

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA STROJNÍHO INŽENÝRSTVÍ
ÚSTAV MATEMATIKY

FACULTY OF MECHANICAL ENGINEERING
INSTITUTE OF MATHEMATICS

MATEMATICKÉ METODY SEGMENTACE OBRAZU PRO DÁLKOVÝ PRŮZKUM ZEMĚ

MATHEMATICAL METHODS OF IMAGE SEGMENTATION
FOR REMOTE SENSING APPLICATIONS

DOKTORSKÁ PRÁCE
DOCTORAL THESIS

AUTOR PRÁCE:
AUTHOR

Ing. JAN NOVOTNÝ

VEDOUČÍ PRÁCE:
SUPERVISOR

doc. PaedDr. DALIBOR MARTIŠEK, Ph.D.

BRNO 2015

Abstrakt

Segmentace obrazu na jednotlivé stromy je důležitý krok při zpracování dat dálkového průzkumu pro lesnickou praxi. Tato dizertační práce podává široký přehled dané problematiky. Shrnuje teoretický kontext z pohledu aplikované matematiky a základní pojmy leteckého snímání a laserového skenování. Matematické metody detekce pozice stromů jsou zaměřeny na adaptivní techniky umožňující přizpůsobení se charakteru zpracovávaného území. Pro fázi delineaace je představen nový přístup kombinující růstový algoritmus s aktivní konturou na okrajích koruny. Praktická část analyzuje parametrizaci všech algoritmů a rozebírá další praktické aspekty celé úlohy. Přílohou práce jsou spustitelné aplikace, které segmentaci realizují.

Summary

Segmentation of an image into individual tree crowns is a key step in the processing of remotely sensed data for forestry practice. The doctoral thesis gives a broad overview of this topic. It comprehends theoretical context from mathematical point of view and defines basic terms from airborne imaging and laser scanning. Mathematical methods of tree detection are focused on a robust adaptation to the actual conditions in a region of interest. A novel approach of crown area delineation is introduced, it combines a seeded region growing technique with an active contour as a crown boundary representation. The parametrisation of all algorithms is analysed in a practical half of the thesis and more application-oriented issues are mentioned. Executable computer programs are attached.

Klíčová slova

numerické metody analýzy obrazu, dálkový průzkum Země, segmentace jednotlivých korun, normalizovaný model povrchu, růstový algoritmus

Keywords

numerical image processing, remote sensing of environment, individual tree crown segmentation, canopy height model, seeded region growing technique

NOVOTNÝ, J. *Matematické metody segmentace obrazu pro dálkový průzkum Země*. Vysoké učení technické v Brně, Fakulta strojního inženýrství, 2015. 80 s. Vedoucí: doc. PaedDr. Dalibor Martišek, Ph.D.

Prohlašuji, že jsem dizertační práci Matematické metody segmentace obrazu pro dálkový průzkum Země vypracoval samostatně, pod vedením doc. PaedDr. Dalibora Martiška, Ph.D., s použitím materiálů uvedených v seznamu literatury.

Ing. Jan Novotný

Děkuji doc. Daliboru Martiškovi za vedení mé dizertační práce.

Děkuji Centru výzkumu globální změny AV ČR za poskytnutí reálných dat dálkového průzkumu pro testování algoritmů.

Děkuji kolegům z Ústavu matematiky FSI VUT v Brně a kolegům z Oddělení dálkového průzkumu Země AV ČR za komentáře a rady přispívající k mému výzkumu.

Děkuji svým rodinným příslušníkům za morální podporu a za pomoc se složitější sazbou a korekturami.

Ing. Jan Novotný

Obsah

Úvod	3
1 Teoretické pozadí	5
1.1 Používané pojmy z matematiky	5
1.1.1 Matematická analýza	6
1.1.2 Statistika	7
1.1.3 Numerické metody analýzy obrazu a vizualizace dat	9
1.1.4 Digitální topologie	16
1.1.5 Variační počet	17
1.2 Používané pojmy z dálkového průzkumu Země	18
1.2.1 Hyperspektrální snímkování	18
1.2.2 Laserové skenování	21
2 Matematické metody	23
2.1 Metody přípravy dat	24
2.1.1 Od bodového mračka k mapě výšek	24
2.1.2 Úpravy mapy výšek	25
2.1.3 Klasifikace typů pokryvu	27
2.2 Metody detekce stromů	28
2.2.1 Hledání lokálního maxima	28
2.2.2 Prahování	29
2.2.3 Hledání vzoru	30
2.2.4 Hledání kmenů	30
2.3 Metody delineace korun	33
2.3.1 Zaplavování	33
2.3.2 Metoda minimové sítě	33
2.3.3 Růstový algoritmus	34
3 Praktická část	37
3.1 Použitá reálná data	37
3.1.1 Data laserového skenování	37
3.1.2 Podpůrná data	38
3.2 Detekce pozice stromů	40

3.2.1	Filtrování	40
3.2.2	Prvotní vyhledání maxim	42
3.2.3	Očekávané rozměry koruny	42
3.2.4	Výběr z množiny maxim	43
3.2.5	Export výsledných pozic	46
3.3	Delineace plochy korun	47
3.3.1	Zaplavování	47
3.3.2	Minimová síť	48
3.3.3	Růstový algoritmus	52
3.3.4	Srovnání delineačních algoritmů	57
3.4	Hodnocení výsledků segmentace	58
3.4.1	Hodnocení kvality detekce	58
3.4.2	Hodnocení kvality delineace	59
3.4.3	Terénní šetření	60
3.5	Typ vstupních dat	62
3.5.1	Skenování versus snímkování	62
3.5.2	Postup segmentace pro hyperspektrální snímek	63
3.5.3	2D versus 3D	63
3.6	Využití výsledků v praxi	64
3.7	Počítačová implementace algoritmů	69
3.7.1	Programovací prostředí Lazarus	69
3.7.2	Programy, které jsou součástí práce	69
3.7.3	Výpočetní náročnost algoritmů	74
	Shrnutí	75
	Literatura	76
	Přílohy	80

Úvod

Dálkový průzkum Země patří mezi nejúspěšnější aplikace číslicového zpracování obrazových dat... napsali pánové Šonka a Hlaváč v knize Počítačové vidění v roce 1992. Následující dizertační práce mimo jiné ukazuje, že užitečné propojení těchto dvou oborů je velmi aktuální i o dvacet let později.

Numerické metody analýzy obrazu jsou aplikovaným odvětvím matematiky, které se zabývá zpracováním obrazové informace nejrůznějšího charakteru. Jedno z použití zná každý Čech i Japonec, a to úpravu fotografií z dovolené. Ani každodenní uživatel kdekeré rozšířené aplikace si možná neuvědomí, že dnes rutinní metody jako je úprava kontrastu či hledání obličejů stojí na pevných matematických základech. Ze tyto postupy musel někdo vymyslet a jejich účinnost a efektivitu odvodit často s pomocí vyšší matematiky v čele s funkcionální analýzou. Rozvoj numerických metod analýzy obrazu pochopitelně souvisí s rozvojem počítačů a počítačové grafiky, kouzlo klasické fotografie je jiná kapitola. Počítačové zpracování snímků, jednodušší i komplexnější, nalézá uplatnění v mnoha oborech lidské činnosti. Chceme-li uvést jediný příklad, bude to životně důležitý obor – lékařství. V této práci je nicméně pozornost zaměřena jinam.

Dálkový průzkum Země (DPZ) je aplikované odvětví vycházející z fyziky, matematiky a geografie, které v nejširším slova smyslu můžeme definovat jako sběr informací o objektech zájmu bez přímého kontaktu s nimi. Teorii elektromagnetického záření, která tento sběr dat umožňuje, se zabývat nebudeme. Nicméně informaci o objektech zájmu nejčastěji získáváme v podobě obrazu, čtenář si může pro začátek představit letecké snímky dostupné jako komplementární k mapám na internetu. Je tedy zřejmé, proč při analýze těchto snímků přichází ke slovu analýza obrazu. Také z historického pohledu mají oba obory mnoho společného. Moderní dějiny DPZ začínají s vynálezem klasické fotografie. A prudký rozvoj DPZ v posledních desetiletích souvisí s rostoucími možnostmi počítačů z hlediska uchování a zpracování velmi objemných obrazových dat.

