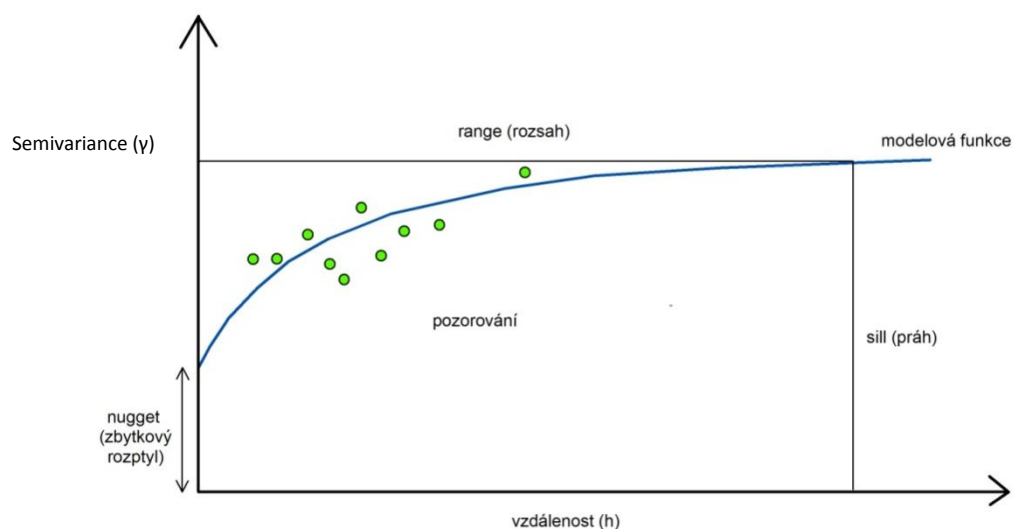
$x_j$  – hodnota proměnné v ploše  $j$

Při pohledu na rovnici vidíme, že jediným rozdílem mezi čitatelem a jmenovatelem jsou váhy. Z toho vyplývá, že výsledek je vždy nezáporný. Pokud váhy vychází z binární matice nebo budou její hodnoty menší než jedna, pak výsledek Getis – Ord General G se budou pohybovat v rozpětí od 0 do 1 (ArcGIS Resources, 2014).

### 2.5.5 Variogram, korelogram a kartogram

Prostorovou autokorelaci lze zachytit graficky. V mapě ji lze vizualizovat pomocí kartogramu, kde jsou dílčí územní celky vyznačeny například barevnou intenzitou dle vypočítaných indexů. Graf, v kterém jsou proti vzdálenostem vyneseny hodnoty prostorové autokorelace, se nazývá korelogram. Ve variogramu jsou naopak zaznamenány proti vzdálenostem semivariance (Glosová, 2013).

Empirický variogram má tři základní parametry: zbytkový rozptyl (nugget), prahovou hodnotu (sill) a dosah (range). Prahovou hodnotou se rozumí plochá část variogramu a ukazuje celkový rozptyl dat. Dosah je vzdálenost, od které se hodnota semivariance nemění. Vzdálenost na ose  $y$  mezi nulou a zachycenou hodnotou  $y$  představuje zbytkový rozptyl (Glosová, 2013).



**Obr. 3: Empirický variogram**

*(Zdroj: vlastní tvorba v programu ArcGIS 10.2)*

Pro vykreslení varigoramů či korelogramů se musí nejdříve spočítat matice vzdáleností (vzdálenosti všech objektů navzájem) a následně dvojice objektů rozřadit do vzdálenostních tříd. Všechny dvojice bodů, nacházející se v daném intervalu vzdálenosti, jsou reprezentovány hodnotou 1. Ty dvojice, které danému intervalu vzdálenosti neodpovídají, se označí v matici hodnotou 0. Pomocí těchto matic se pak vypočítají korelační koeficienty pro všechny dvojice v rámci každého intervalu vzdálenosti. (Zuur, 2005). Autoři doporučují využít Sturgesova pravidla ( $k = 1 + 3,3 \cdot \log(m)$ ) pro zvolení vhodného počtu tříd. Symbol  $k$  představuje počet tříd a  $m$  je celkový počet dvojic. Třídy se mohou rozdělit na úseky o stejné vzdálenosti, kdy maximální pozorovanou vzdálenost vydělíme počtem tříd a získáme požadovaný interval. Další možností je rozdělení intervalů o shodném počtu párů. První z těchto možností se užívá častěji (Glosová, 2013).

## 2.6 Biodiverzita a indexy

Tato kapitola obecně probírá význam biodiverzity a způsob jejího výpočtu. Rozebere se teoretická stránka Shannonova indexu a princip, na kterém funguje.

### 2.6.1 Biodiverzita v dálkovém průzkumu Země

Definice biodiverzity se shodují na tom, že je to pestrost živé přírody v krajině. U většiny případů platí, že na větších územích je i vyšší biodiverzita. Vše závisí na měřítku. Výzkum se může provádět na více úrovních (organismus, druh, ekosystém) (NRMED, 2014).

Vztah mezi strukturou krajiny a rozmanitostí ekosystému mohou posuzovat metody dálkového průzkumu Země. Klasifikace satelitního snímku poskytuje užitečný pohled na data z hlediska spektrálních charakteristik. Indexy biodiverzity mohou být aplikovány na klasifikovaná či neklasifikovaná data. V případě neklasifikovaných dat se očekává velké množství unikátních hodnot pixelů, což nepředstavuje vypovídající hodnotu o biodiverzitě. Každá unikátní hodnota pixelu by pak prezentovala typ stanoviště v krajině.

Využití indexů k charakteristice neklasifikovaných dat DPZ není příliš rozsáhlé. V tomto směru se využívají tři běžné prostorové indexy k charakteristice klasifikované krajiny a těmi jsou Shannonův diverzitní index, contagion index a fraktální dimenze z obvod/plocha (Read, 2002). Díky těmto indexům můžeme zjistit nejen absolutní složení struktur lesní vegetace, ale i její relativní četnost (Gross, 2000).

Dle mého názoru je vhodnější provést před výpočtem indexu na datech klasifikaci, která rozřadí pixely do menšího množství tříd. V této práci bude biodiverzita zkoumána na základě klasifikovaných dat.

## 2.6.2 Shannonův diverzitní index

Shannonův index je jedním z ukazatelů struktury společenstva. Prezentuje se jako množství zástupců každé třídy (v našem případě počty pixelů) a zároveň také jako rovnoměrnost rozložení jednotlivých tříd (Gross, 2000).

Představuje pravděpodobnost, k jakému druhu patří náhodně vybraný jedinec z počtu druhů  $s$  při celkovém počtu jedinců  $N$ . Shannonův index diverzity podává informaci o bohatství stanovišť (počtu typů) a jejich vyrovnanosti (relativní poměr krajinných prvků v každém typu). Rozmanitost je měřena krajinnou kompozicí (ČZU SKRIPTA, 2014). Podíl druhů  $i$  v poměru k celkovému počtu druhů ( $P_i$ ) je vypočítán a poté vynásoben přirozeným logaritmem tohoto poměru ( $\ln P_i$ ). Výsledek je sečten se všemi ostatními druhy a vynásoben -1:

$$S = - \sum_{i=1}^s P_i \cdot \ln (P_i)$$

$$S = - \sum_{i=1}^s \left(\frac{n_i}{N}\right) \cdot \ln \left(\frac{n_i}{N}\right)$$

kde  $s$  – počet druhů pokryvu

$P_i$  - podíl plochy obsazený typem povrchu  $i$ , v ekologii podíl jedinců patřící

k  $i$ - tému druhu v datovém souboru zájmu

$S$  – Shannonův diverzitní index – pohybuje se od 0 do nekonečna

$n_i$  – počet jedinců náležejících  $i$ -tému druhu z počtu druhů  $s$  ve vzorku s celkovým počtem

jedinců  $N$

$N$  – celkový počet jedinců

V oblasti, kde se vyskytuje pouze jeden druh pokryvu, bude hodnota nulová. Dosažení maxima se získá za předpokladu, že všechny přítomné druhy jsou zastoupeny stejným počtem jedinců (rovnoměrné rozdělení) (Dvořák, 2005). Čím se bude vyskytovat více typů povrchu, tím poroste i hodnota indexu. Například v komunitě 10 druhů, kde je každý druh zastoupen stejným počtem, je  $P_i = 0,1$  pro každý druh. Ve společenství s 10 druhy, u nichž jeden druh má 90% zastoupení jedinců ( $P_i = 0,9$ ) pro dominantní druh, je 10% zastoupení pro ostatních 9 druhů ( $P_i = 0,01$ )(Gross, 2000).

Při výpočtu Shannonova indexu se velmi často vypočítá i Shannonova vyrovnanost ( $E_H$ ). Předpokládaný výsledek se pohybuje mezi 0 a 1, kde 1 znamená úplnou vyváženost.

$$E_H = \frac{S}{H_{max}} = \frac{S}{\ln s}$$

$s$  – počet druhů

$H_{max}$  – maximální (teoretická) hodnota diverzity

Existují i další biodiverzitní indexy fungující na podobných principech (Simpsonův, Margalefův či Menhinickův). Shannonův se jeví jako nejlepší kandidát, a proto bude zpracován v praktické části.

## **2.7 Metody prostorové autokorelace a krajinných metrik v DPZ**

V této kapitole jsou rozebrány dříve publikované studie, které se nějakým způsobem zabývaly prostorovými analýzami či krajinnými metrikami z družicových či leteckých snímků. Jejich autoři se většinou snažili prokázat svoji teorii, avšak některé studie nevyšly úspěšně. Jsou zde uvedeny obě varianty.

### **2.7.1 Prostorové metody pro charakterizaci land cover a detekci změn v tropech**

Nejprve si rozebereme podrobně odbornou práci Reada (2001), který porovnával různé metody prostorových analýz a krajinné indexy na neklasifikovaných datech z Landsat TM na severovýchodním území Costa Ricy. Tato oblast je charakteristická nížinatými lesy a zemědělskou krajinou. Nezabýval se pouze lesní vegetací, ale do výzkumu právě zahrnul i jiné kategorie krajinných pokryvů. Cílem práce bylo zjistit, zda pomocí těchto metod lze zkoumat fragmentovanou krajinu a zda lze zachytit vliv lidské disturbance. Měl k dispozici tři scény z let 1986, 1996 a 1997. Read (2001) nejdříve provedl neřízenou klasifikaci, podle níž zařadil pixely do čtyř kategorií (lesy, křoviny, pastviny a orné půdy). Prostorové analýzy aplikoval na neklasifikovaná data v rámci každé třídy zvlášť. Tento proces provedl u všech pásem a u vegetačního indexu NDVI.

Hypotéza zněla, že roztržitost krajiny v přírodě klesá s rostoucím vlivem lidské aktivity. Mezi aplikované prostorové analýzy patřila fraktální dimenze z izarytmických linií a z trojúhelníkové hranolové plochy, dále pak grafické zobrazení pomocí variogramu a prostorová autokorelace vyjádřena prostřednictvím Moranova indexu. V práci jsou vypočteny i některé krajinné indexy (Shannonův index diverzity, contagion index a fraktální dimenze z obvod/plocha). Ty vypočítal přímo z neklasifikovaných dat a pracoval se samotnou hodnotou pixelu.

### 2.7.1.1 Fraktální dimenze

První zmíněnou metodou prostorových analýz jsou fraktály. Ty si zakládají na konceptu fraktální dimenze, která se zabývá tvarem a složitostí objektů. Své využití má při výzkumu určitých přírodních typů krajín, jako jsou například pobřežní linie (Read, 2001). Každý fraktál je soběpodobný. Soběpodobnost je vlastnost objektu, kde jeho libovolná část je podobná jiné části objektu při jiném rozlišení (např. list kapradiny). Tento jev se často vyskytuje v přírodě.

Protože jsou fraktály na měřítku nezávislé, jsou také porovnatelné. Při složitějším tvaru linie či hranic objektu bývá i vyšší fraktální dimenze. Různé měřítko se využije při sběru dat dálkového průzkumu Země ze senzorů, kdy jsou data porovnávána. Těmto fraktálům se říká pravé fraktály, většina z nich ale v přírodě není čistě fraktální (Hinner, 1999).

V Readově (2001) výzkumné práci byla fraktální dimenze zachycena již zmíněnými třemi metodami. Předchůdci Readova (2001), kteří se zabývali izarytmickou metodou byly Lam (1997) a Clarke (1986). Clarke (1986) ji kritizoval z důvodu, že výsledky závisí na hodnotách izarytmů a jejich intervalech. Clarke (1993) se kromě fraktálů zabýval i modifikovanou trojúhelníkovou plochou. Lam et al. (1997) studoval fraktály prostřednictvím variogramu, ale došel k závěru, že pro data dálkového průzkumu je tato metoda nevhodná. Ukazovala totiž vyšší dimenzionalitu než topografická plocha (Read, 2001).

Výsledek ukázal, že s klesajícím gradientem fraktální dimenze roste vliv lidské aktivity (lesy – křoviny – pastviny – orná půda).

### 2.7.1.2 Prostorová autokorelace

Prostorová autokorelace je podle Cliffa et al. (1973), jehož zmiňuje Read (2001), na měřítku závislá statistika. Tvrdí také, že mezi prostorovou autokorelací a fraktální dimenzí je inverzní vztah. Složitější hranice objektů (vyšší stupeň dimenzionality) souvisí s nízkým stupněm shlukování (nízké hodnoty Moranova indexu) (Read, 2001).

Výsledek Moranova indexu u lesní vegetace je reprezentován nižší hodnotou pozitivní prostorové autokorelace u všech netermálních pásem. V případě lesního porostu bylo prostorové rozmístění pixelů spíše náhodné než ve shlucích. Ostatní krajinné typy jako pastviny, křoviny a orná půda vykazovaly větší míru shlukování, jelikož výsledky Moranova indexu byly vyšší než u lesa. Tyto hodnoty byly prokázány v 6. pásmu (termální 10.42 – 12.5  $\mu\text{m}$ ) u všech tříd. Naopak u 7. spektrálního pásma (2.08 – 2.35  $\mu\text{m}$ ) vyšly pouze nízké hodnoty.