Segmentace obrazu na objekty je jedna ze základních úloh analýzy obrazu. Jedná se o oblast důkladně probádanou, nabízející širokou škálu metod. Nicméně častým závěrem studií je, že každá praktická aplikace má svá specifika a vyžaduje nové metody nebo alespoň pečlivou adaptaci metod známých. V našem případě segmentujeme obraz lesa na jednotlivé stromy. Tento praktický produkt má své uplatnění při další analýze dat DPZ v aplikacích lesnických nebo též při zpracování problematiky městské zástavby a zeleně. Vývoj segmentačních algoritmů (pro lesnické aplikace DPZ) se táhne odbornou literaturou od 90. let 20. století. Postupně se mění zdroj použitých dat (od satelitního DPZ k leteckému) i jejich charakter (od snímkování k laserovému skenování) a prostorové rozlišení

(od metrů k centimetrům). Jednotlivé přístupy jsou tak stále vylepšovány, jejich adaptace na nové skutečnosti umožňuje kvalitnější výstup. Autor se touto oblastí výzkumu zabývá již 7 let, od diplomové práce, i v rámci zaměstnání v Oddělení dálkového průzkumu Země v Centru výzkumu globální změny, AV ČR. Tato dizertační práce představuje široký náhled na segmentační postup a jeho praktickou aplikaci na reálná data z prostředí lesů České republiky. Hlavní teoretický přínos tvoří nový segmentační algoritmus kombinující růstový algoritmus a aktivní konturu, viz cíl 1. Praktickým přínosem je rozbor parametrizace a aplikovatelnosti na reálná data, viz cíl 2 a rovněž kompletní softwarové zpracování celé problematiky, viz cíl 3.

Mezi hlavní cíle této práce patří:

1. Rozvinout inovativní přístup kombinující růstový algoritmus s aktivní konturou na hranici koruny. (kapitola 2, zejména odstavec 2.3.3)
2. Posoudit účinnost tří různých segmentačních algoritmů na vybraných lesních porostech. Určit optimální parametry segmentačních algoritmů pro homogenní porostní celky. Popsat vztahy mezi parametry vstupních dat a jednotlivých fází segmentace. (kapitola 3, zejména odstavce 3.2 a 3.3)
3. Softwarové zpracování segmentačního procesu. (odstavec 3.7 a příložené CD)

Práce je rozdělena do tří základních kapitol. První z nich (1) představuje teoretické pozadí práce, definujeme v ní vybrané pojmy z numerických metod analýzy obrazu a dalších odvětví matematiky, v rozsahu potřebném k odvození používaných algoritmů, a představujeme též základní principy DPZ, konkrétně hyperspektrálního snímkování a laserového skenování, v rozsahu potřebném pro porozumění datovým strukturám, s nimiž pracuje praktická část práce.

Další kapitola (2) obsahuje matematické metody zpracování obrazu používané při segmentaci korun. Proces členíme do tří fází, na předzpracování, detekci a delineaci. V závěrečném odstavci představujeme hlavní teoretický výsledek této práce – růstový algoritmus kombinovaný s aktivní konturou.

Třetí kapitola (3) pak rozebírá komplexně parametrizaci procesu segmentace a zabývá se z mnoha dalších pohledů praktickým zpracováním dat DPZ metodami analýzy obrazu. Jednotlivé podkapitoly se zabývají použitými datovými strukturami, parametrizací detekce a delineace, hodnocením výsledků segmentace, různými typy vstupních dat, využitím výsledků v praxi i počítačovou implementací algoritmů.

Kapitola 1

Teoretické pozadí

Tato dizertační práce představuje konkrétní aplikaci matematických metod, především analýzy obrazu, v praxi zpracování dat dálkového průzkumu Země. Proto v rámci teoretického úvodu uvedeme vybrané pojmy z numerických metod analýzy obrazu a dalších odvětví matematiky, v rozsahu potřebném k odvození používaných algoritmů. Dále představíme základní principy dálkového průzkumu Země, konkrétně hyperspektrálního snímkování a laserového skenování, v rozsahu potřebném pro porozumění datovým strukturám, s nimiž pracujeme.

1.1 Používané pojmy z matematiky

Segmentační algoritmy aplikované na datech dálkového průzkumu vycházejí z pojmů z několika matematických disciplín. Uvádíme v této kapitole jednotlivé pojmy poměrně strohým výčtem s občasným osvětlením souvislosti k problematice DPZ. Matematické věty nedokazujeme, laskavého čtenáře odkazujeme na primární zdroje.

V prvním odstavci definujeme pojmy z matematické analýzy, především reálnou funkci dvou proměnných, její lokální extrémy, pojem derivace a gradientu.

Ve druhém odstavci definujeme některé pojmy ze statistiky, především popisné, jako jsou výběrový průměr, medián a směrodatná odchylka, dále korelační analýza, testování hypotéz, regresní analýza a pojem semivariance (soběpodobnosti).

Ve třetím odstavci zmíníme v práci používané základní pojmy z teorie analýzy obrazu, tedy obecnou definici digitálního prostoru, jeho nosič a rozlišení, pojem obrazu, valuce, konvoluce a lineárního filtru. Dále z konkrétnějších pojmů obrazovou maticí, aditivní a impulzní šum, filtrování, objekty v obraze a metody jejich segmentace. Na pomezí analýzy obrazu a analýzy funkcí představujeme problematiku diskrétní Fourierovy transformace a její souvislost s konvolucí obrazů.

Ve čtvrtém odstavci upřesníme pojmy z práce s diskrétními obrazovými daty jako je sousedství obrazových bodů a jejich vzdálenost. Poslední odstavec matematické teorie vychází z variačního počtu a představuje koncepci adaptivní kontury, která je klíčová pro ústřední algoritmus celé práce.

1.1.1 Matematická analýza

V tomto odstavci se zaměřujeme na tři podoblasti matematické analýzy, respektive analýzy funkcí, které souvisí s výkladem podkapitoly 1.1.3 nebo se objeví dále v práci. Zaprvé se jedná o základní pojmy a výsledky týkající se extrémů funkce dvou proměnných, dále o pojmy směrové derivace a gradientu funkce dvou proměnných a zatřetí o problematiku diskrétní Fourierovy transformace zařazenou z důvodu lepší návaznosti až v odstavci 1.1.3. Používané definice uvádíme dle [15], [7] a [21].

Definice 1. Buď $M \subseteq \mathbb{R}^2$, $M \neq \emptyset$. Zobrazení $f : M \rightarrow \mathbb{R}$ nazveme *reálnou funkcí dvou reálných proměnných*. Množina M se nazývá *definiční obor* funkce f a značí se $\text{Dom}f$, množina $f(M)$ se nazývá *obor hodnot* funkce f a značí se $\text{Im}f$. Funkci dvou proměnných zapisujeme $z = f(x, y)$.

Definice 2. Buď f funkce dvou proměnných, $(x_0, y_0) \in \text{Dom}f$.

Pokud existuje konečná limita

$$\lim_{x \rightarrow x_0} \frac{f(x, y_0) - f(x_0, y_0)}{x - x_0},$$

nazýváme ji *parciální derivací* funkce f podle x v bodě (x_0, y_0) a značíme ji $\frac{\partial f}{\partial x}(x_0, y_0)$.

Pokud existuje konečná limita

$$\lim_{y \rightarrow y_0} \frac{f(x_0, y) - f(x_0, y_0)}{y - y_0},$$

nazýváme ji *parciální derivací* funkce f podle y v bodě (x_0, y_0) a značíme ji $\frac{\partial f}{\partial y}(x_0, y_0)$.

Definice 3. Buď V_2 dvojrozměrný vektorový prostor nad \mathbb{R} , f funkce dvou proměnných, $(x_0, y_0) \in \text{Dom}f$, $\vec{v} = (v_1, v_2) \in V_2$ a $t \in \mathbb{R}$. Položme $\varphi(t) = f(x_0 + tv_1, y_0 + tv_2)$. Má-li funkce φ derivaci v bodě 0, nazveme tuto derivaci *derivací* funkce f *ve směru* \vec{v} v bodě (x_0, y_0) a značíme ji $f_{\vec{v}}(x_0, y_0)$.

Definice 4. Řekneme, že funkce f nabývá v bodě (x^*, y^*) *lokálního maxima* (resp. *minima*), jestliže existuje okolí $\mathcal{O}(x^*, y^*)$ bodu (x^*, y^*) takové, že $\mathcal{O}(x^*, y^*) \subseteq \text{Dom}f$ a pro každé $(x, y) \in \mathcal{O}(x^*, y^*)$ platí $f(x, y) \leq f(x^*, y^*)$ (resp. $f(x, y) \geq f(x^*, y^*)$). Jsou-li tyto nerovnosti pro $(x, y) \neq (x^*, y^*)$ ostré, mluvíme o ostrém lokálním maximu (resp. minimu). (Ostrá) lokální maxima a minima nazýváme souhrnně (ostré) *lokální extrémy*.

Definice 5. Řekneme, že $(x^*, y^*) \in \mathbb{R}^2$ je *stacionárním bodem* funkce f , jestliže f má v tomto bodě parciální derivace podle obou proměnných a platí

$$\frac{\partial f}{\partial x}(x^*, y^*) = \frac{\partial f}{\partial y}(x^*, y^*) = 0.$$

Věta 6. Nechť funkce f má v bodě $(x^*, y^*) \in \mathbb{R}^2$ lokální extrém a nechť v tomto bodě existují obě parciální derivace funkce f . Pak (x^*, y^*) je stacionárním bodem funkce f .

Data laserového skenování představují 3D strukturu povrchu, tedy k nim přistupujeme jako k reálné funkci dvou proměnných. Pozici stromu například hledáme jako lokální maximum výšky, přičemž tradiční definici lokálního extrému diskretizujeme, viz definice okolí bodu v odstavci 1.1.3.

Definice 7. Je-li $X_0 = [x_0, y_0] \in D(f) \subseteq \mathbb{R}^2$ bod definičního oboru diferencovatelné funkce f dvou proměnných, pak *gradientem* funkce f v bodě X_0 rozumíme vektor

$$\text{grad } f(X_0) = \left[\frac{\partial f}{\partial x}(X_0), \frac{\partial f}{\partial y}(X_0) \right].$$

Grafem funkce dvou proměnných je plocha v prostoru. Gradient funkce v bodě X_0 je vektor, který udává směr nejstrmějšího stoupání této plochy v bodě X_0 a velikost tohoto gradientu

$$|\text{grad } f(X_0)| = \sqrt{\left[\frac{\partial f}{\partial x}(X_0) \right]^2 + \left[\frac{\partial f}{\partial y}(X_0) \right]^2}$$

zároveň kvantifikuje strmost stoupání. Toho lze použít k hledání hranice objektů v obraze způsobem popsaným v podkapitole 1.1.3.

1.1.2 Statistika

V tomto odstavci uvádíme vybrané pojmy z popisné statistiky. Předpokládáme běžnou definici pravděpodobnostního prostoru, náhodné veličiny a jejích charakteristik. K obrazu a případně dalším praktickým datům z řešené problematiky dálkového průzkumu se vztahuje pojem náhodného výběru a jeho charakteristiky. V práci používané definice uvádíme dle [20], [1] a [14].

Definice 8. Opakujeme-li n -krát nezávisle na sobě pokus, jehož výsledek je náhodná veličina X s distribuční funkcí $F(X)$, pozorujeme vlastně náhodný vektor $\mathbb{X} = (X_1, \dots, X_n)$, jehož složky jsou vzájemně nezávislé náhodné veličiny s touž distribuční funkcí $F(X)$. Pro takový vektor používáme označení *náhodný výběr*, počet opakování se nazývá *rozsah* náhodného výběru.

Definice 9. Výběrový průměr:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

Definice 10. *Medián* je prostřední prvek setříděného výběru. V případě sudého počtu prvků počítáme průměr dvou prostředních prvků.

Definice 11. Výběrový rozptyl:

$$S_X^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

Definice 12. Výběrová směrodatná odchylka:

$$S_X = \sqrt{S_X^2}$$

Definice 13. Výběrová kovariance:

$$S_{XY} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$$

Definice 14. Výběrový korelační koeficient:

$$r = \frac{S_{XY}}{\sqrt{S_X^2 S_Y^2}}$$

Výše definované pojmy používáme mj. při běžném vyhodnocování výsledků segmentace, při definování filtrů a při srovnávání obrazů pomocí korelační analýzy. Korelační analýzou máme na mysli posuzování shodnosti dvou náhodných výběrů (matic, obrazů) podle hodnoty výběrového korelačního koeficientu. Při vyhodnocování výsledků segmentace dále používáme testování statistických hypotéz a regresní analýzu. Základní definice z těchto oblastí uvádíme dle [20].

Definice 15. Buď $D = \{d_1, d_2\}$ množina možných rozhodnutí. Buď Ω parametrický prostor příslušného experimentu, θ jeho prvky. Uvažujme rozdělení prostoru Ω na dvě části, řekněme ω a $\bar{\omega} = \Omega - \omega$, kde při $\theta \in \omega$ je výhodnější rozhodnutí d_1 než d_2 a při $\theta \in \bar{\omega}$ je výhodnější rozhodnutí d_2 než d_1 . Takový rozhodovací problém nazýváme *úlohou testu statistické hypotézy*. Tvrzení „ $\theta \in \omega$ “ označíme jako hypotézu H a opačné tvrzení „ $\theta \in \bar{\omega}$ “ jako alternativní hypotézu A .

Jestliže je hypotéza H správná, tj. jestliže ve skutečnosti je θ prvkem ω , pak je na místě rozhodnutí d_1 ; volbu rozhodnutí d_1 označujeme tedy jako přijetí hypotézy H a volbu rozhodnutí d_2 jako zamítnutí H (čili přijetí alternativní hypotézy A). Pravidlo, podle kterého se na základě náhodného experimentu rozhoduje, zda danou hypotézu přijmout či zamítnout, se nazývá *test hypotézy H* .

Rozhodnutí „zamítnout hypotézu H “, když ve skutečnosti je H správná, se nazývá *chyba 1. druhu*. Rozhodnutí „nezamítnat hypotézu H “, když ve skutečnosti je správná alternativní hypotéza A , se nazývá *chyba 2. druhu*.

Definice 16. Mějme jednu vysvětlující proměnnou x a necht' podmíněná střední hodnota náhodné veličiny Y pro danou hodnotu x je rovna $E(Y|x) = \beta_0 + \beta_1 x$. Tato funkce se nazývá *regresní přímka*.

Pro adaptivní analýzu částí obrazu dále potřebujeme pojem semivariogramu, který v praxi obrazových dat popisuje soběpodobnost pixelů v závislosti na jejich vzdálenosti. Jeho prvky $\gamma(h)$ počítáme jako součet přes všechny dvojice pixelů, jejich vzdálenost je rovna h (počet takových dvojic budiž n):

$$\gamma(h) = \frac{1}{n} \sum (x_i - x_j)^2$$

1.1.3 Numerické metody analýzy obrazu a vizualizace dat

Vybrané pojmy z matematického zpracování obrazu, viz též [21] nebo [33].

Definice 17. Necht' ${}_kI = \{0, 1, \dots, i_k, \dots, m_k\}; k \in \{1, 2, \dots, n\}$ jsou indexové množiny. Pak množinu

$$\mathbf{I}^{(n)} = \bigtimes_{k=1}^n {}_kI$$

nazýváme multiindexem.

Definice 18. Necht' ${}_kJ = \langle a_k; b_k \rangle; k \in \{1, 2, \dots, n\}$ jsou intervaly. Množinu $\mathbf{J}^{(n)} = \bigtimes_k J$ nazýváme n -rozměrným nosičem digitálního prostoru.

Definice 19. Necht' ${}_kD = \{{}_kx_0, {}_kx_1, \dots, {}_kx_{i_k}, \dots, {}_kx_{m_k}\}; k \in \{1, 2, \dots, n\}$ jsou ekvidistantní dělení intervalů ${}_kJ = \langle a_k; b_k \rangle$. Množinu $\mathbf{D}^{(n)} = \bigtimes_k D$ nazýváme ekvidistantním multidělením nosiče $\mathbf{J}^{(n)}$.

Definice 20. Necht' $\mathbf{J}^{(n)} = \bigtimes_k J$ je nosič digitálního prostoru, $\mathbf{D}^{(n)} = \bigtimes_k D$ jeho ekvidistantní multidělení. Uspořádanou dvojici $\mathcal{D}^{(n)} = (\mathbf{J}^{(n)}; \mathbf{D}^{(n)})$ nazýváme n -rozměrným digitálním prostorem. Uspořádanou n -tici $\mathbf{r} = (m_1, m_2, \dots, m_k, \dots, m_n)$ nazýváme rozlišení prostoru $\mathcal{D}^{(n)}$.