Inverzní vztah mezi prostorovou autokorelací a fraktály byl dokázán. Fraktální dimenze vyšla nízká pro shlukovaná data a vysoká více u fragmentovaných.

### 2.7.1.3 Krajinné metriky

Shannonův diverzitní index patří mezi krajinné metriky, jež se využívají v krajinné ekologii k charakteristice druhů, komunit a prostředí v krajině. I tyto metody jsou v případě Readovi práce (2001) aplikovány na neklasifikovaná data družicového snímku. Každá unikátní hodnota pixelu představuje jeden typ povrchu. Na data byl kromě Shannonova diverzitního indexu aplikován také contagion index a fraktální dimenze z obvod/plocha.

Shannonův diverzitní index byl již podrobně popsán v předchozí kapitole, takže jen stručně zopakují, že se zabývá mírou rozmanitosti, která kombinuje informace o bohatosti prostředí (počet typů) a vyrovnanosti (relativní poměr krajiny v každém typu).

V odborné studii Read (2001) prezentuje bohatost jako počet odlišných hodnot pixelů na zájmovém území. Shannonův index vykazoval vysokou variabilitu a rozmanitost z důvodu velkého množství různých hodnot pixelů. Lesní vegetace ji měla ze všech krajinných typů nejnižší, a to ve všech spektrálních pásmech. Nejvyšší hodnoty byly zaznamenány u pastvin a křovin. Velmi proměnlivé výsledky byly u 4. pásma a NDVI ve všech krajinných typech.

Dalším krajinným indexem je contagion index (C). Ten je široce využíván při zjišťování stupně shlukování a fragmentace prvků v krajině (Read, 2001). Rovnici vytvořili Li a Reynolds (1993) :

$$C = \frac{1 + \sum_{i=1}^m \sum_{j=1}^m P_{ij} * \ln(P_{ij})}{2 * \ln(m)}$$

$P_{ij}$  = pravděpodobnost, že 2 sousední pixely náhodně vybrané jsou prvky typů  $i$  a  $j$

Index je 100%, právě tehdy když jsou všechny pixely rovnoměrně rozmístěny vůči sobě na základě rozdělení dle krajinných typů (McGarigal a Marks, 1994). Tento index ukázal na to, že kategorie lesy a orné půdy mají tendence ke shlukování (Read, 2001).

### 2.7.1.4 Porovnání výsledků prostorových analýz a krajinných indexů

Read (2001) došel k závěru, že vysoké spektrum hodnot neklasifikovaných pixelů není vhodnou volbou pro výzkum. Dostačujícími charakteristikami se staly informace z fraktální dimenze a prostorové autokorelace. Krajinné metriky zde nevyužívají absolutních hodnot pixelů ani rozdílů mezi jejich hodnotami, ale jednoduše jen odlišnost od ostatních pixelů. Proto se jeví nepříznivě. Naopak prostorové analýzy využívají obou možností a prostorového uspořádání pixelů.

Moranův index má v sobě potenciál pro větší (regionální a globální) plochy. Read (2001) tvrdí, že by mohl být využit u klasifikovaných dat s odlišným stupněm antropogenního

vlivu. Nesmíme zapomínat, že kdyby se nejednalo o nížinaté území v tropech, kde vliv sezónnosti je minimální, měl by i tento efekt být zpracován v datech. Například tím, že porovnávané snímky budou ze stejného ročního období či podobných podmínek. Problémem může být sněhová pokrývka či fenologická odlišnost. Dále pak doporučuje výzkum zpracování dat transformací PCA (Principal Component Analysis) a Tasseled Cap. Tvrdí, že by se měl brát v potaz také vliv biotických a abiotických faktorů (topologie, hydrologie, fenologie, geologie atd.).

### **2.7.2 Další příklady využití prostorové autokorelace**

Případem, kde se prostorová autokorelace neprojevila, byl výzkum Lianga et. al. (2009). Zájmovou oblastí byly smíšené lesy NP Chequamegon v severním Wisconsinu, kde se klasifikace provedla na základě fenologických vlastností lesní vegetace. V rámci jednotlivých druhů zde nebyla prostorová autokorelace detekována. Tato prostorová charakteristika zřejmě nebyla potvrzena z důvodu velké různorodosti malých mikroprostředí.

Rodriguez et al. (2011) také zpracovával klasifikaci lesní vegetace, kde se poté zabýval prostorovou autokorelací. V tomto případě byla ale zkoumána v jednotlivých spektrálních pásmech na třech prostorových měřítkách, která byla závislá na velikosti a tvaru jednotlivých objektů. Byla postavena na výpočtu texturního měření na různých velikostech oken. Nebyla zachycena Moranovým indexem, ale graficky pomocí různých technik (rodogram, madogram, variogram, křížový variogram a pseudovariogram).

### **2.7.3 Další příklady Shannonova diverzitního indexu**

Kovacs et al. (2011) využil Shannonova indexu biodiverzity ke zjišťování změn rozložení mangrových lesů v průběhu let na území Mexika (Teacapán – Aqua). Terénním průzkumem byly vytipovány lokality a na nich zaznamenány základní údaje. Pro výpočet Shannonova indexu je důležitý počet stromů, jejich druh a zařazení do třídy (zdravý dospělý strom, zdravý malý strom, mangrovníky ve špatném stavu a mrtvé mangrovníky). Výzkum proběhl na 61 lokalitách.

Výsledek Shannonova indexu potvrdil, již předvídanou představu, že zde dochází k degradaci mangrových lesů a poklesu biodiverzity v této oblasti.

Byla zde potvrzena předpokládaná teorie degradace tohoto vzácného ekosystému. V kategorii zdravý vzrostlý porost byl zjištěn pokles hodnoty indexu z 1.1 (v případě zahrnutí všech stromů) na 0.63 (pouze živé stromy). Podobný pokles byl zaznamenán i v případě jiných lokalit.

## KAPITOLA 3

### 3 DATA A METODIKA

#### 3.1 Výběr analýz při výzkumu vztahů v prostoru

Analýzy v prostoru jsou významné díky svým schopnostem objevit skryté informace, které nejsou na první pohled zřejmé. Tyto prostorové analýzy, krajinné indexy a další ukazatele poskytují informace o míře heterogenity v prostoru. Jelikož se v této diplomové práci rozebírá krajinný pokryv lesního porostu, aplikuje se na data z družicových snímků Shannonův index biodiverzity a prostorová autokorelace.

Nejprve je ale důležité si říci, na jakých územních jednotkách budou tyto charakteristiky zkoumány. V rámci zájmového území, které se rozkládá částečně ve Středočeském a Jihočeském kraji, byla lesní vegetace porovnáвана na menších územních prvcích administrativního dělení České republiky. Administrativními stupni jsou úrovně ORP a správní území obcí. Velikosti těchto administrativních jednotek jsou vhodné pro výzkum prostorových charakteristik. Správní území obcí budou použita u prostorové autokorelace i Shannonova indexu, zatímco ORP pouze u Shannonova indexu. Počet pěti obcí s rozšířenou působností není vhodný na aplikování prostorové autokorelace. Nebylo by možné zde zachytit významná centra na lokální úrovni, kde dochází k závislosti.

Proč bylo vybráno administrativní členění na polygony? Rozdělení přírodních prvků na základě hranic katastrálních území obcí může posloužit k hodnocení přírodní krajiny v rámci každé obce. Jednotlivé obce jsou porovnatelné s ostatními. Z biologického hlediska pak výskyt určitých rostlin či živočichů, jež se specializují na určitou strukturu lesa, může být hodnocen v rámci katastrů. Lesní porost se mohl také rozdělit na pravidelně velká území nebo nejmenší územní jednotky - pixely. V tomto případě by výpočty způsobovaly velkou zátěž na hardware a software. Také si neuvědomuji další praktické využití výsledků.

Shannonův index se zde využije na třídy strukturně odlišných kategorií lesa. Výsledek napoví, v kterých oblastech zájmového území se nachází vyšší rozmanitost lesní krajiny. Řízenou klasifikací budou pixely zařazeny do jedné z pěti kategorií struktur lesního porostu. Tím ale dojde k omezení výsledku Shannonova indexu, kdy při vyšším počtu tříd by byly pravděpodobně rozdíly hodnot indexů mezi jednotlivými obcemi vyšší. Bude zde zhodnoceno rozložení tříd lesního porostu v rámci obcí a ORP. Pokud bude docházet k výrazné převaze určité třídy nad ostatními, tato kategorie se stane výrazně dominantní a prostředí se bude jevit homogenně. V rámci Shannonova indexu se vypočítá ještě Shannonova vyváženost, která se pohybuje v rozpětí hodnot 0 – 1 (1- úplná vyváženost).

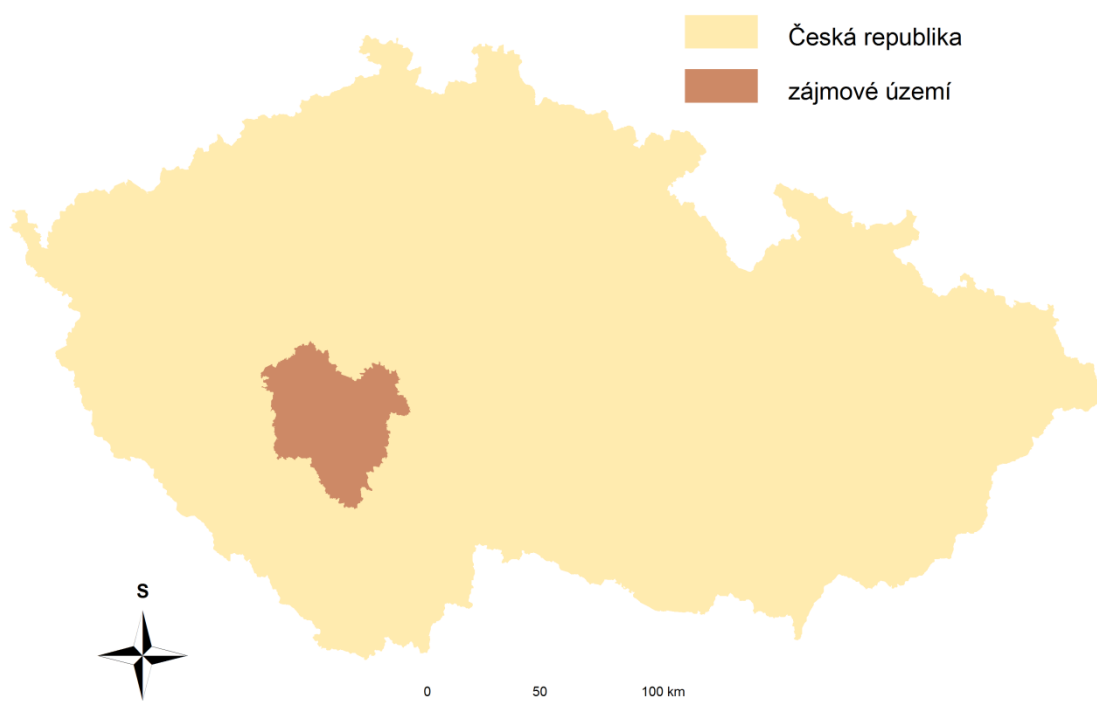
Prostorová autokorelace se bude zabývat naopak rozlohou ploch lesní vegetace na katastrálních územích v rámci každé třídy zvlášť. Výzkum může poukázat na lesní struktury, které mají v určitých místech tendenci ke shlukování.

Poslední způsob zpracování bude vyjádření Shannonova indexu pomocí prostorové autokorelace. Díky této analýze bude biodiverzita (vyjádřena 1 proměnnou pro každou obec) zkoumána z pohledu prostorové závislosti, kdy se výpočtu zúčastní všechny zájmové třídy.

### 3.2 Modelové území

Zájmovým územím je oblast pokrývající přibližně jednu třetinu snímku Landsat 8 o rozloze 2 775.4 km<sup>2</sup>. Na *obrázku 4* je zobrazeno umístění v rámci České republiky. Modelová oblast zahrnuje 5 obcí s rozšířenou působností na území Jihočeského a Středočeského kraje (Blatná, Milevsko, Písek, Příbram a Sedlčany). Všechny 5 ORP se skládá ze 198 správních jednotek obcí.

Nejdůležitější je ale rozsah lesní vegetace na tomto území, který činí 1 028.7 km<sup>2</sup>. Lesní porost tedy zaujímá na vybraném území více jak 1/3 jeho celkové rozlohy. Výběr modelového území vyplynul z již dříve provedeného terénního průzkumu, kdy bylo sebráno 22 trénovacích množin. Dalším důvodem bylo pestřejší složení lesů, než je tomu například v pohraničních pohořích. Tam je sice vyšší hustota zalesnění, ale většinu pokrývají smrkové monokultury.



**Obr. 4: Zájmové území**  
(Zdroj: vlastní zpracování v ArcGIS 10.2, 2015)

### 3.3 Snímky LANDSAT

Družicové snímky jsou v dnešní době zdařilým výtvozem lidstva, které mají mnoho výhod na rozdíl například od leteckých snímků nebo pozemního průzkumu. Oproti leteckým snímkům zaznamenávají družice mnohem větší území. Výhodou oproti terénnímu šetření jsou ještě levnější a časově méně náročné práce.

K výběru zpracování družic Landsat vedly dva důvody. Prvním byl fakt jednoduché dostupnosti, kde jsou na internetu snímky volně k dispozici. Druhým pak pokus o výzkum struktur lesní vegetace s prostorovým rozlišením 30 m.

Náhradou pro Landsat 5, Landsat 7 je Landsat 8, jenž byl vypuštěn na oběžnou dráhu předminulý rok. Provoz Landsat 5 byl ukončen v lednu 2013, pouze Landsat 7 stále běží, ale kvůli technickým problémům v květnu 2003 lze snímky využít pouze z 1/7 dat plné scény. Hlavním úkolem nového satelitu je pokračovat v zaznamenávání celého zemského povrchu (USGS, 2013).