Definice 21. Podmnožinu $\mathbf{F}^{(n)} \subset \mathbf{J}^{(n)}$ nosiče $\mathbf{J}^{(n)}$ digitálního prostoru $\mathcal{D}^{(n)} = (\mathbf{J}^{(n)}; \mathbf{D}^{(n)})$ nazýváme fyzickou $n - D$ doménou právě tehdy, když

$$\mathbf{F}^{(n)} = \langle {}_1x_{i_1}; {}_1x_{i_1+1} \rangle \times \langle {}_2x_{i_2}; {}_2x_{i_2+1} \rangle \times \dots \times \langle {}_kx_{i_k}; {}_kx_{i_k+1} \rangle \times \dots \times \langle {}_nx_{i_n}; {}_nx_{i_n+1} \rangle.$$

Zapisujeme $\mathbf{F}^{(n)} = \bigtimes \langle {}_kx_{i_k}; {}_kx_{i_k+1} \rangle = \mathbf{F}_{[i_1, i_2, \dots, i_k, \dots, i_n]}^{(n)} = \mathbf{F}_{\mathbf{i}}^{(n)}$. Číslo ${}_kv_{\mathbf{i}} = {}_k x_{i_k+1} - {}_k x_{i_k}; i_k \in \mathbf{i}$ nazýváme k -tým rozměrem fyzické $n - D$ domény $\mathbf{F}_{\mathbf{i}}^{(n)}$.

Věta 22. Množina $\mathcal{F}^{(n)} = \{\mathbf{F}^{(n)} = \bigtimes \langle {}_kx_{i_k}; {}_kx_{i_k+1} \rangle; i_k \in {}_kI\}$ všech fyzických domén nosiče $\mathbf{J}^{(n)}$ digitálního prostoru $\mathcal{D}^{(n)} = (\mathbf{J}^{(n)}; \mathbf{D}^{(n)})$ je rozkladem nosiče $\mathbf{J}^{(n)}$.

Věta 23. Necht' $\mathcal{D}^{(n)} = (\mathbf{J}^{(n)}; \mathbf{D}^{(n)})$ je digitální prostor, $A, B \in \mathbf{J}^{(n)}$ libovolné body jeho nosiče. Relace $\rho \subset \mathbf{J}^{(n)} \times \mathbf{J}^{(n)}$ definovaná vztahem $\rho(A, B) \Leftrightarrow \exists \mathbf{F}_{\mathbf{i}} \in \mathcal{F}^{(n)} : A \in \mathbf{F}_{\mathbf{i}} \wedge B \in \mathbf{F}_{\mathbf{i}}$ je ekvivalence na $\mathbf{J}^{(n)}$.

Definice 24. Faktorovou množinu $\mathcal{F}^{(n)} = \mathbf{J}^{(n)} | \rho$ z předchozí věty nazýváme fyzickým prostorem nosiče $\mathbf{J}^{(n)}$ respektive prostoru $\mathcal{D}^{(n)} = (\mathbf{J}^{(n)}; \mathbf{D}^{(n)})$. Rozlišením fyzického prostoru $\mathcal{F}^{(n)}$ rozumíme rozlišení prostoru $\mathcal{D}^{(n)}$.

Definice 25. Necht' $\mathcal{F}^{(n)}$ je fyzický prostor digitálního prostoru $\mathcal{D}^{(n)}$, ${}_kv$ rozměry jeho fyzických domén. Dále necht' $\mathbf{C} \in \mathbf{J}^{(n)} : \mathbf{C} = [c_1, c_2, \dots, c_k, \dots, c_n]; c_k \in \langle 0; {}_kv \rangle$. Množinu

$${}_{\mathbf{C}}\mathcal{L}^{(n)} = \times \{ {}_kr_{i_k} \in \mathbb{R} | \forall k \in \{1, 2, \dots, n\} : {}_kr_{i_k} \in \langle {}_1x_{i_k}; {}_1x_{i_k+1} \rangle \wedge {}_kr_{i_k} - {}_k x_{i_k} = c_k \}$$

nazýváme logickým prostorem prostoru $\mathcal{D}^{(n)} = (\mathbf{J}^{(n)}; \mathbf{D}^{(n)})$, její prvky

$${}_{\mathbf{C}}L_{\mathbf{i}}; \mathbf{i} = [i_1, i_2, \dots, i_k, \dots, i_n]$$

nazýváme logické domény. Rozlišením logického prostoru ${}_{\mathbf{C}}\mathcal{L}^{(n)}$ rozumíme rozlišení prostoru $\mathcal{D}^{(n)}$.

Věta 26. Necht' $\mathcal{F}^{(n)}$ je fyzický prostor, ${}_{\mathbf{C}}\mathcal{L}^{(n)}$ logický prostor téhož digitálního prostoru $\mathcal{D}^{(n)} = (\mathbf{J}^{(n)}; \mathbf{D}^{(n)})$. Zobrazení ${}_{\mathbf{C}}\varphi: \mathcal{F}^{(n)} \rightarrow {}_{\mathbf{C}}\mathcal{L}^{(n)}$ takové, že ${}_{\mathbf{C}}\varphi(\mathbf{F}_i) = {}_{\mathbf{C}}L_i \Leftrightarrow L_i \in \mathbf{F}_i$, je bijekce.

Definice 27. Zobrazení ${}_{\mathbf{C}}\varphi: \mathcal{F}^{(n)} \rightarrow {}_{\mathbf{C}}\mathcal{L}^{(n)}$ z předchozí věty nazýváme mapování fyzického prostoru $\mathcal{F}^{(n)}$. Bod $\mathbf{C} \in \mathbf{J}^{(n)}: \mathbf{C} = [c_1, c_2, \dots, c_k, \dots, c_n]; c_k \in \langle 0; {}_k v \rangle$ nazýváme jeho řídicím bodem.

Definice 28. Mapování ${}_{\mathbf{V}}\varphi: \mathcal{F}^{(n)} \rightarrow {}_{\mathbf{V}}\mathcal{L}^{(n)}$, jehož řídicím bodem je bod $\mathbf{V} = [0, 0, \dots, 0]$, nazýváme vrcholovým mapováním. Mapování ${}_{\mathbf{S}}\varphi: \mathcal{F}^{(n)} \rightarrow {}_{\mathbf{S}}\mathcal{L}^{(n)}$, jehož řídicím bodem je bod $\mathbf{S} = [\frac{1v}{2}, \frac{2v}{2}, \dots, \frac{k v}{2}, \dots, \frac{n v}{2}]$, nazýváme středovým mapováním.

Definice 29. Necht' $\mathcal{D}^{(n)} = (\mathbf{J}^{(n)}; \mathbf{D}^{(n)})$ je digitální prostor, ${}_k v$ rozměry jeho domén, ${}_{\mathbf{C}}\varphi: \mathcal{F}^{(n)} \rightarrow {}_{\mathbf{C}}\mathcal{L}^{(n)}$ libovolné mapování. Dále necht' \mathbf{R}^n je n -dimenzionální reálný vektorový prostor s bází $\{\mathbf{e}_k\}_{k=1}^n; \mathbf{e}_k = (0, 0, \dots, {}_k v, \dots, 0)$. Uspořádanou $(n+2)$ -tici $L = \langle \mathcal{L}^{(n)}, S, \mathbf{e}_2, \mathbf{e}_1, \dots, \mathbf{e}_k, \dots, \mathbf{e}_n \rangle$ nazýváme světovou souřadnou soustavou logického prostoru $\mathcal{L}^{(n)}$. Uspořádanou $(n+2)$ -tici $F = \langle \mathcal{F}^{(n)}, S, \mathbf{e}_2, \mathbf{e}_1, \dots, \mathbf{e}_k, \dots, \mathbf{e}_n \rangle$ nazýváme světovou souřadnou soustavou fyzického prostoru $\mathcal{F}^{(n)}$ indukovanou mapováním ${}_{\mathbf{C}}\varphi$. Uspořádanou $(n+2)$ -tici $D = \langle \mathcal{D}^{(n)}, S, \mathbf{e}_2, \mathbf{e}_1, \dots, \mathbf{e}_k, \dots, \mathbf{e}_n \rangle$ nazýváme světovou souřadnou soustavou digitálního prostoru $\mathcal{D}^{(n)}$ indukovanou mapováním ${}_{\mathbf{C}}\varphi$.

Při práci s obrazovými daty dálkového průzkumu je korektní zacházení se souřadnými systémy včetně mapování velmi důležité. Neboť jenom to umožňuje kombinaci obrazů stejného reálného území pořízených v různém čase, případně různou technikou (různým senzorem). Není-li uvedeno jinak, používáme v této práci středové mapování.

Definice 30. Necht' $\mathcal{F}^{(n)}$ je fyzický prostor, A je libovolná, minimálně dvouprvková množina. Zobrazení $\beta_{\mathcal{F}}: \mathcal{F}^{(n)} \rightarrow A$ nazýváme obecnou valuací fyzického prostoru $\mathcal{F}^{(n)}$. Je-li A číselná množina, nazýváme valuaci β numerickou valuací.

V obrazových datech dálkového průzkumu a tedy též v této práci se nejčastěji setkáme s valuací reálnou, případně celočíselnou, kdy $A \subset \mathbb{R}$, respektive $A \subset \mathbb{Z}$.

Definice 31. Necht' $\mathbf{J}^{(n)}$ je nosič digitálního prostoru. Funkci $g(\mathbf{x})$ definovanou pro každé $\mathbf{x} = [x_1, x_2, \dots, x_n] \in \mathbb{R}^n$ nazveme vzorkovanou právě tehdy, když $\forall \mathbf{x} \in \mathbf{J}^n: g(\mathbf{x}) = g(\text{Trunc}(\mathbf{x}))$, kde $\text{Trunc}(\mathbf{x}) = [\text{Trunc}(x_1), \text{Trunc}(x_2), \dots, \text{Trunc}(x_n)]$. (Označení $\text{Trunc}(t)$ používáme pro dolní celou část reálného čísla t .)

Výše používané n -rozměrné definice pojmů mají svůj význam například ve vizualizaci dat, nicméně v realitě obrazových dat dálkového průzkumu v této práci pochopitelně pracujeme především s dvojrozměrnými obrazy ($n = 2$), pouze v několika odstavcích se lehce dotýkáme problematiky práce ve 3D. Následující definice a věty proto vyslovíme pouze pro dvojrozměrný případ.

Definice 32. Necht' $W = \langle 0; w \rangle \subset \mathbb{R}; w \in \mathbb{N}; H = \langle 0; h \rangle \subset \mathbb{R}; h \in \mathbb{N}; V = \langle v_1; v_2 \rangle \subset \mathbb{R}$ jsou intervaly. Funkci $I: W \times H \rightarrow V^m$, kde m je počet barevných složek, nazveme

(analogovým) obrazem. Je-li funkce I vzorkovaná, hovoříme o vzorkovaném obrazu, je-li definičním oborem $W \times H$ funkce I fyzická (logická) rovina, hovoříme o fyzickém (logickém) obrazu. Rozlišením fyzického (logického) obrazu rozumíme rozlišení jeho nosiče. Je-li funkce I vzorkovaná a $H \subset \mathbb{N}$, hovoříme o digitálním obrazu. Číslo h nazýváme barevnou hloubkou (dynamickým rozsahem) obrazu.

Barevné obrazy (jako jsou fotografie) bývají třísloužkové (například RGB). Hyperspektrální snímky (viz odstavec 1.2.1) mívají složek několik desítek i stovek, naopak modely odvozené z laserového skenování (viz odstavec 1.2.2) bývají jednosložkové, podobně jako obrázky v odstínech šedi. Při zpracování vícesložkových obrazů většinou postupujeme po jednotlivých složkách, proto ve zbytku práce vesměs uvažujeme $m = 1$.

Definice 33. 2D konvolucí dvou funkcí $\mathbf{C}(\mathbf{x})$, $g(\mathbf{x})$ definovaných pro každé

$$\mathbf{x} = [x_1, x_2] \in \mathbf{J}^2$$

a na množině \mathbf{J}^2 integrovatelných s kvadrátem rozumíme integrál

$$\mathbf{C}(\mathbf{x}) * g(\mathbf{x}) = \int_{\mathbf{J}^2} \mathbf{C}(\mathbf{t})g(\mathbf{x} - \mathbf{t})d\mathbf{t}.$$

Věta 34. Jsou-li $\mathbf{C}(\mathbf{x})$, $g(\mathbf{x})$ digitalizované funkce a na \mathbf{J}^2 je definovaná fyzická rovina s jednotkovou velikostí fyzických pixelů, pak

$$\mathbf{C}(\mathbf{F}_{ij}) * g(\mathbf{F}_{ij}) = \sum_{m=-\varepsilon}^{\varepsilon} \sum_{n=-\varepsilon}^{\varepsilon} \mathbf{C}(\mathbf{F}_{mn}) g(\mathbf{F}_{i-m, j-n}) = \sum_{m=-\varepsilon}^{\varepsilon} \sum_{n=-\varepsilon}^{\varepsilon} \mathbf{C}(m, n) g(i - m, j - n).$$

Vzhledem k tomu, že digitalizovaný obraz má diskrétní a konečný obor hodnot, musí být hodnota této konvoluce zaokrouhlena a případně ořezána. Pro $n = 2$ je $\mathbf{C}(m, n)$ „dvojměrná tabulka“ reálných hodnot – matice. Tu lze formálně definovat jako zobrazení $\mathbf{C}(m, n) : \{-\varepsilon_1, \dots, 0, \dots, \varepsilon_1\} \times \{-\varepsilon_2, \dots, 0, \dots, \varepsilon_2\} \rightarrow \mathbb{R}$.

Pro kvantifikaci různých úrovní informace v obraze a též úpravu některých vlastností obrazu potřebujeme pojem diskrétní Fourierovy transformace a jejího amplitudového a fázového spektra.

Definice 35. Nechtě $\{x_{m,n}\}; m = 0, 1, \dots, M - 1; n = 0, 1, \dots, N - 1$ je dvojměrná posloupnost komplexních čísel. Dvojměrnou posloupnost $\{X_{k,l}\} = \mathcal{F}(\{x_{m,n}\}); k = \vartheta + \omega m; l = \lambda + \omega n; \omega \in \mathbb{Z}$, kde

$$X_{k,l} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} x_{m,n} \exp\left(\frac{-im2\pi k}{M}\right) \exp\left(\frac{-in2\pi l}{N}\right),$$

nazýváme diskrétní Fourierovou transformací dvojměrné posloupnosti $\{x_{m,n}\}$.

Definice 36. Necht' $\{X_{k,l}\}; k = 0, 1, \dots, M - 1; l = 0, 1, \dots, N - 1$ je dvojrozměrná posloupnost komplexních čísel. Posloupnost $\{x_{m,n}\} = \mathcal{F}^{-1}(\{X_{k,l}\}); m = \mu + \omega M; n = \nu + \omega N; \omega \in \mathbb{Z}$, kde

$$x_{m,n} = \frac{1}{MN} \sum_{k=0}^{M-1} \sum_{l=0}^{N-1} X_{k,l} \exp\left(\frac{im2\pi k}{M}\right) \exp\left(\frac{in2\pi l}{N}\right),$$

nazýváme zpětnou diskretní Fourierovou transformací dvojrozměrné posloupnosti $\{X_{k,l}\}$.


Definice 37. Necht' $\{X_{k,l}\}; k = \vartheta + \nu n; l = \lambda + \nu n; \vartheta, \lambda \in \mathbb{N}; \nu \in \mathbb{Z}$, je diskretní Fourierova transformace posloupnosti $\{x_{m,n}\}; m = 0, 1, \dots, M - 1; n = 0, 1, \dots, N - 1$. Množinu $\{|X_{k,l}|\} = \{\sqrt{\operatorname{Re}^2(X_{k,l}) + \operatorname{Im}^2(X_{k,l})}\}; k = \vartheta + \nu n; l = \lambda + \nu n; \vartheta, \lambda \in \mathbb{N}; \nu \in \mathbb{Z}$ nazveme amplitudovým spektrem posloupnosti $\{X_{k,l}\}$. Množinu $\{|\arg X_{k,l}|\} = \{\operatorname{arctg} \frac{\operatorname{Re}(X_{k,l})}{\operatorname{Im}(X_{k,l})}\}; k = \vartheta + \nu n; l = \lambda + \nu n; \vartheta, \lambda \in \mathbb{N}; \nu \in \mathbb{Z}$ nazveme fázovým spektrem posloupnosti $\{X_{k,l}\}$.