Landsat 8 opustil zemský povrch 11. února 2013, ale plného provozu dosáhl až 30. května 2013. Tímto dnem byla převzata i starost o samotný provoz družice od NASA k Americké geologické službě. Její původní název zněl Landsat Data Continuity Mission (GISAT, 2014).

Označení pásma	Rozsah od [μm]	Rozsah do [μm]	Kódování spektrálního pásma	Prostorové rozlišení [m]
8 PAN	0.5	0.68	PAN	15.0
1	0.433	0.453	COASTAL	30.0
2	0.45	0.515	BLUE	30.0
3	0.525	0.6	GREEN	30.0
4	0.63	0.68	RED	30.0
5	0.845	0.885	NIR	30.0
9	1.36	1.39	SWIR	30.0
6	1.56	1.66	SWIR	30.0
7	2.1	2.3	SWIR	30.0
TIR1	10.3	11.3	TIR	100.0
TIR2	11.5	12.5	TIR	100.0

*Tab. 1: Spektrální pásma u družice Landsat 8 – senzor OLI  
(Zdroj: Gisat, 2014)*

Landsat 8 nese dva senzory – OLI (Operational Land Imager) a TIRS (Thermal Infrared Sensor). Senzor TIRS zaznamenává multispektrální tepelná data v rozlišení 100 m. Senzor OLI zachycuje 9 pásem, z toho osmé je panchromatické s rozlišením 15 m. Ostatní pásma mají

prostorové rozlišení 30 m. Landsat 8 OLI má 7 kanálů v rozpětí 0.433 – 2.3  $\mu\text{m}$ . Oproti Landsat 7 ETM+ obsahuje navíc dvě další pásma. Pásmo 1 je využíváno pro lepší detekci vodních zdrojů a zkoumání pobřežních oblastí. Pásmo 9, které se nachází v infračervené oblasti záření, slouží k detekci mraků typu cirrus. Zpracování se budou účastnit snímky z vegetačního období (jaro, léto). Podzimní a zimní scény nebyly využity z důvodu opadáných listů stromů, výskytu častější oblačnosti a sněhu (USGS, 2013).

Snímky Landsat jsou volně dostupné na stránkách USGS (U. S. Geological Survey), kde po rychlé registraci jsou všechny k dispozici. Bohužel většina z nich je pokryta velkým množstvím oblačnosti, proto se musí pečlivě vybírat, které snímky jsou pro výzkum vhodné. Landsat 8 mapuje stejné území pravidelně každých 16 dní. Proto může nastat problém, kdy není nalezen pro určitou lokalitu bezoblačný snímek v daném roce. V této práci byla lesní vegetace ohraničena maskou lesa, aby následné operace byly provedeny pouze nad lesy a nebyl zatěžován počítačový hardware. Jako maska lesa posloužila vektorová vrstva krajinného pokryvu lesní vegetace Corine land Cover 2006 z programu Corine zprostředkovanou European Environment Agency (EEA). Pravdou je, že rozdíl mezi využitými snímky a vrstvou CLC je sedm let. Předpokládalo se, že ke změnám dojde pouze v nepatrném množství.

Snímky získané z USGS byly ve formátu GeoTIFF a obsahovaly obrazy jednotlivých pásem a metadata k pořízenému snímku. Spojením všech pásem se docílilo multispektrálního snímku.

Pro provedení řízené klasifikace lesní vegetace na modelovém území byly použity 2 scény 191\_026 z družice Landsat z jarního a letního období (27. července 2013, 8. března 2014). V *tabulce 2* se nachází jejich parametry:

<b>parametr</b>	<b>8. 3. 2014</b>	<b>27. 7. 2013</b>
<b>Čas pořízení [UTC]</b>	2014:067:09:51:41.3550141	2013:208:09:53:06.6123500
<b>Název scény</b>	LC81910262014067LGN00	LC81910262013208LGN00
<b>Azimut Slunce [°]</b>	155.76766261	146.58558959
<b>Výška Slunce [°]</b>	33.69134601	56.86903768

**Tab. 2: Charakteristiky vybraných scén**  
(Zdroj: USGS, 2014)

Scény se úplně přesně nepřekrývaly, a proto byla část lesa, vyskytující se pouze na jedné scéně, odstraněna a nevstupovala do klasifikace. Červencový snímek navíc nad zájmovým územím obsahoval malé množství mraků, které byly odstraněny metodou řízené klasifikace a nebyly zahrnuty do celkové klasifikace lesní vegetace.

### **3.4 Použité softwarové programy (ArcGIS, ENVI, Geomatica)**

#### **3.4.1 Geomatica**

Pro prvotní zpracování družicových snímků byl využit program PCI Geomatica verze 9.1. a 2012. Vynalezena byla kanadskou soukromou společností založenou v roce 1982 se sídly v Torontu (Ontario) a v Gatineau (Quebeck). Jejich programy jsou prodávány do více než 135 zemí světa. Software pracuje jako ArcGIS for Desktop s geografickými daty, ale specializuje se na dálkový průzkum, prostorové analýzy, mozaikování a digitální fotogrammetrii. Najde se pro něj využití v mnoha oborech jako je zemědělství, lesnictví či životní prostředí (PCI Geomatics, 2014).

#### **3.4.2 SW ARCGIS**

Software ArcGIS for Desktop se využívá v geografických informačních systémech a je velmi populární. Byl vytvořen americkou firmou ESRI, Inc., jejíž vznik se datuje do roku 1969. Představuje jeden z nejúspěšnějších programů pro tvorbu map, editaci, jejich vizualizaci a analýzu (ESRI, 2014). Největší uplatnění má v územním plánování, správě dat a u analýz v dopravě. Moje data budou zpracovávána v modulu ArcMap ve verzi ArcGIS 10.2.

#### **3.4.3 ENVI**

Firma Exelis Inc (Exelis Visual Information Solutions), která vytvořila program ENVI, se zabývá vzdušným prostorem, obranou a servisními a informačními službami. Vznikla v říjnu 2011. Exelis má šest odvětví, na která se zaměřuje: vzdušný prostor, elektronické systémy, geoprostorové systémy, informační systémy a systémy pro mise a noční vidění a komunikace (EXELIS, 2012).

ENVI je počítačový software, který poskytuje nástroje a technologie pro lepší získání informací z dat a snímků k provedení lepšího rozhodování. Kombinuje pokročilá zpracování obrazu s osvědčenou technologií geoprostorových analýz.

### 3.5 Předzpracování dat

Jak již bylo výše napsáno, snímky byly získány ze serveru USGS, kde jsou volně dostupné. Jelikož se družice Landsat 8 objeví nad stejným územím vždy po 16 dnech, je někdy obtížné získat bezoblačné snímky, proto byl okruh snímků zúžen na dva, které jsou popsány v *tabulce 2*. Scény byly staženy v zazipovaném souboru, který obsahuje jednotlivá pásma ve formátu TIF a textový dokument s informacemi o nich. Na stránkách USGS bylo také zjištěno, že snímky Landsat 8 jsou již ortorektifikované a převzorkované kubickou konvolucí. Mapová projekce odpovídá polární stereografické projekci (Universal Transvers Mercator UTM – WGS World Geodetic System 84).

Snímky Landsat 8 odpovídají úrovni předzpracování Level 1T, které již v sobě zahrnují systematickou radiometrickou a geometrickou přesnost. Využívá se kontrolních bodů a digitálního modelu terénu pro topografickou přesnost. Geodetická přesnost závisí na přesnosti kontrolních bodů a rozlišení digitálního modelu terénu (kontrolní body z GLS 2000) (USGS, 2014).

Nové pásmo	popis
1	březen B1
2	březen B2
3	březen B3
4	březen B4
5	březen B5
6	březen B6
7	březen B7
8	březen B8
9	červenec B1
10	červenec B2
11	červenec B3
12	červenec B4
13	červenec B5
14	červenec B6
15	červenec B7
16	červenec B8

**Tab 3: Nová pásma a jejich prezentace**

*(Zdroj: vlastní zpracování, 2015)*

V SW PCI Geomatica 2012 v modulu Focus byla jednotlivá pásma spojena do formátu PIX. Pomocí nástroje *Merge* došlo ke spojení, kterého se zúčastnilo prvních 8 pásem z březnového i červencového snímku. Osmé a šestnácté pásmo je panchromatické, a proto mají

jiná prostorová rozlišení než ostatní. Výsledek byl uložen jako *Brez\_cerv.pix*. Geomatica 2012 měla totiž problém vyexportovat vrstvu ve formátu TIFF, kterou lze načíst v SW ENVI 5.0. Proto v SW ArcGIS 10.2 byla vrstva *Brez\_cerv.pix* vyexportována ve formátu TIFF. V tabulce 3 se nachází popis jednotlivých pásem po spojení.

Červencová část multitemporálního snímku obsahuje nad zájmovým územím nepatrné množství mraků, a proto muselo dojít k odstranění těchto ploch, aby nezasahovaly do samotného procesu klasifikace lesní vegetace. Navíc zde bylo také nalezeno území, které se nevyskytuje na březnovém snímku z důvodu posunutí snímků při pořizování.

Odstranění mraků a stínů bylo provedeno v programu ENVI 5.0 pomocí řízené klasifikace (*Classification Workflow*). Při zobrazení pásem v barevné syntéze 13 12 šlo velmi dobře odlišit mraky a stíny od zbytku krajinného pokryvu. Byly vytvořeny trénovací množiny pro třídy mraků, stínů, okraje, lesní vegetaci, ornou půdu, vodu a zástavbu. Výchozím algoritmem byl *Minimum Distance*.

Po vizualizaci bylo zhodnoceno, že klasifikace dobře kopíruje hranice polygonů stínů a oblaků, a proto byl výsledek vyexportován ve vektorové podobě. V SW ArcGIS byly vybrány pouze polygony z tříd *okraj*, *mraky* a *stíny* a byly vyexportovány. Z vrstvy *Lesy\_ORP* (vektorová vrstva lesů zájmového území z CLC) byly následně odstraněny rušivé elementy *okraje*, *mraky* a *stíny* pomocí nástroje *Erase*. Nakonec došlo k ruční editaci vrstvy *Lesy\_ORP*, která milně zahrnovala říční tok.

### 3.6 Trénovací plochy a kontrolní body

Z terénního průzkumu bylo získáno 22 trénovacích množin, které ale podle velikosti území nejsou dostatečně reprezentativní. Proto se muselo přejít k dalšímu kroku. V tomto případě se využilo WMS služby z geoportálu ČÚZK. Konkrétně se pro sběr dat využilo ortofota, z kterého se dala posuzovat lesní vegetace.

V modulu ArcMap 10.2 byl zobrazen multispektrální snímek ve spektrálních kombinacích 5 4 3 (březnová část), 13 12 11 (červencové pásmo) a ortofoto. Nyní se mohlo přejít ke sběru trénovacích množin a kontrolních bodů. Multitemporální snímek byl použit vždy v případě, kdy nešlo jednoznačně určit kategorii lesa. Nejvíce problematickou částí byly strukturně homogenní a heterogenní listnaté lesy. Proto byla využita trénovací množina strukturně heterogenního lesa, která byla ověřena terénním průzkumem. Oblasti jí spektrálně a vizuálně podobné byly zahrnuty do páté třídy. Ze zkušeností v terénu vyplynulo, že většina listnatých lesů má charakter strukturně homogenních lesů a strukturně heterogenní lesy se hledaly velmi těžko.

V tabulce 4 jsou zaznamenány počty a rozlohy nasbíraných plošek a bodů. Na první pohled je zřejmé, že první třída (jehličnaté lesy) se hledala snadněji, a proto zastupuje také nejvyšší

počet trénovacích množin. Předpokládalo se, že i jehličnaté lesy budou představovat největší rozlohu lesního porostu v zájmovém území.

třída	kontrolní body	trénovací plochy	počet pixelů
1	50	96	1685
2	30	65	404
3	30	45	223
4	40	70	727
5	20	35	350

**Tab 4: Trénovací plochy a kontrolní body**

*(Zdroj: vlastní zpracování, 2015)*

V příloze 7 se nachází mapa znázorňující oblasti nasbíraných kontrolních bodů a trénovacích ploch.

### 3.7 Řízená klasifikace

Po sběru trénovacích plošek nutných pro řízenou klasifikaci se přešlo k dalšímu zpracování. Do programu ENVI 5.0 byl naimportován multitemporální snímek *Brez\_cerv* a vektorové vrstvy *Lesy\_ORP* a *Trenovaci\_plochy*.

Pro zajímavost byla zde řešena i neřízená klasifikace. Pixely byly rozděleny do pěti kategorií při aplikování klasifikátoru ISODATA. Neřízené klasifikace se zúčastnilo 16 spektrálních pásem. Bohužel se při zhlédnutí výsledku zjistilo, že klasifikace nebyla příliš úspěšná a trénovací body, získané z terénu, nemají žádnou souvislost s novou klasifikovanou vrstvou.

Řízené klasifikace s kombinacemi různého počtu spektrálních pásem a přítomnosti různých klasifikačních algoritmů (Maximum Likelihood, Minimum Distance, Malahanobis Distance a Spectral Angle Mapper) zde byly provedeny. Byly také vypočteny klasifikace samostatně jen pro březnovou a červencovou scénu. Výsledky byly uloženy a připraveny na další zpracování.

### 3.8 Postklasifikační úpravy

Do modulu ArcMap verze 10.2 byly nahrány postupně všechny proběhnuté klasifikace, kontrolní body a multispektrální snímek *Brez\_cerv*. Na první pohled bylo zjevné, že výsledky při použití algoritmů *Mahalanobis Distance* a *Spectral Angle Mapper* neodpovídají hodnotám trénovacích ploch a kontrolních bodů. Proto byly tyto výsledky z dalšího procesu vyřazeny.

Přesnost klasifikace byla ověřena metodou chybové matice a vypočtením kappa koeficientu. Pro ověření se převedly klasifikace a *Kontrolni\_body* na rastr o prostorovém rozlišení 30 m, aby bylo možné je vzájemně porovnávat. Pomocí nástroje *Combine (Spatial Analyst)* byly konfrontovány překrývající se hodnoty tříd kontrolních bodů s řízenou klasifikací. Výsledkem tohoto nástroje byla vektorová vrstva s novými hodnotami. V atributové tabulce se nacházely dva sloupce s hodnotami ze dvou rastrů a celkový počet případů, kdy k jaké kombinaci došlo. Už zde můžeme vidět, které klasifikace vyšly přesněji. Nejlépe vyhodnocená klasifikace byla při zahrnutí všech spektrálních pásem a algoritmu maximum likelihood.

počet	kontrolní body - třída	klasifikace - třída
91	1	1
24	2	1
42	2	2
9	1	2
24	3	3
2	2	4
23	5	5
13	4	4
2	5	3
4	4	3
1	2	5
8	4	5
1	2	3
1	3	5

**Tab 5: Výsledky přesnosti řízené klasifikace algoritmem Maximum Likelihood multitemporálního snímku *Brez\_cerv.tif* při účasti všech spektrálních pásem**  
(Zdroj: vlastní zpracování v Microsoft Excel, 2015)

Z této tabulky bylo jednoduché vytvořit tabulku chybové matice. Nejprve se samostatně vyexportovala pomocí nástroje *Copy rows (Data Management)* a poté na ní byl aplikován nástroj *Pivot table (Data Management)*.

Výsledná tabulka byla zkopírována do SW Microsoft Excel, kde byla vypočtena celková přesnost a kappa koeficient. Tento proces byl proveden ještě samostatně u klasifikací pouze

červencového a pouze březnového snímku při užití algoritmů maximum likelihood a minimum distance. Šlo o zjišťování nejpřesnější klasifikace.

Nejpřesněji vyšla již zmíněná klasifikace při aplikování algoritmu maximum likelihood a přítomnosti všech spektrálních pásem. Proto na této klasifikaci došlo k odstranění nejmenších polygonů. Nástroj *Eliminate (Data Management)* spojil malé polygony o velikosti jednoho či dvou rastrů k sousedním podle délky hranice. Nakonec se vypočítala rozloha jednotlivých kategorií. Klasifikace byla upravena do formy mapového výstupu se všemi náležitostmi (*Příloha 8*).

### 3.9 Statistické metody

Z hlediska průzkumu heterogenity v rámci jednotlivých území obcí byl na data aplikován Shannonův diverzitní index a díky němu vyhodnocena rovnoměrnost rozložení tříd. Prostorová autokorelace byla vypočtena Moranovým indexem a analýzou Getis - Ord General G. Výpočty se provedly na globální i lokální úrovni modelového území.

#### 3.9.1 Metoda Shannonova diverzitního indexu

Shannonův diverzitní index byl vypočítán na úrovni ORP (5) a správních území obcí (198). Všechny úpravy byly provedeny v prostředí ArcGIS 10.2 a samotná statistika v Microsoft Excel 2007. Pro jeho výpočet je potřeba mít rozlohy za jednotlivé kategorie v obcích a ORP. Pomocí nástroje *Split* byla klasifikovaná lesní vegetace rozdělena podle hranic katastrálních území obcí a ORP. Vytvořilo se 198 vrstev lesní vegetace pro jednotlivé obce, které byly opětovně spojeny dohromady pomocí nástroje *Merge*. V atributové tabulce nové vrstvy *Lesy* byl vytvořen nový sloupec *Area*, kam byly vygenerovány rozlohy polygonů.

Pomocí funkce *Select by Attributes* byly vybrány všechny polygony, které se klasifikovaly jako třída 1 a vyexportovány jako samostatná vrstva. Stejný postup byl proveden na dalších čtyřech kategoriích lesní vegetace. Tyto plochy byly převedeny na body, na které byl aplikován nástroj *Spatial Join (Analysis Tools)*. Díky tomu byla vytvořena vrstva *Obce\_lesy2*. Ta obsahuje pět atributů s rozlohou jednotlivých tříd pro danou obec.

Atributová tabulka byla zkopírována do Microsoft Excel, kde byl vypočten pomocí vzorců popsaných v teoretické části Shannonův index a Shannonova vyrovnanost. Byly zjištěny relativní podíly jednotlivých tříd pro daná území a z nich poté Shannonův index a vyrovnanost. V případě malé obce Třebesko se na tomto území nevyskytovaly žádné lesy, a proto nemohl být vypočten Shannonův index pro tuto obec. V *příloze 3 a příloze 4* se pak nachází vypočtené

hodnoty za obce i ORP. Byl také vytvořen kartogram pro lepší vizualizaci výsledků Shannonova indexu (*Příloha 9*).

### 3.9.2 Analýzy prostorové autokorelace

Před samotnými výpočty prostorové autokorelace je důležité si uvědomit, jak fungují statistické testy. Základem je stanovit nulovou hypotézu, která v našem případě zní, že prvky jsou v prostoru uspořádány náhodně. O tom, zda tuto hypotézu zamítneme, rozhoduje p-hodnota a z-skóre. Pokud nulovou hypotézu zamítneme, jsou prvky uspořádány rozptýleně nebo tvoří shluky. P-hodnota je pravděpodobnost, že zkoumaný prostorový vzorek byl vytvořen náhodným způsobem. Když je hodnota malá, je nízká pravděpodobnost, že prostorová struktura byla vytvořena z náhodných procesů a můžeme zamítnout nulovou hypotézu. Z-skóre je směrodatná odchylka. Velmi nízké a vysoké hodnoty z-skóre jsou spojovány s p-hodnotami blízcími se k nule.

Pro analýzy v prostoru se v SW ArcGIS nachází speciální dataset nástrojů. Nejdříve se vypočetly charakteristiky globální úrovně, poté lokální. Pracovalo se vždy s každou kategorií lesního porostu samostatně, kde se výsledky porovnávaly mezi jednotlivými obcemi. Pouze prostorová autokorelace Shannonova indexu zahrnovala všechny třídy.

Jelikož území obce Brdy je výrazně větší než ostatní, bylo vypočteno relativní zastoupení každé třídy na celkové území obce. Tyto relativní hodnoty vstupovaly do zpracování prostorovými analýzami.

#### 3.9.2.1 Moranův index

Všechny prostorové analýzy jsou k nalezení v toolsetu *Spatial Statistics Tools*. U výpočtu globální varianty Moranova indexu (*Spatial Autocorrelation*) vstupní vrstvou byla zvolena vrstva *Obce\_lesy2* a atributem zájmu sloupec s relativní rozlohou třídy 1. Ke zpracování se nabízela celá řada prostorových vztahů. Byla vybrána metoda *Contiguity\_edges\_corners*, která pracuje pouze s polygony sdílející hranice nebo bod se zájmovým polygonem. Nastavena byla eukleidovská vzdálenost měřící přímou vzdálenost mezi dvěma body. Tento postup byl proveden i u dalších čtyř kategorií lesního porostu a Shannonova indexu.

Lokální varianta byla vypočtena obdobným způsobem jako globální. Rozdíl byl pouze v tom, že se tento nástroj jmenoval *Cluster and Outlier Analysis (Anselin Local Morans I)*. Výstupem nebyly reporty, ale nová vrstva polygonů s atributy výsledků, které byly upraveny do formy kartogramů a vyexportovány (*příloha 10, příloha 11 a příloha 14*).

### 3.9.2.2 Getis - Ord General G

Getis – Ord General G analýzu nalezneme pod názvem *High/Low Clustering* v *Spatial Statistics Tools*. Všechny parametry byly nastaveny stejně jako u Moranova indexu a reporty upraveny do formy tabulky. Byl tu jeden rozdíl od globální varianty Moranova indexu, a to v případě kdy by byla zamítnuta nulová hypotéza.

U Getis – Ord General G statisticky signifikantní pozitivní z-skóre znamená, že vyšší hodnoty shluků jsou prostorově více u sebe a při negativní jsou zase nízké hodnoty blízko u sebe. Zatímco u Moranova indexu jsou při pozitivním z-skóre shlukovány vždy hodnoty vysoké nebo nízké. Negativní vypovídá o prostorové rozptýlenosti hodnot, kdy vysoké hodnoty jsou nalezeny daleko od sebe.

Obdobným způsobem jako lokální varianta Moranova indexu byla vytvořena i zde Getis - Ord General G analýza (*ArcToolbox – Spatial Statistics Tools – Mapping Clusters – Hot Spot Analysis (Getis-Ord Gi)*). Vznikly nové polygonové vrstvy s hodnotami lokálních indexů. Vytvořen byl kartogram pro lesní vegetaci a Shannonův index nacházející se v *příloze 12 a příloze 14*.

# KAPITOLA 4

## 4 Výsledky

Tato kapitola hodnotí dosažené výsledky, které vychází z aplikovaných metod. Ty jsou prezentovány formou tabulek, grafů a mapových výstupů. Nejdříve bude vyhodnocen samotný proces klasifikace a přesnost. Poté následovalo aplikování Shannonova indexu a prostorové autokorelace.

### 4.1 Klasifikace a její přesnost

Řízená klasifikace byla vytvořena na základě 22 trénovacích ploch ověřených z terénu a dalších 289 množin, které byly vybrány vizuálně z ortofota. Bylo zrealizováno více kombinací na základě využití různých algoritmů a spektrálních pásem. Provedla se i neřízená klasifikace, která ale při porovnání s trénovacími množinami a kontrolními body vůbec neodpovídala skutečnosti. Nejlepšího výsledku dosáhla klasifikace při účasti všech 16 spektrálních pásem a algoritmu maximum likelihood. Tím se potvrdila teorie z odborné literatury, kdy výsledky multitemporálního snímku vychází lépe než klasifikace pouze z jednoho. Klasifikace v mapové podobě je k vidění v příloze 8. V příloze 1 se pak nachází rozlohy jednotlivých kategorií lesní vegetace za ORP.

Důležitou součástí klasifikace je ověřování přesnosti. Již v *tabulce 4* byly zaznamenány počty kontrolních bodů za jednotlivé třídy. Třída 1 (jehličnaté stromy) má největší počet kontrolních bodů z důvodu rozsáhlých ploch vyskytujících se na tomto území. Naopak nejmenší počet zástupců náleží třídě 5 (strukturně heterogenní listnaté lesy). V *tabulce 6* se nachází chybová matice multitemporálního snímku Landsat 8 při použití klasifikátoru maximum likelihood. Nejhorší zpracovatelská (0.63) i uživatelská přesnost (0.54) byla zaznamenána u smíšených lesů (třída 2). K nejrozsáhlejším záměnám došlo s jehličnatými a strukturně homogenními lesy. Pravděpodobně je to způsobený tím, že tato třída obsahuje jehličnaté i listnaté stromy. Dle poměru stromů v jednotlivých pixelech zde vzniká podobnost s jehličnatými či listnatými lesy. Překvapivě byla nejlépe klasifikována třída 5 z hlediska zpracovatelské přesnosti (strukturně heterogenní listnaté lesy). Nejlepší uživatelské přesnosti dosáhla třída 1 (jehličnaté lesy) s hodnotou 0.91. Další chybové matice jsou k vidění v *příloze 2*.

Landsat 8 - multitemporální		TŘÍDY SKUTEČNÉ						
		1	2	3	4	5	celkem	uživatelská přesnost
KLASIFIKOVANÉ TŘÍDY	1	43	4	0	0	0	47	0,91
	2	6	19	2	7	1	35	0,54
	3	0	1	26	2	0	29	0,90
	4	1	4	1	27	0	33	0,82
	5	0	2	1	4	19	26	0,73
	celkem	50	30	30	40	20	<b>170</b>	
	zpracovatelská přesnost	0,86	0,63	0,87	0,68	0,95		

**Tab 6: Chybová matice multitemporálního snímku z Landsat 8**

(Zdroj: vlastní zpracování v MS Excel 2007)

V tabulce 7 se pro srovnání nachází přesnosti klasifikací a vypočítaný kappa index. Vyšší přesnosti vyšly u klasifikací, kde byl použit klasifikátor maximální věrohodnosti na rozdíl od minimální vzdálenosti. Multitemporální snímek dokazuje vyšší přesnost než snímek jednoho data. Klasifikace s celkovou přesností 78,8 % představuje reprezentativní prvek, který v dálkovém průzkumu můžeme dále využít.

	celková přesnost [%]	Kappa index
multitemporální - ML	78,8	0,735
multitemporální - MD	68,2	0,602
březnový - ML	71,2	0,643
březnový - MD	61,8	0,519
červencový - ML	71,8	0,643
červencový - MD	52,9	0,415

**Tab 7: Přesnost řízených klasifikací snímku z Landsat 8**

(Zdroj: vlastní zpracování v MS Excel 2007)

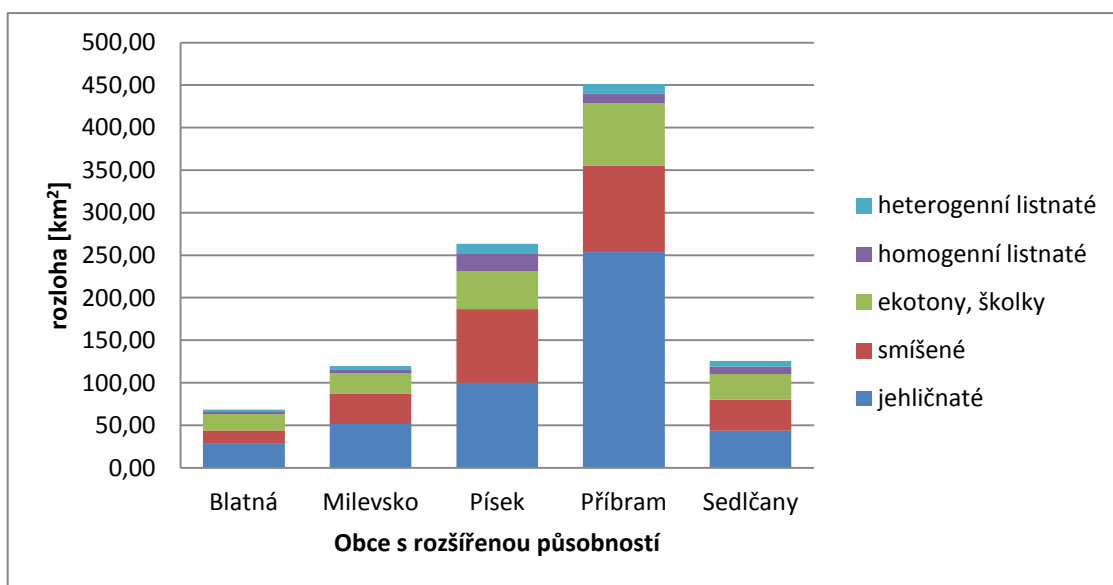
Pozn. ML – Maximum Likelihood, MD – Minimum Distance

## 4.2 Rozlohy lesní vegetace v ORP

Na *obrázku 5* je zobrazen graf s celkovým zastoupením lesního porostu jednotlivých kategorií na území ORP. Příbram zde má dominantní postavení vůči ostatním ORP kvůli jeho celkové rozloze a hlavně rozsáhlou lesní vegetací, která se zde nachází. Písek se nachází na druhém místě.