Díky definicím 36 a 37 a vzhledem k Eulerově identitě $e^{ix} = \cos x + i \sin x$ můžeme každý obraz chápat jako součet periodických signálů vhodných amplitud a frekvencí. Amplitudové spektrum udává amplitudy příslušných frekvencí. Hovoříme-li o nízkých či vysokých prostorových frekvencích v obraze, máme na mysli právě frekvence ve smyslu Fourierovy transformace.

Amplitudové spektrum obrazu můžeme chápat rovněž jako obraz. Protože obraz, který zpracováváme ($x_{m,n}$ v definici 35) je reálný, jeho Fourierova transformace je středově souměrná podle počátku. Tento počátek proto většinou zobrazujeme ve středu amplitudového spektra. Nízké prostorové frekvence jsou tak v blízkosti středu amplitudového spektra, směrem k jeho okrajům prostorové frekvence rostou. Vyšší prostorové frekvence v amplitudovém spektru mohou signalizovat vysoký kontrast a ostrost obrazu (viz obrázek 1.1), anebo také šum.

Vzhledem k obvyklému charakteru obrazových dat DPZ nejčastěji pracujeme s maticovou reprezentací obrazu podle definice 32 pro $k = 2$. Obraz A je pak obdélníková matice $m \times n$, její prvky $a_{ij} \in \mathbb{R}(i = 1 \dots m, j = 1 \dots n)$ jsou reálná čísla. Při práci s obrazovými daty DPZ mají většinou význam odrazivosti povrchu, při práci s daty z laserového skenování mají většinou význam výšky objektu nad terénem. Body obrazu (a_{ij}) mívají přesné souřadnice v některém geografickém souřadném systému, přesto při zpracování častěji pracujeme s diskretní, maticovou formou. Vzdálenost mezi dvěma pixely v obraze (a_{ij}, a_{kl}) měříme euklidovskými v maticových souřadnicích: $\rho = \sqrt{(i - k)^2 + (j - l)^2}$, pokud chceme znát jejich skutečnou vzdálenost, násobíme $\Delta = \rho \cdot ps$, kde ps je velikost pixelu v metrech. Při pohybu obrazem pracujeme se 4-sousedností (stranou), případně 8-sousedností (stranou či rohem) dle definice 39 v odstavci 1.1.4 a okolím bodu $O(a_{ij})$ obecně rozumíme vhodnou submatici obrazu A , která obsahuje prvek a_{ij} .

Kvalitu obrazu ovlivňuje šum, který může mít dvojí charakter. Tzv. aditivní šum se projevuje v celé ploše obrazu, jeho vliv modelujeme jako součet matic $A = B + S$, kde B je původní obraz a S představuje šum. Veličiny B a S mohou být nezávislé nebo nemusejí, podle toho, zda zašuměnost obrazu závisí na konkrétních hodnotách či nikoliv. V datech



Obrázek 1.1: Amplitudové spektrum ostrého kontrastního obrazu (vlevo) a téhož obrazu rozostřeného a s nízkým kontrastem (vpravo).

laserového skenování může být aditivní šum důsledkem chyby v záznamu trajektorie letu a může se projevit posunem výšek oproti realitě. Takový stav, pokud je systematický, ovšem příliš neovlivňuje výsledky segmentace. Tzv. impulsní šum se projevuje radikálně odlišnými hodnotami v náhodných pozicích obrazu. K tomu může v našich datech dojít například při nesprávném vyhodnocení jednoho konkrétního pulzu a projevem je neočekávaně nízká nebo vysoká hodnota výšky v jinak hladkém povrchu lesa. Takové chyby naopak musíme důsledně odstranit, jinak ovlivní výsledky segmentace. Používáme k tomu vhodné metody filtrování, viz další odstavec, kapitola 2.1 o předzpracování a také viz praktická část práce.


Obrazové filtry jsou matematické nástroje k úpravě obrazu určené ke zvýraznění či potlačení určitých informací. Lze je dělit podle použitých matematických operací na filtry lineární a nelineární, nebo podle schopnosti přizpůsobit svoji činnost lokálním vlastnostem obrazu na filtry neadaptivní a adaptivní. Lineární filtry pracují tak, že nahrazují hodnotu zpracovávaného pixelu lineární kombinací hodnot okolních pixelů. Pracují tedy na principu (dvojměrné) konvoluce a využívají tzv. konvolučního teorému:

Věta 38. Necht $A = \{a_{i,j}\}$ a $C = \{c_{i,j}\}$ jsou dva obrazy. Pak pro jejich konvoluci platí:

$$\mathcal{F}(A * C) = \mathcal{F}(A) \cdot \mathcal{F}(C)$$

kde $\mathcal{F}(M)$ značí Fourierovu transformaci matice M . (Násobení na pravé straně je násobením po prvcích, nikoliv násobením matic.)

Konvoluční teorém je ilustrován na obrázku 1.2. Vlevo nahoře vidíme původní obraz A , uprostřed konvoluční matici (jádro) $C = \{c_{i,j}\}$, $c_{i,j} = \frac{1}{(2\delta+1)^2}$ pro $|i|, |j| \leq \delta$ a $c_{i,j} = 0$



Obrázek 1.2: Ilustrace konvolučního teorému.

jinde. Nulové prvky jsou obarveny černě, nenulové bíle. Vpravo nahoře je konvoluce $A * C$, v tomto případě vyhlazený původní obraz. Dole vidíme zleva amplitudové spektrum $\mathcal{F}(A)$ původního obrazu, amplitudové spektrum $\mathcal{F}(C)$ konvoluční matice (frekvenční charakteristiku filtru) a součin $\mathcal{F}(A) \cdot \mathcal{F}(C)$ těchto spekter, který je díky konvolučnímu teorému současně amplitudovým spektrem vyhlazeného obrazu.

K potlačení šumu se používají například filtry průměrovací (jádro C výše). Z frekvenční charakteristiky filtru C je zřejmé, že tento filtr sice potlačuje vyšší prostorové frekvence, ale jen v určitých pásmech (tmavší proužky). Většinu vysokých frekvencí propouští. Proto se častěji používají gaussovská jádra, která tímto nedostatkem netrpí. Prvky gaussovského jádra počítáme podle vzorce $c_{ij} = \exp^{-\frac{x^2+y^2}{2\sigma^2}}$. Pokud nechceme ovlivnit původní rozsah hodnot v obraze, jádra konvolučních filtrů normalizujeme součtem, tj. tak, aby $\sum c_{ij} = 1$. K filtrování obrazů je možné využít kromě průměru i jiné statistické charakteristiky, například medián, viz definice 10 v odstavci 1.1.2. Průměrovací, mediánové i gaussovské filtry lze použít i adaptivně. Další možností adaptivního vyhlazování je použití rotující masky, kdy v prvním kroku vybíráme dílčí okolí s nejnižší heterogenitou a z něj používáme průměr k nahrazení.

Hranice objektů v obraze se vyznačují výraznou změnou intenzity. Základní metody

k jejich hledání jsou tři: použití konvolučního filtru typu horní propust, gradientní metoda a metoda dilatace-eroze. V prvním případě budujeme taková konvoluční jádra, která potlačí nízké prostorové frekvence a zachovají ty vysoké. Nejčastěji používané příklady jsou Laplacovská jádra (C_1 , C_2) a filtr pracující na principu neostré masky (C_3):

$$C_1 = \begin{pmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{pmatrix} \quad C_2 = \begin{pmatrix} -1 & 0 & -1 \\ 0 & 4 & 0 \\ -1 & 0 & -1 \end{pmatrix} \quad C_3 = \begin{pmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{pmatrix}$$

Gradientní metoda vyhledává prudké změny intenzity v obraze ve dvou krocích. Napřed počítáme diskretizovanou hodnotu gradientu v místě pixelu a_{ij} dle definice 7 jako

$$g_{ij} = \sqrt{(a_{i+1,j} - a_{ij})^2 + (a_{i,j+1} - a_{ij})^2}.$$

Tento gradientní filtr nabývá nejvyšší hodnoty na hranicích objektů, které můžeme následně určit prahováním.