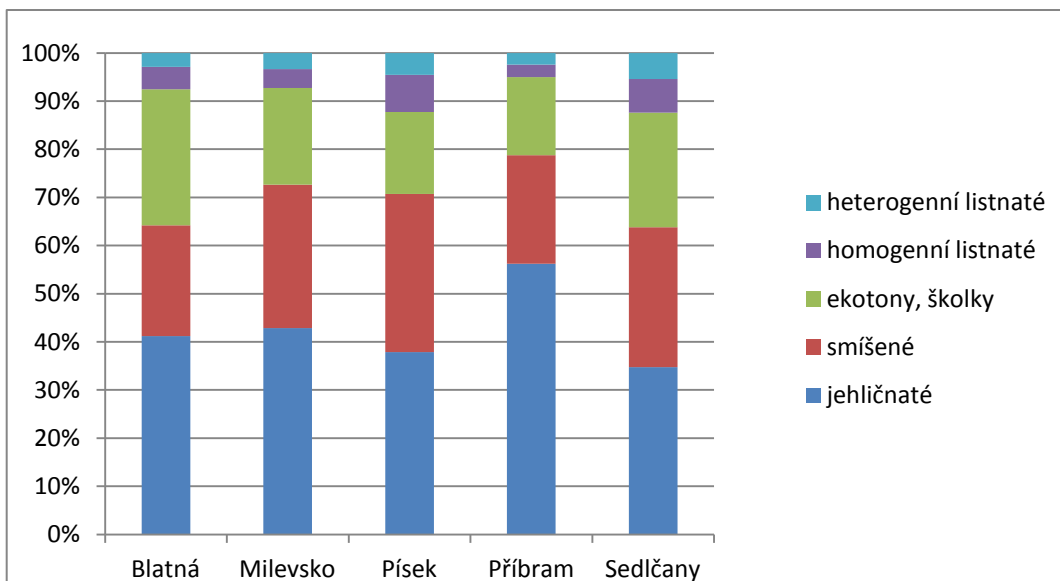
Jednoznačně ve všech ORP vede přítomnost jehličnatých lesů. Překvapivě se na druhém či třetím místě umístily ekotony. Tento fakt může mít příčinu v ne zcela podrobné masce lesní vegetace, která neodstranila všechna území nerepresentující lesní pokryv. Tyto oblasti mají spektrální odrazivost podobnou právě ekotonům, a proto byly plochy do této kategorie většinou zařazeny. V *příloze 1* jsou číselně vyjádřeny rozlohy lesní vegetace za jednotlivé ORP.

*Obrázek 6* zobrazuje graf v procentuálním podílu jednotlivých tříd lesní vegetace v ORP. Vidíme zde, že třídy jsou poměrově všude stejně zastoupeny. ORP Příbram obsahuje rozsáhlý jehličnatý les, a proto reprezentuje nadpoloviční většinu lesní vegetace na daném území. Ve všech ORP se nejméně vyskytují listnaté lesy.



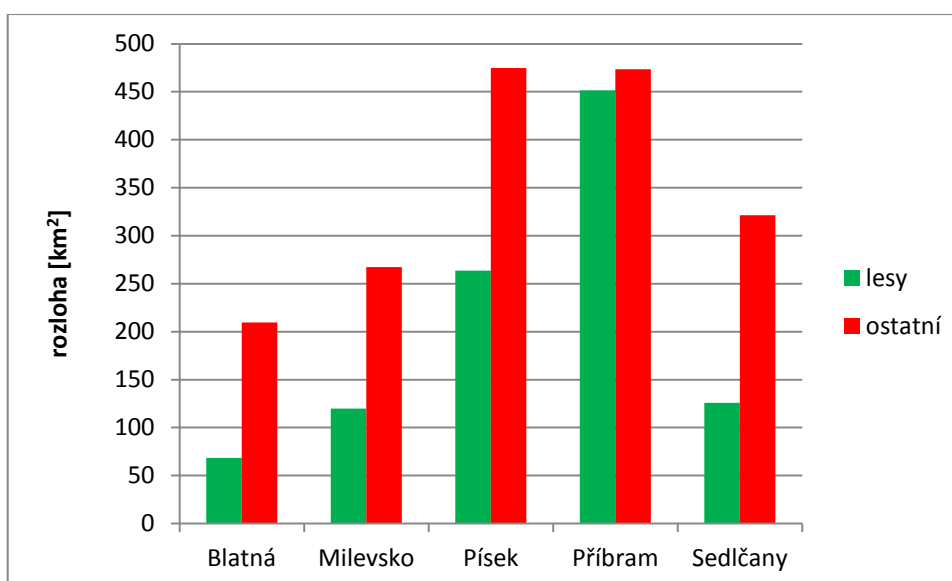
**Obr. 5: Lesní vegetace ve vybraných ORP**

(Zdroj: vlastní zdroj zpracováno v Microsoft Excel 2007)



**Obr. 6: Procentuální zastoupení lesní vegetace v ORP**  
 (Zdroj: vlastní zdroj zpracováno v Microsoft Excel 2007)

Obrázek 7 zobrazuje porovnání ploch lesní vegetace ke zbytku nezalesněného území obcí s rozšířenou působností. Největší lesnatost k rozloze celého ORP má Příbram, zatímco nejmenší Blatná, která je také nejmenším ORP. Lesnatost v ORP Příbram způsobuje přítomnost většího geomorfologického celku Brdy, jenž je pokryt převážně jehličnatými lesy.



**Obr. 7: Porovnání rozlohy lesní vegetace s nelesní za ORP**  
 (Zdroj: vlastní zdroj zpracováno v Microsoft Excel 2007)

V *příloze 13* se naopak nachází procentuální podíl lesní vegetace v jednotlivých správních územích obcí.

### 4.3 Výsledky Shannonova diverzitního indexu

Shannonův diverzitní index byl díky řízené klasifikaci omezen na pět kategorií. Našlo se několik případů, kde některá třída na území obce úplně chyběla. Obec Třebsko na svém území neobsahovala žádnou lesní vegetaci, a proto zde nebyl Shannonův index vypočítán.

V *příloze 3* se nalézá tabulka s vypočítanými hodnotami Shannonova indexu a Shannonovy vyrovnanosti za jednotlivé obce. Obdobný způsob byl proveden i na úrovni území ORP. Výsledky se nacházejí v *příloze 4*. Shannonův index charakterizuje a prezentuje informace o počtu druhů a velikosti jejich populace na území dané obce. V případě obcí se hodnoty Shannonova indexu pohybují v rozmezí 0.395 – 1.568. Nejnížší hodnota byla zjištěna u obce Bratronice v ORP Blatná. Na území této obce se vyskytují pouze lesní porosty z kategorií jehličnatých lesů a ekotonů, což zapříčiňuje sníženou hodnotu. V případě obce Kozlí, která dosáhla nejvyšší hodnoty, se zde nachází vyrovnané počty zástupců jednotlivých tříd.

Za ORP byla nejvyšší hodnota zjištěna u Sedlčan (1.378), nejnížší v Příbrami s dominujícími jehličnatými lesy (1.058).

Shannonova vyrovnanost většinou kopírovala výsledek Shannonova indexu. Byly zde ale i některé odlišnosti. Například nejnížší vyrovnanost byla vypočtena u obce Občov (0.509) v ORP Příbram. Vizualizované výsledky jsou k nalezení v *příloze 9*.

### 4.4 Výsledky prostorové autokorelace

Výsledky jsou prezentovány v podobě tabulek a mapových výstupů, které jsou umístěny v přílohách. Globální varianty jsou zhodnoceny ve formě tabulek, zatímco lokální byly představeny ve formě kartogramů.

#### 4.4.1 Výsledky Moranova indexu

V následující tabulce jsou vypočteny základní statistické charakteristiky globální varianty Moranova indexu. Ve formě kartogramů jsou v *příloze 10* a *příloze 11* porovnány výsledky lokální varianty aplikované na jednotlivé třídy lesní vegetace v rámci území obce.

*Tabulka 8* vypovídá o prokázání signifikantnosti na 95% hladině spolehlivosti. Vysoké hodnoty z-skore a velmi nízké p-hodnoty zamítají nulovou hypotézu, že třídy lesního porostu

jsou uspořádány náhodně. Hodnoty Moranova indexu se pohybují kolem hodnot lehce nad nulou, což značí o mírné pozitivní prostorové autokorelaci. Lesní vegetace má tendence ke shlukování, ale pouze velmi malé. Zde si uvádíme příklad při aplikaci prostorového vztahu Contiguity Edges Corners. V příloze 5 jsou ale k vidění obdobné tabulky s využitím prostorových vztahů Inverse Distance a Fixed Distance Band. V těchto případech vyšla prostorová autokorelace ještě slaběji.

Kategorie (Contiguity Edges Corners)	Moranův index	očekávaná hodnota	variance	z - skore	p-value
Jehličnaté lesy	0,290	-0,005	0,002	6,996	0,000
Smíšené lesy	0,317	-0,005	0,002	7,614	0,000
Ekotony	0,144	-0,005	0,002	3,529	0,000
Strukturně homogenní listnaté lesy	0,196	-0,005	0,001	5,372	0,000
Strukturně heterogenní listnaté lesy	0,251	-0,005	0,002	6,245	0,000

**Tab 8: Charakteristiky globálního Moranova indexu lesní vegetace na úrovni obcí**

(Zdroj: vlastní zpracování v ArcGIS a MS Excel 2007)

Lesní vegetace není v zájmovém prostředí nijak výrazně uspořádána z hlediska katastrálních území obcí. Vliv na výskytu, jaký typ lesa se v dané lokalitě nachází, závisí i na jiných faktorech (nadmořská výška, teplota atd.).

Příloha 10 obsahuje kartogramy s výsledky lokální varianty indexu a ukazuje, zda tyto výsledky jsou signifikantní či nikoliv. V příloze 11 jsou pak zobrazeny prostorové vztahy mezi obcemi. Pouze některé z nich jsou signifikantní.

Kategorie jehličnatých lesů vykazuje velmi vysoké hodnoty na správním území obce Brdy. Vysvětlení se může nacházet v sousedních obcích, do kterých také zasahují právě rozlehlé zalesněné jehličnaté plochy z tohoto geomorfologického útvaru. Tendence shlukování byly zaznamenány také v oblasti na rozmezí ORP Milevsko a ORP Písek. Touto oblastí protéká řeka Vltava a podél toku se rozléhají husté lesy. Nízké hodnoty jsou rozmístěny spíše náhodným způsobem. Pouze dvě obce spolu sousedí, a to Chyšky a Nechvalice. Smíšené lesy vykazují shlukování opět v oblastech toku Vltavy na pomezí ORP Písek a ORP Milevsko. V těchto místech byly vypočteny nejvyšší hodnoty lokální varianty Moranova indexu. Rozložení ekotonů v jednotlivých obcích nevykazuje příliš velké prostorové závislosti. Pouze obec Brdy v případě fotonů zachycuje zápornou prostorovou autokorelaci, kdy okolní obce mají vyšší hodnoty než Brdy. Strukturně homogenní listnaté lesy mají tendence ke shlukování v jižní části ORP Písek. Dle mapy klasifikace se na tomto území rozkládá rozsáhlejší lesní porost, který obsahuje

listnaté stromy. Výsledky strukturně heterogenního listnatého lesa ukazují na mírnou tendenci shlukování podél říčního toku Vltavy.

V *tabulce 9* se nachází základní charakteristické rysy lokálního Moranova indexu. Největší rozdíly hodnot jsou u smíšených lesů. Velmi zanedbatelné nalezneme u strukturně heterogenních listnatých lesů. Můžeme předpokládat, že na územích některých obcí se nevyskytují žádné smíšené lesy a u některých je jich převaha. Velké rozdíly mezi z-skóre představují velké odlišnosti v signifikanci. To znamená, že všechny výsledky zaznamenané v kartogramu nemusí být vypovídající.

charakteristika	Jehličnaté lesy	Smíšené lesy	Ekotony	Strukturně homogenní listnaté lesy	Strukturně heterogenní listnaté lesy
<b>zprůměrovaná hodnota z jednotlivých lokálních variant Moranova indexu</b>	1,555	1,700	0,775	1,054	0,001
<b>maximální hodnota Moranova indexu</b>	26,608	33,326	15,137	27,909	0,008
<b>minimální hodnota Moranova indexu</b>	-11,149	-7,312	-10,688	-3,798	-0,002
<b>průměrná hodnota z-skóre</b>	0,672	0,721	0,344	0,554	0,795
<b>z-skóre maximální hodnota</b>	12,166	12,905	6,308	15,331	12,395
<b>z-skóre minimální hodnota</b>	-4,648	-2,668	-2,697	-1,634	-1,934

**Tab. 9: Charakteristiky lokálního Moranova indexu**  
(Zdroj: vlastní zpracování v ArcGIS a MS Excel 2007)

Globální Moranův index ukázal, že celkově na modelovém území je velmi malá pozitivní prostorová autokorelace. To je potvrzeno tím, že v lokální variantě opravdu většina obcí obsahovala hodnotu lokálního Moranova indexu kolem nuly.