Prahováním máme na mysli odlišení objektů a pozadí v obraze pomocí jednoduchého jasového prahu. V případě obrazu v odstínech šedi, kde jsou například světlé objekty na tmavém pozadí, můžeme sestavit histogram hodnot jednotlivých pixelů. Je-li histogram bimodální, jasovou úroveň k odprahování volíme v lokálním minimu mezi dvěma maximy. V datech laserového skenování může mít práh podobu minimální výšky využitě k odlišení stromů a louky.

Metoda dilatace-eroze kombinuje minimový ($b_{ij} = \min O(a_{ij})$) a maximový ($b_{ij} = \max O(a_{ij})$) filtr. V případě světlých objektů na tmavém pozadí první krok rozšíří plochu objektů a následná dilatace plochu zúží zpět. Odečtením erodovaného obrazu od dilatovaného získáváme hranice objektů.

Obecnou nevýhodou uvedených základních postupů je nedostatek robustnosti; mohou být citlivé na šum; mohou záviset na barvě objektů; selhávají, je-li hranice objektů nekompletní; a podobně. Jinými slovy použití obecného segmentačního algoritmu v konkrétní praktické úloze vyžaduje vždy jisté přizpůsobení zpracovávaným datům. A přesně tak postupujeme v kapitole 2, kde představujeme jednotlivé algoritmy segmentace korun.

1.1.4 Digitální topologie

V tomto odstavci uvedeme několik základních pojmů z digitální topologie, které potřebujeme při výkladu segmentačních algoritmů. Poukážeme především na rozdíly mezi vlastnostmi některých objektů z reálného světa, respektive světa reálných čísel, a ze světa digitálních obrazů, neboli diskretizovaných záznamů reálného světa.

Definice 39. Uvažujme digitální rovinu \mathbb{Z}^2 . 4-přilehlým bodem (sousedem) bodu $(x, y) \in \mathbb{Z}^2$ rozumíme libovolný ze čtyř bodů $(x \pm 1, y)$ a $(x, y \pm 1)$. 8-přilehlým bodem (sousedem) bodu $(x, y) \in \mathbb{Z}^2$ rozumíme libovolný z osmi bodů $(x \pm 1, y \pm 1)$, $(x \pm 1, y)$ a $(x, y \pm 1)$.

Definice 40. Je-li $k = 4$ nebo $k = 8$, pak k -cestou rozumíme libovolnou posloupnost P_0, \dots, P_n bodů ze \mathbb{Z}^2 takovou, že P_{i-1} je k -přilehlým bodem bodu P_i pro $\forall i, 1 \leq i \leq n$. Množina $S \subseteq \mathbb{Z}^2$ se nazývá k -souvislá, jestliže každé její dva body lze spojit k -cestou ležící v S . Jordanovská k -křivka je konečná k -souvislá množina, která obsahuje s každým bodem právě 2 jeho k -přilehlé body. A konečně k -komponentou množiny $S \subseteq \mathbb{Z}^2$ rozumíme její maximální k -souvislou podmnožinu.

Věta 41. Buď $k \in \{4, 8\}$ a J jordanovská k -křivka s vlastností $|J| \geq 5$ pro $k = 4$ a $|J| \geq 4$ pro $k = 8$. Pak J rozděluje digitální rovinu \mathbb{Z}^2 na právě dvě $(12 - k)$ -komponenty.

S pojmy k -křivky a k -oblasti se setkáme při digitální interpretaci plochy koruny a její hranice. Naopak při interpretaci obrazových segmentů v kontextu reálných lesnických metrik (např. rozměry koruny) je podstatnou otázkou vzdálenost dvou bodů. Vzdálenost mezi dvěma obrazovými elementy v digitální rovině se souřadnicemi (i, j) a (k, l) lze definovat více způsoby. Pro nás je plně vyhovující definice eukleidovská: $\delta_E = \sqrt{(i - k)^2 + (j - l)^2}$. V obrazových datech dálkového průzkumu navíc můžeme určit i reálnou vzdálenost dvou objektů představovaných jednotlivými pixely. Počítáme $\delta_R = p\delta_E$, kde δ_R je vzdálenost v realitě, δ_E je vzdálenost v obraze a p je prostorové rozlišení, neboli velikost jednoho pixelu (v metrech).

1.1.5 Variační počet

Některé z problémů uvedených na konci odstavce 1.1.3 lze řešit tím, že hranici objektu v obraze hledáme pomocí aktivní kontury, struktury z variačního počtu.

Aktivní kontura \mathbf{c} je rovinná, časově proměnná křivka definovaná parametricky následujícím předpisem:

$$\mathbf{c} : [0, 1] \times [0, \infty) \rightarrow \mathbb{R}^2, \mathbf{c}(s, t) = (x(s, t), y(s, t)).$$

Reálné funkce x a y mají význam prostorových souřadnic, $t \in [0, \infty)$ je časová proměnná, $s \in [0, 1]$ je parametr. Kontura hranice objektu je uzavřená křivka, tedy $\mathbf{c}(0, t) = \mathbf{c}(1, t)$.

Aktivní kontuře v každém čase přiřazujeme hodnotu energie funkcíonálem

$$E(\mathbf{c}(t)) = \int_0^1 (E_{in}(\mathbf{c}(s, t)) + E_{out}(\mathbf{c}(s, t))) ds.$$

Vnitřní energie kontury, složka E_{in} , závisí na vlastnostech křivky jako je délka či křivost. Složka E_{out} představuje působení vnějších sil na konturu. Mezi ně patří gradient intenzity v obraze a další uživatelské vlivy. Celkově chápeme energii E jako veličinu měřící kvalitu aproximace hranice pomocí aktivní kontury.

Po konkrétním naplnění jednotlivých složek energie je možné sestavit pohybové rovnice aktivní kontury a danou soustavu parciálních diferenciálních rovnic řešit. Numerické řešení zahrnuje diskretizační kroky a řadu omezujících podmínek. Algoritmus pro segmentaci korun, který budujeme v kapitole 2.3.3, je rovnou odvinutý od reality diskrétního obrazu a principem aktivní kontury se pouze inspiruje.

1.2 Používané pojmy z dálkového průzkumu Země

Dálkový průzkum Země (DPZ) v nejšířším slova smyslu můžeme definovat jako sběr informací o objektech zájmu bez přímého kontaktu s nimi. Například oči čtenáře provádí dálkový průzkum ve chvíli, kdy čtou tento text. Přesněji technicky řečeno, oči měří světlo odražené od potlaštěného papíru a mozek, náš zabudovaný počítač, překládá snímaný obraz na písmena, z nichž skládá slova a věty. Shrnutí historie DPZ, výklad teoretických principů a příklady aplikací leteckého DPZ laskavý čtenář nalezne například v nové české monografii [31], kterou vydalo v roce 2014 Centrum výzkumu globální změny, a do níž přispíval též autor této dizertační práce.


V dalším se zaměříme pouze na vybrané pojmy z teorie DPZ, které přímo souvisí s praktickou částí práce. Metody DPZ dělíme do dvou skupin podle použitého zdroje energie na metody aktivní a pasivní. V praxi lesnických aplikací, které jsou předmětem této dizertační práce, je příkladem pasivních metod hyperspektrální snímkování (1.2.1) a příkladem aktivních metod je laserové skenování (1.2.2).

1.2.1 Hyperspektrální snímkování

Hyperspektrální snímkování je metodou pasivní, neboť skener pasivně snímá elektromagnetické záření odražené od objektů na zemském povrchu (zdrojem je Slunce, obrázek 1.3). V našich konkrétních úlohách se jedná o letecký řádkový hyperspektrální skener, což implikuje následující principy a parametry. Nasnímaná data mají podobu tzv. hyperspektrální krychle. První rozměr má význam prostorové souřadnice napříč letu a je dán počtem čipů v řádku skeneru. Druhý prostorový rozměr vzniká pohybem letadla, tedy podél letu. Jeden snímek má tedy podobu obdélníkové matice (silně nečtvercové) a každý pixel nese hodnotu energie odražené z určitého čtverce na zemském povrchu. Rozměr pixelu, jinak též prostorové rozlišení, závisí na technických limitech skeneru a také na výšce a rychlosti letu. Pro naše aplikace je typické prostorové rozlišení 20 centimetrů až 1 metr (obrázek 1.4). Pro plošné skenování většího území pak spojujeme více letových linií vedle sebe. Třetí rozměr hyperspektrální krychle je dán spektrálním rozlišením. Odražené elektromagnetické záření je děličem separováno podle vlnové délky a jednotlivé hodnoty jsou ukládány samostatně. Prostorová složka hyperspektrální krychle je tedy 2-D fyzickým digitálním prostorem ve smyslu definice 21, jeho fyzické domény nazýváme pixely (akronym z anglického picture element). Celou hyperspektrální krychli můžeme též chápat jako m -složkový obraz dle definice 32. Barevná letecká fotografie má 3 složky. Má-li obraz složek více, hovoříme o multispektrálním snímku. Typickým příkladem je využití vhodných filtrů a přidání vrstvy v oblasti infračerveného elektromagnetického záření. Jsou-li složek desítky tak, jak to popisujeme výše, hovoříme o hyperspektrálním snímkování. U hyperspektrálních dat pro každý prostorový pixel získáváme spektrální profil, což je závislost odrazivosti na vlnové délce (obrázek 1.5). Typické rozlišení (krok) v našich aplikacích je 2 až 10 nanometrů a rozsah spektra 400 až 1000 nanometrů.