#### 4.4.2 Výsledky Getis - Ord General G

Zpracování Getis – Ord General G bylo obdobné jako u Moranova indexu. Nejdříve byly hodnoty vypočteny na globální úrovni, poté na lokální. Výstupem výsledků globální úrovně Getis – Ord General G (High/Low Clustering) byla *tabulka 10* s charakteristikami

klasifikovaných tříd. Tato metoda měří stupeň shlukování vysokých nebo nízkých hodnot. General G může mít pouze pozitivní hodnotu. Nízké výsledky vypovídají o neprokázání shlukování z pohledu celého území. V příloze 6 jsou k vidění výsledky při užití prostorových vztahů Inverse Distance a Fixed Distance Band.

Kategorie lesa (Contiguity Edges Corners)	General G	očekávaná hodnota	variance	z - skóre	p-value
Jehličnaté lesy	0,036	0,027	0,000	4,904	0,000
Smíšené lesy	0,058	0,027	0,000	4,685	0,000
Ekotony	0,031	0,027	0,000	3,339	0,001
Strukturně homogenní listnaté lesy	0,051	0,027	0,000	4,503	0,000
Strukturně heterogenní listnaté lesy	0,037	0,027	0,000	3,328	0,001

**Tab 10: Charakteristiky globální General G analýzy lesní vegetace**

(Zdroj: vlastní zpracování v ArcGIS a MS Excel 2007)

Mnohem zajímavější jsou výsledky lokální varianty Getis – Ord General G, která přesně hledá oblasti Hot spots (shluky vyšších hodnot) a Cold spots (shluky nižších hodnot). V kartogramu v příloze 12 nalezneme hodnoty ukazující signifikantnost výsledků a hot/cold oblasti.

Pět kartogramů, zastupující každý jednu strukturu lesní vegetace, zobrazuje místa shluků. Nízké hodnoty jsou prezentovány modrou barvou, zatímco oranžová a červená znázorňuje shlukování vysokých hodnot. Světle zelené polygony obcí nejsou signifikantní. Globální výsledek opět vystihuje lokální variantu, kdy jen malé množství obcí obsahuje určitý prostorový vztah vůči sousedním obcím.

Jehličnaté lesy vytváří dva shluky s pozitivními hodnotami opět v okolí Brd a na rozmezí hranic ORP Milevsko a ORP Písek. Naopak nízké hodnoty jsou vykazovány na východě na hranicích mezi ORP Milevsko a ORP Sedlčany. Smíšené lesy vytváří výraznější oblast výskytu opět podél řeky Vltavy u hranic ORP Milevsko a ORP Písek. Strukturně homogenní a heterogenní lesy vytváří shluky v jižní části ORP Písek. Pravděpodobně je to z důvodu výskytu listnatých lesů, které se zde mohou střetávat. Strukturně homogenní listnaté lesy tvoří ještě jeden větší shluk na území obcí Bohostice, Milešov, Smolotely, Solenice, Zduchovice a Dolní Hbity. Touto oblastí protéká opět řeka Vltava a podél ní se nachází husté listnaté lesy.

Charakteristika (Contiguity Edges Corners)	Jehličnaté lesy	Smíšené lesy	Ekotony	Strukturně homogenní listnaté lesy	Strukturně heterogenní listnaté lesy
<b>průměrná hodnota z-skóre</b>	0,157	0,190	0,163	0,061	-0,009
<b>z-skóre maximální hodnota</b>	4,622	5,824	3,214	5,454	4,810
<b>z-skóre minimální hodnota</b>	-2,481	-2,329	-2,452	-1,410	-2,232

**Tab 11: Z - skóre lokální varianty Getis – Ord General G klasifikovaných tříd lesní vegetace**  
(Zdroj: vlastní zpracování v ArcGIS a MS Excel 2007)

Jak je vidět v *tabulce 11*, průměrná hodnota z-skóre se pohybuje kolem nuly a znamená, že rozlohy jednotlivých typů lesní vegetace na území obcí jsou rozloženy náhodně. Jsou zde ale některé výjimky, které mají z-skóre vyšší než 1,96 a nižší než -1,96. Ty jsou významné na 95% hladině spolehlivosti.

#### 4.4.3 Aplikování prostorové autokorelace na Shannonův index

Na Shannonův diverzitní index byla aplikována prostorová autokorelace. Díky tomu můžeme zahrnout do prostorových statistik všech pět struktur lesní vegetace najednou a prostorově zjišťovat, zda v některých místech dochází ke shlukování vyšších či nižších hodnot.

V *tabulce 12* se nachází výsledky globální varianty Moranova indexu. U většiny prostorových vztahů byla opět představena mírná pozitivní prostorová autokorelace. Avšak nejvyšší byla prezentována prostorovým vztahem Contiguity Edges Corners.

prostorový vztah	Moranův index	očekávaná hodnota	variance	z - skóre	p-value
<b>Contiguity Edges Corners</b>	0,268	-0,005	0,002	6,556	0,000
<b>Inverse Distance</b>	0,186	-0,005	0,001	6,448	0,000
<b>Fixed Distance Band</b>	0,148	-0,005	0,001	5,773	0,000

**Tab 12: Globální Moranův index Shannonova indexu**  
(Zdroj: vlastní zpracování v MS Excel 2007)

prostorový vztah	General G	očekávaná hodnota	variance	z - skore	p-value
<b>Contiguity Edges Corners</b>	0,028	0,027	0,000	2,083	0,037
<b>Inverse Distance</b>	0,000	0,000	0,000	-2,293	0,022
<b>Fixed Distance Band</b>	0,063	0,064	0,000	-1,469	0,142

*Tab 13: Getis-Ord General G analýza Shannonova indexu  
(Zdroj: vlastní zpracování v MS Excel 2007)*

Tabulka 13 zobrazuje základní statistické charakteristiky při aplikování globální varianty analýzy Getis - Ord General G. Kvůli velmi nízkým hodnotám General G můžeme říci, že v rámci celého území nedocházelo k žádným výrazným shlukům, avšak to nevyklučuje jiný stav na lokální úrovni. Výsledek lokální úrovně můžeme nalézt v příloze 14.

Lokální výsledky Shannonova indexu jsou výrazně zajímavější. Zde už nalezneme některé oblasti, které vypovídají o heterogenitě prostředí. Na první pohled je zjevné, že v jižní části ORP Písek se vyskytuje území, kde je vyšší heterogenita prostředí. Pravděpodobně v této oblasti nalezneme nejrozličnější lesní ekosystém, v kterém se bude vyskytovat více druhů organismů a rostlin. Tato oblast zahrnuje katastrální území Písku, Heřmaně, Skal, Protivína, Žďáru, Tálína a Ražic.

Moranův index považuje za reprezentativní pouze oblast jižní části ORP Písek. Naopak Getis - Ord General G zdůrazňuje ještě jednu oblast hot spot, která se táhne podél hranic ORP Sedlčany a ORP Milevsko. Tato analýza také poukázala na cold spot vyskytující se v ORP Příbram zahrnující Brdskou vrchovinu. V těchto obcích byly vypočteny nižší hodnoty Shannonova indexu z důvodu výskytu dominantní třídy jehličnatých lesů.

# KAPITOLA 5

## 5 Diskuze

Heterogenita prostředí má výrazný vliv na biodiverzitu krajiny. V práci bylo zmíněno, že čím různorodější krajina, tím také větší bohatost na faunu a flóru. Tento důležitý aspekt souvisí s poskytováním ekosystémových služeb. Většina produktů, které využíváme, vzniká prvotně z přírody. Snížením množství hmyzu klesne produkce hospodářských plodin, jež jsou jím opylovány. Většina léků proti nemocem také pochází z přírody. A důvodů je mnohem více. Proto musíme naši krajinu chránit a zajímat se, jak je biodiverzita bohatá a hlavně kde se tyto oblasti nachází (Biodiverzita, 1999).

Tato práce se specializovala na lesní porost, který byl rozdělen dle struktury do pěti tříd (jehličnaté lesy, smíšené lesy, ekotony, strukturně homogenní listnaté lesy, strukturně heterogenní listnaté lesy). Řízená klasifikace ze snímků Landsat 8 zařadila jednotlivé pixely do jedné z pěti tříd. K dispozici bylo 311 trénovacích množin, které byly sebrány terénním průzkumem či z ortofota díky WMS službě z geoportálu ČÚZK.

Většina odborných studií používala ve své práci starší družicový systém z řady Landsat. Zde byly aplikovány dva družicové snímky Landsat 8 OLI (27. 7. 2013 a 8. 3. 2014). Například Moore a Bauer (1990) využil pro klasifikaci snímek Landsat 5 MSS, který obsahoval 4 kanály s prostorovým rozlišením 80 m. Zatímco Wolter et al. (1995) již nakombinoval snímky s MSS a TM senzorem (30 m). Thematic Mapper má tedy již shodné prostorové rozlišení jako senzor OLI.

Landsat TM použil také při klasifikaci vegetačního pokryvu Rodriguez (2011), který zpracovával multitemporální snímek, kde byly spojeny scény z různých dob během roku. Aplikoval na lesní vegetaci klasifikátor Random Forest, kde hodnota kappa indexu činila 0.92 a při výpočtech s algoritmem maximum likelihood 0.83. Při řízené klasifikaci lesní vegetace Jihočeského a Středočeského kraje vyšel kappa index 0.735. Byl zde použit klasifikátor maximum likelihood, což je oproti práci Rodrigueze (2011) nižší výsledek o 0.1. U ostatních kombinací spektrálních pásem a snímků vyšel kappa index vždy nižší. Proto byla tato varianta řízené klasifikace dále zpracovávána. Nižší přesnost než v práci Rodrigueze může být způsobena pravděpodobně absencí dalších snímků zakomponovaných do klasifikace, které by reprezentovaly ještě jiná období během roku. Dalším důvodem mohla být vyšší jednoznačnost zařazení pixelů do tříd.

Předchůdcem Landsat 8 OLI byl Landsat 7 ETM+. Snímky z této družice použil ve své práci Helmer et al. (2012). Ten zpracovával multitemporální snímek nad územím tropických lesů, kdy se přesnost klasifikace pohybovala okolo 90 %. Snímky byly pořízeny v různých ročních dobách, aby byly odlišeny jednotlivé druhy stromů.

V mojí práci byly využity dva snímky, první byl pořízen na začátku jara a druhý v období vrcholícího léta. Bohužel se na většině dostupných snímků Landsat vyskytovala nad modelovým územím oblačnost, a proto nebyly tyto snímky využity. Červencový snímek obsahoval drobnou oblačnost, nad kterou byla vytvořena maska, aby toto území nezasahovalo do klasifikace.

Helmer et al. (2012) zahrnul do klasifikace všechna pásma a ještě některé vypočítané spektrální indexy (Tasseled cap – brightness, greenness, wetness, NDVI, NDSI a WBDI). V této diplomové práci vstupovalo do procesu klasifikace prvních osm pásem. Nezahrnula jsem zde devátá pásma, která jsou vhodná převážně pro odstraňování mraků typu cirrus. Určitě by bylo zajímavé vyzkoušet stejný proces ještě s dalšími spektrálními či vegetačními indexy. Tento postup by mohl zlepšit kvalitu samotné klasifikaci. Celková přesnost totiž vyšla 78.8 %, což je o cca 11 % méně oproti práci Helmera (2012).

Kombinaci snímků Landsat TM/+ETM využil také Ionnis et al. (2011). Scény byly pořízeny v letech 1986, 1999 a 2008. Nepracoval zde pouze s lesní vegetací, ale s celým zájmovým územím, které klasifikoval do devíti krajinných typů. Řízená klasifikace byla opět provedena za účasti algoritmu maximum likelihood a 832 trénovacích množin. Množství trénovacích množin je vyšší než v našem případě (311), tak jako počet klasifikovaných tříd. Bylo dosaženo 85% celkové přesnosti, což značí, že výsledky jsou přesnější než v mé práci.

Nejvyšší uživatelské přesnosti v diplomové práci bylo dosaženo u jehličnatých lesů a nejnižší u smíšených. Nejčastější chyby se vyskytovaly mezi smíšenými a strukturně homogenními listnatými lesy. Důvodem špatného zařazení mohla být spektrální podobnost pixelů, kdy smíšené lesy obsahovaly větší množství listnatých lesů než jehličnatých. Naopak nejlepšího zařazení kontrolních bodů do správné třídy bylo u strukturně heterogenních listnatých lesů, kde bylo z 20 bodů správně identifikováno 19. Vyšší počet kontrolních bodů a trénovacích ploch by mohl zlepšit výsledky klasifikace.

Velikost modelového území odpovídala přibližně 1/3 snímku Landsat a nacházela se na hranicích Středočeského a Jihočeského kraje. Zájmová oblast obsahuje lesní porost zahrnující území ORP Příbram, Sedlčany, Písek, Blatná a Milevsko. Prostorové analýzy byly ale aplikovány na úrovni správních území obcí (198).

Prostorové charakteristiky byly zkoumány z hlediska heterogenity lesa a prostorových vztahů mezi správními územími obcí. Nejprve byla vypočtena úroveň biodiverzity pomocí Shannonova indexu, která byla dále zpracována prostorovou autokorelací. Prostorová autokorelace byla také aplikována na úrovni obcí každé klasifikované třídy zvlášť. Zpracování probíhalo tím způsobem, že klasifikovaná data, byla rozřezána dle hranic obcí a dále se pracovalo s rozlohou jednotlivých tříd.

V odborné literatuře jsem bohužel nenalezla obdobný způsob aplikování Shannonova indexu a prostorové autokorelace jako v mé práci na administrativní jednotky. Například Read

(2001) porovnával více metod prostorových analýz a výsledky krajinných indexů na neklasifikovaných datech, které byly ale rozděleny neřízenou klasifikací do čtyř tříd. Každý krajinný pokryv byl zkoumán zvláště Shannonovým indexem dle spektrálních hodnot vypočteného vegetačního indexu nebo spektrálního pásma. Problémem u aplikování Shannonova indexu ale bylo, že spektrální hodnoty byly velmi různorodé a v tomto případě, kdy každá hodnota reprezentuje jeden druh, bylo zpracování velmi obtížné. Vzniklo obrovské množství druhů, což neobsahovalo vypovídající hodnotu.

Glosová (2013) se zabývala ve své bakalářské práci zjišťováním prostorové struktury typologických snímků lesní vegetace. Byl zde aplikován podobný postup analýzy prostorové autokorelace pro Shannonův diverzitní index. V případě prostorového vztahu Contiguity Edges Only se nenastavovala žádná hraniční vzdálenost, do které by se měla prostorová autokorelace počítat. Glosová (2013) nezmiňuje, který prostorový vztah využila, pouze vypočetla Moranův index na různě dlouhých vzdálenostech pro vzorky na území České republiky. Silně autokorelovaná hodnota (vyšší než 0.5) vyšla pouze ve vzdálenostní třídě 0 – 200 m. Na dalších vzdálenostech se nevyskytovala prostorová autokorelace. Závislost hodnot biodiverzity souvisí pouze s velmi malou vzdáleností. Bohužel nelze tento výsledek vhodně porovnávat s našimi, kde bylo stanoveno pouze pět druhů, zatímco v případě Glosové (2013) se vyskytovalo pestřejší zastoupení dřevin a rostlin. Také se liší zahrnutí okolních prvků do prostorové autokorelace, kdy v mém výzkumu byly zahrnuty pouze obce se společnými hranicemi.

Glosová (2013) aplikovala také prostorovou autokorelaci na některé hojně se vyskytující druhy stromů (smrk ztepilý, buk lesní, borovice lesní a jedle bělokorá). Smrk byl silně prostorově autokorelovaný do vzdálenosti 800 m, buk do 400 m, borovice do 1200 m a jedle pouze do 200 m.

V diplomové práci vyšly hodnoty Shannonova indexu za jednotlivá území mezi 0.395 – 1.568. Tento výsledek vypovídá o nižších biodiverzitních hodnotách, který byl ovlivněn omezením druhů na pět tříd. Nejnižší rozmanitost se nacházela v obci Bratronice, na jejímž území se vyskytovaly pouze dvě kategorie lesního porostu. Nejvyšší byly zaznamenány na území obce Kožlí, kde se pravděpodobně vyskytují vyrovnaně zastoupené třídy. Všechny hodnoty Shannonova indexu na úrovni ORP vyšly vyšší než hodnota 1. V rámci větších územních celků jsou hodnoty vyrovnanější než na nižších jednotkách. Shannonova vyrovnanost většinou odpovídá stejnému zařazení jako u Shannonova indexu, ale ne vždy.

Prostorovou autokorelaci zkoumal Read (2001) pomocí Moranova indexu, kde v případě lesního porostu vyšla mírná pozitivní prostorová autokorelace. Vyšší míru shlukování vykazovaly ostatní krajinné typy. Ve výzkumné práci Lianga et al. (2009) naopak nedošlo k prokázání autokorelace nejspíše z důvodu velké rozmanitosti mikroprostředí.

Langer (2007) ve své bakalářské práci na území České republiky studoval na vybraných typech land cover (městská zástavba, orná půda a lesy) metodu prostorové autokorelace.

Vybraná metoda Moranův index  $I$  byl vypočten na globální i lokální úrovni jako v této práci. V případě lesů vyšel globální Moranův index  $-0.09$ , představující velmi slabou negativní prostorovou autokorelaci. Avšak kvůli hodnotě  $z$ -skóre  $-0.069$  nebyla tato hodnota statisticky významná na hladině  $\alpha = 0.05$ . Na lokální úrovni vyšly u většiny krajů hodnoty kolem nuly jako v mé práci. Pouze Jihočeský a Plzeňský kraj vykazovaly vyšší tendenci shlukování díky zalesněné Šumavě.

Moranův index a Getis - Ord General  $G$  analýza byly metodami, jejichž prostřednictvím byly v této práci zkoumány prostorové vazby. Na globální úrovni nebyly zachyceny zajímavé hodnoty vykazující nějakou výraznou autokorelaci. Globální varianta Moranova indexu vyšla ve všech třídách lehce nad hodnotou nula, které představují mírnou pozitivní prostorovou autokorelaci.

Lokální úroveň ukazuje na oblasti, kde dochází k vytváření shluků či naopak. I na této úrovni většina územních jednotek obsahuje hodnoty blízké nule. Lokální úroveň odpovídá výsledkům na globální úrovni. Určitě nás nepřekvapí, že vyšší pozitivní hodnota u třídy 1 vyšla v obci Brdy, kde se na jejím území nachází hustý jehličnatý les zasahující i do okolních obcí. Kromě třídy ekotonů se vyskytovala pozitivní prostorová autokorelace u všech tříd v některé z oblastí podél toku Vltavy.

Analýza Getis - Ord General  $G$  krásně vykresluje oblasti shlukování nízkých hodnot a vysokých. Výsledky jsou velmi podobné Moranovu indexu. Většina obcí ale není signifikantní a opět lokální varianta odpovídá hodnotě výsledku globální varianty Getis - Ord General  $G$ .

Zajímavé informace byly zjištěny u prostorové autokorelace Shannonova indexu za jednotlivé obce. Zde jsou dobře zachyceny oblasti, kde jsou shlukovány hodnoty s vyšší biodiverzitou a naopak nižší biodiverzitou. Byla objevena oblast v jižní části ORP Písek, kde se pravděpodobně vyskytuje les s vyšší biodiverzitou a potažmo s vyšší heterogenitou prostředí. Na území těchto obcí byly vypočteny vyšší hodnoty Shannonova diverzitního indexu a bylo zjištěno prostorovou autokorelaci, že tyto hodnoty jsou si podobné a vykazují pozitivní prostorovou autokorelaci. V příloze 3 jsou zvýrazněny hodnoty Shannonova indexu těchto obcí. Všechny tyto oblasti přesahují hodnotu indexu 1.3, což je v rámci pěti tříd vysoká hodnota.

Výše již bylo zmíněno, že biodiverzita silně souvisí s heterogenitou. Avšak heterogenita může být pojata z různých směrů. Z hlediska výskytu rovnoměrného rozložení pěti tříd na daném území můžeme počítat s tím, že se zde častěji střídají lesní prostředí. Pravděpodobně bude v těchto místech i bohatší zastoupení flóry a fauny. Chudší biodiverzita se bude vyskytovat na území obce Brdy, kde má převahu třída 1 – jehličnaté lesy.

# KAPITOLA 6

## 6 Závěr

Tato práce se zabývala výzkumem heterogenity lesní vegetace z družicových snímků. Vstupními daty byly dvě scény pořízené družicí Landsat 8 OLI (8.3.2014, 27.7.2013). Modelové území se nacházelo na rozmezí Jihočeského a Středočeského kraje. Řízenou klasifikací za účasti obou snímků bylo provedeno na základě klasifikačního pravidla maximum likelihood rozřazení pixelů lesního porostu do pěti tříd. Byly vypočteny rozlohy tříd za jednotlivá správní území obcí a dále pak prostorové charakteristiky a Shannonův index.

Hlavním cílem bylo zjistit, zda pomocí spektrálních charakteristik lze rozlišit a zkoumat strukturní složení lesa a jestli zde existují některé prostorové souvislosti v jejich uspořádání. Celková přesnost klasifikace za účasti spektrálních pásem (bez devátých pásem) z obou scén vyšla 78.8 %. Můžeme jí považovat za reprezentativní a výsledky, které z ní dále vzešly, také.

Lesní porost rozdělen z hlediska struktury na pět tříd (jehličnaté lesy, smíšené lesy, ekotony, strukturně homogenní lesy, strukturně heterogenní lesy) byl zkoumán v rámci jednotlivých tříd a také díky Shannonovu indexu společně. Globální charakteristiky nevykazovaly závislost rozloh lesní vegetace mezi územími obcí. Lokální míry poskytly některé skryté informace, které nebyly patrné z globální varianty. Všechny třídy vytváří shluky vyšších hodnot podél řeky Vltavy. Nejsou vždy zastoupeny stejnými obcemi, ale společně mají právě oblast podél vodního toku. Můžeme říci, že na těchto územích jsou hustotně stejně zastoupeny v jednotlivých obcích. Třída 1 tvoří v ORP Příbram shluk s pozitivními hodnotami, která je převážně porostlá jehličnatými lesy.

Prostorová autokorelace Shannonova indexu zobrazila oblasti, kde se nachází více heterogenní prostředí a kde spíše homogenní. Globální úroveň opět neprokázala žádnou výraznou autokorelaci, kterou můžeme vidět na lokální variantě, kdy většina obcí není signifikantní. V již zmíněné oblasti Brdské vrchoviny je velmi nízká heterogenita prostředí. Opačným případem se stala oblast jižní části ORP Písek. Lesní vegetace je zde velmi pestrá a pravděpodobně se zde nachází velké množství druhů organismů a rostlin. Hlavně je to způsobeno díky rovnoměrně rozloženým třídám.

Hypotéza tvrdící, že bude prokázána závislost rozložení lesní vegetace jednotlivých tříd v rámci obcí, nebyla potvrzena na globální úrovni. Výsledky se většinou pohybovaly kolem hodnot dvou desetín, která představuje velmi slabou pozitivní prostorovou autokorelaci. Byly zde nalezeny ohniska homogenních a heterogenních prostředí v rámci bohatosti a rovnoměrnosti rozložení jednotlivých struktur.

V těchto heterogenních prostředích se pravděpodobně mohou vyskytovat organismy či rostliny, z kterých se mohou dále produkovat nové léčebné přípravky. Vyšší biodiverzita a heterogenita představuje vyšší bohatost ekosystému.

Práce může být rozšířena na celou Českou republiku, kde pravděpodobně uvidíme, že homogenní struktury se vyskytují v pohraničních pohořích, na nichž převážně rostou jehličnaté lesy. Díky tomu můžeme najít ohniska zájmu, která mají vyšší znak heterogenity a pak dále toto území zkoumat. Mohly by se také použít do procesu klasifikace snímky s vyšším prostorovým rozlišením.

V budoucích výzkumných pracích mohou být zahrnuty další faktory, které mají vliv na distribuci lesního porostu (nadmořská výška, geologické podloží, sklon, průměrná teplota...).

## POUŽITÉ ZDROJE INFORMACÍ

- ARCGIS RESOURCES. 2015. *ArcGIS Resources* [online]. 2015 [cit 2015-04-24].  
Dostupné z URL:< <http://resources.arcgis.com/en/home/>>.
- ARTHUR, J. 2008. Spatial autocorrelation. *Salisbury University*[online]. 2014 [cit 2014-06-16].  
Dostupné z URL:< <http://faculty.salisbury.edu/~ajlembo/419/lecture15.pdf>>.
- BIODIVERZITA. 2014. *Co je to biodiverzita?* [online]. 2014 [cit 2014-07-05]. Dostupné z  
URL:< <http://biologie.xf.cz/EVVO/Biodiverzita.pdf>>.
- BRIGGS, J. M. ...[et al.] 1991. Seasonal Variation of Heterogeneity in the Tallgrass Prairie: A  
Quantitative Measure Using Remote Sensing. *Photogrammetric engineering and remote  
sensing* [online]. 1991 vol. 57, issue 4 [cit. 2014-04-20] p. 407-411. ISSN 0099-1112. Dostupné  
z URL:<<http://cat.inist.fr/?aModele=afficheN&cpsidt=19600163>>.
- COOPS, N. C. ...[et al.] 2010. Assessing changes in forest fragmentation following infestation  
using time series Landsat imagery. *Forest Ecology and Management* [online]. 2010 vol. 259,  
issue 12 [cit. 2014-04-20] p. 2355-2365. Dostupné z URL:<  
<http://www.sciencedirect.com/science/article/pii/S0378112710001544>>.
- ČERVENÁ, L. 2012. *Klasifikace vegetačního pokryvu z dat DPZ pro účely vyhodnocení rizika  
náklady klišťovou encefalitidou*. Praha, 2012. 78 s. Bakalářská práce na Přírodovědecké fakultě  
Univerzity Karlovy na katedře aplikované geoinformatiky a kartografie.
- ČZU SKRIPTA : *Druhá dominace a diverzita* [online]. 2014 [cit 2014-04-26]. Dostupné z  
URL:< [http://etext.czu.cz/php/skripta/kapitola.php?titul\\_key=68&idkapitola=54](http://etext.czu.cz/php/skripta/kapitola.php?titul_key=68&idkapitola=54)>.
- DVOŘÁK, J. 2005. Diverzita, produkce a adaptabilita bezobratlých živočichů v mokřadech.  
[online]. 2005 [cit 2014-07-05]. Dostupné z  
URL:<[http://www.eamos.cz/amos/kek/externi/kek\\_407/07/07.htm](http://www.eamos.cz/amos/kek/externi/kek_407/07/07.htm)>.
- ESRI. 2014. *About ESRI* [online]. 2014 [cit. 2014-08-04]. Dostupné z URL:  
<<http://www.esri.com/about-esri>>.
- EXELIS. 2015. *Exelis Visual Information Solutions* [online]. 2015 [cit. 2015-04-04]. Dostupné  
z URL: <<http://www.exelisvis.com/Home.aspx>>.
- FROHN, R. C. 1998. *Remote Sensing for Landscape Ecology : New Metric Indicators for  
Monitoring, Modeling and Assessment of Ecosystems* [online]. 2000 [cit. 2015-04-04].  
Dostupné z URL: <<https://books.google.cz/books?hl=cs&lr=&id=OFMSzVM->

bh8C&oi=fnd&pg=PA1&dq=remote+sensing+for+landscape+ecology+new+metric+indicators+for+monitoring+frohn+free+online&ots=6JfnWcxOUB&sig=lfWIUMlok8v6QOPHheJEA9kINFo&redir\_esc=y#v=onepage&q&f=false>.

GISAT. *Družicové snímky* [online]. 2011 [cit 2014-04-24]. Dostupné z URL:<<http://www.gisat.cz/content/cz>>.

GLOBAL MEASURES OF SPATIAL AUTOCORRELATION. *Briggs Hennen University* [online]. 2010 [cit 2015-02-16]. Dostupné z URL:<<http://www.utdallas.edu/~briggs/henan/10SAglobal.ppt>>.

GLOSOVÁ, P. 2013. *Zjištění prostorové struktury typologických snímků lesní vegetace*. Brno, 2013. 57 s. Bakalářská práce na Přírodovědecké fakultě Masarykovy univerzity.

GOND, V. ...[et al.] 2013. Vegetation structure and greenness in Central Africa from Modis multi-temporal data. *Philosophical Transactions of The Royal Society* [online]. 2012 [cit 2015-05-16]. p. 1-8 Dostupné z URL:<<http://www.ncbi.nlm.nih.gov/pmc/articles/PMC3720027/pdf/rstb20120309.pdf>>.

GRIFFITH, D.A. 2009. Spatial autocorrelation. *Elsevier Inc.* [online]. 2014 [cit 2014-06-16]. p. 1-10 Dostupné z URL:< <http://booksite.elsevier.com/brochures/hugy/SampleContent/Spatial-Autocorrelation.pdf>>.

GROSS, L.J. ...[et al.] 2000. Diversity indices: Shannon's H and E. *Alternative Routes to Quantitative Literacy for the Life Sciences* [online]. 2000 [cit 2014-07-05]. Dostupné z URL:<<http://www.tiem.utk.edu/~gross/bioed/bealsmodules/shannonDI.html>>.

HELMER E.H. ...[et al.] 2012. Detailed maps of tropical forest types are within reach: Forest tree communities for Trinidad and Tobago mapped with multiseason Landsat and multiseason fine-resolution imagery. *Forest Ecology and Management* [online]. 2012 [cit 2015-05-05]. Dostupné z URL:< [http://www.fs.fed.us/global/iitf/pubs/ja\\_iitf\\_2012\\_helmer001.pdf](http://www.fs.fed.us/global/iitf/pubs/ja_iitf_2012_helmer001.pdf)>.

HINNER, M. 1999. Výpočet fraktální dimenze. *Jemný úvod do fraktálů* [online]. 1999 [cit 2014-07-05]. Dostupné z URL:<<http://martin.hinner.info/math/Fraktaly/vypocet.php>>.

HORÁK, J. 2002. Prostorové analýzy. *Institut Geoinformatiky – Vysoká škola Báňská, Technická univerzita Ostrava* [online]. 2002 [cit. 2014-06-06]. Dostupné z URL:<<http://gis.vsb.cz/pad/obsah.htm>>.

INFORMAČNÍ SYSTÉM MASARYKOVY UNIVERZITY : *DPZ cvičení* [online]. 2014 [cit 2014-04-26]. Dostupné z URL:< [http://is.muni.cz/www/680/7404989/dpz\\_dzo/](http://is.muni.cz/www/680/7404989/dpz_dzo/)>.

IOANNIS, M., MELIADIS, M. 2011 : Multi-temporal Landsat image classification and change analysis of land cover/use in the Prefecture of Thessaloiniki, Greece. *Proceedings of the International Academy of Ecology and Environmental Sciences* [online]. vol 1, [cit 2015-05-05]. P. 15-25. Dostupné z URL:<<http://www.iaees.org/publications/journals/piaees/articles/2011-1%281%29/Multi-temporal-landsat-image.pdf>>.

IVAN, I. 2011. Prostorová ekonometrie a její aplikace při studiu docházky na zastávky VLD. [online]. 2011 [cit. 2014-06-06]. Dostupné z URL:<[http://gislinb.vsb.cz/~iva026/source/Prostorova\\_autokorelace.pdf](http://gislinb.vsb.cz/~iva026/source/Prostorova_autokorelace.pdf)>.

KATEDRA SKLÁŘSKÝCH STROJŮ A ROBOTIKY: *Fraktální geometrie a fraktály* [online]. 2011 [cit 2014-05-20]. Dostupné z URL:< <http://www.ksr.tul.cz/fraktaly/geometrie.html>>.

KOVACS, J.M...[et al.] 2011. A field based statistical approach for validating a remotely sensed mangrove forest classification scheme. *Wetlands Ecol Manage* [online]. vol. 19 [cit 2015-04-04]. p. 409-421. Dostupné z URL:<[http://www.researchgate.net/publication/251419608\\_A\\_field\\_based\\_statistical\\_approach\\_for\\_validating\\_a\\_remotely\\_sensed\\_mangrove\\_forest\\_classification\\_scheme](http://www.researchgate.net/publication/251419608_A_field_based_statistical_approach_for_validating_a_remotely_sensed_mangrove_forest_classification_scheme)>.

LAMONACA, A. ...[et al.] 2008. Exploring forest structural complexity by multi-scale segmentation of VHR imagery. *Remote Sensing of Environment* [online]. vol. 112 [cit 2015-04-04]. p. 2839-2849. Dostupné z URL:<<http://www.sciencedirect.com.ezproxy.is.cuni.cz/science/article/pii/S0034425708000540>>.

LANGER, T. 2007 : *Rozdíly v charakteru využití země v krajích ČR – využití metod prostorové autokorelace*. Brno, 2007. 33 s. Bakalářská práce na Přírodovědecké fakultě Masaríkovy univerzity na Geografickém ústavě.

LANGHAMMER, J. 2003: *DPZ Část 3 Řízená klasifikace, Spektrální indexy* [online]. 2015 [cit 2015-02-05]. Dostupné z URL:< <https://web.natur.cuni.cz/~langhamr/lectures/vtfg2/>>.

LIANG, L., SCHWARTZ. M. D. 2009. Landscape phenology an integrative approach to seasonal vegetation dynamics. *Landscape Ecol* [online]. vol. 24 [cit 2015-05-04]. p. 465-472. Dostupné z URL:< <http://media.proquest.com.ezproxy.is.cuni.cz/media/>>.

LIPSKÝ, Z. 1998: *Krajinná ekologie jako vědní obor* [online]. 2015 [cit 2015-04-05]. Dostupné z URL:<[https://is.muni.cz/el/1431/jaro2008/Z4066/Krajinna\\_ekologie-Zdenek\\_Lipsky.txt](https://is.muni.cz/el/1431/jaro2008/Z4066/Krajinna_ekologie-Zdenek_Lipsky.txt)>.

MCGARIGAL, K., MARKS, B. J. 1994. *Fragstats – Spatial Patterns Analysis Program For Quantifying Landscape Structure* [online]. 2012 [cit 2015-05-26]. Dostupné z URL:<<http://www.umass.edu/landeco/pubs/mcgarigal.marks.1995.pdf>>.

NATURAL RESOURCES MANAGEMENT AND ENVIRONMENT DEPARTMENT. 2014. *Biodiversity assessment* [online]. 2014 [cit 2014-07-05]. Dostupné z URL:<<http://www.fao.org/docrep/007/y5490e/y5490e0a.htm>>.

NEZDAŘILOVÁ, E. 1984. Prostorová autokorelace jako pojem a metoda geografické analýzy. *Sborník České geografické společnosti 89*. [online]. 1984 vol. 1 [cit. 2014-05-06]. Dostupné z URL:<[http://sreview.soc.cas.cz/uploads/6097969a40937f30519a0d976493521f0469993b\\_516\\_2008-4Spurna.pdf](http://sreview.soc.cas.cz/uploads/6097969a40937f30519a0d976493521f0469993b_516_2008-4Spurna.pdf)>.

PCI GEOMATICS. 2014 *About PCI Geomatics* [online]. 2014 [cit 2014-08-04]. Dostupné z URL: <<http://www.pcigeomatics.com/about-us/our-company>>.

READ, J. M. ...[et al.] 2002. Spatial methods for characterising land cover and detecting land/cover changes for the tropics. *Int. J. Remote Sensing* [online]. vol. 23, issue 12 [cit 2014-04-04]. p. 2457-2474. Dostupné z URL: <<http://www.tandfonline.com/doi/abs/10.1080/01431160110106140#U2amfld18Sg>>.

RICKLEFS, R. E., SCHLUTER, D. (eds.). 1993. *Species Diversity in Ecological Communities: Historical and Geographical Perspectives*. University of Chicago Press, paper \$27.95. 414 pp. ISBN: 0-226-71823-9.

RODRIGUEZ - GALIANO, V. H., CHICA-OLMO, M. (eds). 2011. Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. University of Southampton. *Remote Sensing of Environment* [online]. vol. 121 [cit 2015-05-20]. p. 93-107. Dostupné z URL: <<http://www.sciencedirect.com.ezproxy.is.cuni.cz/science/article/pii/S0034425711004408>>.

ROOT, E.D. 2011. Spatial autocorrelation. *Introduction to Quantitative Methods* [online]. 2014 [cit 2014-07-07]. Dostupné z URL:<[http://www.colorado.edu/geography/class\\_homepages/geog\\_4023\\_s11/Lecture08\\_SpatialAuto.pdf](http://www.colorado.edu/geography/class_homepages/geog_4023_s11/Lecture08_SpatialAuto.pdf)>.

SPURNÁ, P. 2008. Prostorová autokorelace – všudypřítomný jev při analýze prostorových dat? *Sociologický časopis*. [online]. 2008 vol. 44, issue 4 [cit. 2014-05-06]. Dostupné z URL:<[http://sreview.soc.cas.cz/uploads/6097969a40937f30519a0d976493521f0469993b\\_516\\_2008-4Spurna.pdf](http://sreview.soc.cas.cz/uploads/6097969a40937f30519a0d976493521f0469993b_516_2008-4Spurna.pdf)>.

TIŠNOVSKÝ, P. 2000. Fraktály. [online]. 2000 [cit 2014-07-05]. Dostupné z URL:<<http://www.fit.vutbr.cz/~tisnovpa/fract/clanky/1.htm>>.

WOLTER, P. T. ...[et al.] 1995. Improved Forest Classification in the Northern Lake States Using Multi-Temporal Landsat Imagery. *Photogrammetric Engineering & Remote Sensing* [online]. vol. 61 issue 9 [cit 2015-05-20]. p. 1129-1143. Dostupné z URL:<[http://eserv.asprs.org/PERS/1995journal/sep/1995\\_sep\\_1129-1143.pdf](http://eserv.asprs.org/PERS/1995journal/sep/1995_sep_1129-1143.pdf)>.

UC SANTA BARBARA DEPARTMENT OF GEOGRAPHY. 2014. *Walde Tobler* [online]. 2014 [cit 2014-07-05]. Dostupné z URL:<<http://www.geog.ucsb.edu/people/faculty/waldotobler.html>>.

USGS : *U.S. Geological Survey* [online]. 2013 [cit 2014-04-24]. Dostupné z URL:<<http://www.usgs.gov/>>.

ZUUR, A. 2005. Spatial autocorrelation. *San Francisco State University – Department of Biology* [online]. 2014 [cit 2014-06-16]. Dostupné z URL:<<http://userwww.sfsu.edu/efc/classes/biol710/spatial/spat-auto.htm>>.

## POUŽITÉ DATOVÉ ZDROJE

ArcČR 500: Digitální geografická databáze [cd-rom] © 2003 Arcdata Praha, s.r.o.

Corine land cover 2006, získaný od European Environmental Agency

Geoportál ČÚZK [online] © 2010 Geoportal.cuzk.cz. Dostupné z WWW:<<http://geoportal.cuzk.cz/>>. Citováno dne 20. dubna 2015.

Mapový server Mapy.cz [online] © 1996 – 2014 Seznam.cz, a.s. Dostupné z WWW:<<http://mapy.cz/>>. Citováno dne 8. srpna 2014.

LC81920262013215LGN00.tar (Multispektrální snímek Landsat 8 OLI z 3.8.2013) [online]. U.S. Geological Survey. Staženo dne 27. července 2014 z webových stránek <<http://earthexplorer.usgs.gov/>>.

LC81910262014067LGN00.tar (Multispektrální snímek Landsat 8 OLI z 8.3.2014) [online]. U.S. Geological Survey. Staženo dne 27. července 2014 z webových stránek <<http://earthexplorer.usgs.gov/>>.

## SEZNAM PŘÍLOH

Příloha 1	Plochy lesní vegetace ve vybraných ORP
Příloha 2	Chybové matice
Příloha 3	Shannonův index a vyrovnanost u jednotlivých obcí
Příloha 4	Shannonův index a Shannonova vyrovnanost u ORP
Příloha 5	Globální Moranův index lesní vegetace
Příloha 6	Getis-Ord General G analýza lesní vegetace
Příloha 7	Trénovací množiny a kontrolní body
Příloha 8	Složení lesní vegetace ve vybraných ORP
Příloha 9	Shannon a lesní vegetace
Příloha 10	Lokální Moranův index jednotlivých tříd lesní vegetace
Příloha 11	Vztahy shlukování/odlehých hodnot jednotlivých tříd lesní vegetace
Příloha 12	Hot/cold spots jednotlivých tříd lesní vegetace
Příloha 13	Relativní četnost lesního porostu
Příloha 14	Prostorová autokorelace lesního porostu ze Shannonova indexu
Příloha 15	Náhled celého snímku – Landsat 8, LC81910262014067LGN00
Příloha 16	Náhled snímku – Landsat 8, LC81910262013208LGN00