Z technických podrobností nad rámec této práce dodejme, že surová nasnímaná data prochází procesem radiometrických, atmosférických a geometrických korekcí tak, abychom


získali datovou krychli s významem popsáným v předchozím odstavci. Více informací o této problematice lze nalézt v monografii [31].



Obrázek 1.3: *Princip pasivního dálkového průzkumu.* Zdrojem energie je Slunce. Senzory měří záření odražené od různých objektů na zemském povrchu. Energie odražená od jednotlivých objektů se pochopitelně liší. Různé typy povrchů odrážejí různou procentuální část dopadajícího záření, zbytek pohlcují. (Navíc, především v termální části spektra, některé objekty samy energii vyzařují.) Odrazové poměry se mohou lišit podle vlnové délky záření. Některé typy povrchů mají také různé odrazové vlastnosti podle směru dopadajícího záření, rozlišujeme například zrcadlový odraz a lambertiánský povrch odrážející všemi směry stejně. Všechny tyto vlivy se skládají do výsledného obrazu (obrázek 1.4), respektive do tzv. spektrální charakteristiky každého obrazového bodu (obrázek 1.5). V tomto schématu lze poukázat ještě na jeden podstatný jev, a tím je ovlivnění měřené energie průchodem atmosférou. Obrazová data DPZ proto pořizujeme především za jasných dnů a i tak jednotlivá spektra musíme od vlivu atmosféry očišťovat.




Obrázek 1.4: *Letecký snímek vysokého prostorového rozlišení.* Při zobrazení v pravých barvách není rozdíl oproti klasické fotografii. Je třeba mít na paměti, že u hyperspektrálních dat máme pro každý pixel k dispozici informace o celém spektru odrazivosti v jisté škále vlnových délek. Viz též obrázek 1.5.



Obrázek 1.5: *Typický spektrální profil zelené vegetace,* například jehlic smrku. Na vodorovné ose x je vlnová délka elektromagnetického záření v mikrometrech, na svislé ose y je odrazivost povrchu v procentech (v tomto případě násobeno 100, pohybujeme se tedy v rozsahu 0 až 30 procent). Charakteristickými prvky spektra zelené vegetace jsou lokální maximum okolo 550 nm, lokální minimum okolo 680 nm, následný prudký nárůst a vysoká stabilní úroveň v blízké infračervené oblasti, za 800 nm. Svislé barevné linie znázorňují pozici vlnové délky modrého, zeleného a červeného viditelného světla.

1.2.2 Laserové skenování


Laserové skenování je metodou aktivní, neboť skener aktivně vysílá laserový pulz směrem k objektům na zemském povrchu a následně měří energii od nich odraženou (obrázek 1.6). V našem případě se jedná o letecké laserové skenování, což implikuje následující principy a parametry. Při znalosti časů vyslání a přijetí pulzu z jednoduché rovnice $2s = c\Delta t$ odvodíme vzdálenost odrážejícího povrchu (vzdálenost s , rozdíl časů Δt a rychlost světla c). Při znalosti přesné polohy letadla (a skeneru) během trajektorie letu dopočítáváme přesné 3D souřadnice místa odrazu. Surová data z laserového skenování mají podobu bodového mračka (obrázek 1.7). Klíčovým parametrem skenování je bodová hustota, která je dána technickými omezeními skeneru a výškou letu, a která určí, jak podrobnou a věrnou 3D rekonstrukci objektů na zemském povrchu získáme. Pro naši aplikaci je typická hustota 5 až 50 bodů na metr čtvereční.




Obrázek 1.6: *Princip aktivního dálkového průzkumu.* Skener vysílá k objektům na povrchu Země laserové pulzy a měří časové zpoždění a intenzitu odraženého záření.

Z technických podrobností přesahujících záběr této práce dodejme, že použitá vlnová délka laserového záření (např. 1062 nm) ovlivňuje, jak se od kterých povrchů pulz odráží. Dále, že moderní laserové skenery umožňují zaznamenávat kompletní průběh odražené vlny, což také umožňuje odvozovat podrobnější informace o odrážejících objektech. Více informací o této problematice lze nalézt v monografii [31].

My se spokojíme s prostou 3D rekonstrukcí a pro segmentaci korun stromů odvodíme z bodového mračka tzv. mapu výšek objektů (obrázek 1.8). K jejímu výpočtu potřebujeme v bodovém mračku rozdělit body na odrazy od terénu (holé země), odrazy od povrchu nadzemních objektů (stromů...) a případné další odrazy (například uvnitř koruny). Následně interpolujeme body terénu do rastrové vrstvy nazývané digitální model terénu (DTM) a body povrchu do rastrové vrstvy nazývané digitální model povrchu (DSM). Odečtením DSM-DTM získáváme výše zmíněnou mapu výšek, nazývanou též normalizovaný model povrchu (nDSM). Proces tvorby mapy výšek dále rozebíráme v kapitole 2.1.



Obrázek 1.7: *Bodové mračno*. Základním produktem laserového skenování je mračno bodů, jejich poloha v prostoru udává 3D souřadnice odrazů jednotlivých vyslaných pulzů. Jak vidíme, může sloužit k velmi podrobnému mapování povrchů přirozených i umělých.



Obrázek 1.8: *Normalizovaný model povrchu*. Výška nadzemních objektů je zde reprezentována na škále od černé (0 m) po žlutou (30 m).

Kapitola 2

Matematické metody

Tato kapitola popisuje matematické metody zpracování obrazu používané při segmentaci korun, uvádíme postupy známé a odvozujeme postupy nové, vyvinuté v rámci této dizertační práce.

Klíčová slova *local maxima approach* (detekce pomocí lokálních maxim, odstavce 2.2.1), *watershed* (delineace pomocí zaplávání, odstavce 2.3.1), *valley following* (delineace pomocí minimové sítě, odstavce 2.3.2) a *seeded region growing* (delineace pomocí růstového algoritmu, odstavce 2.3.3) se v literatuře vyskytují dlouhodobě. Nicméně je potřeba si uvědomit, že v jednotlivých studiích se vyskytují různé datové zdroje, různý typ DPZ a také různé prostorové rozlišení. My se zaměřujeme na data laserového skenování a vyšší prostorové rozlišení (minimální hustota mračna 5 bodů na metr a tedy velikost pixelu nejčastěji 0,5 metru). Druhý faktor, vzhledem k mezinárodní literatuře, je typ ekosystému. Jednotlivé studie se pochopitelně zaměřují na lesy v dané zemi. Českých studií je poskrovnu. My v praktické části práce rozebíráme použití algoritmů ve třech moravských lokalitách, v mladém a dospělém lese smrkovém a také v lese bukovém.

Celkově lze říci, že žádná část této metodické kapitoly není pouze opsaná z primárního zdroje. Na druhou stranu výhradně původní je pouze modifikovaný růstový algoritmus (2.3.3), poprvé publikovaný v [25]. Ambici na teoretický přínos své oblasti mají především detekce lokálních maxim adaptivně parametrizovaná podle lokálních vlastností obrazu a druhu dřevin a růstový algoritmus využívající aktivní konturu k aproximaci hranic korun.


Kapitola je v souladu se zvyklostmi rozdělena do tří částí podle jednotlivých fází segmentačního procesu. První podkapitola se zabývá předzpracováním obrazu před samotným zahájením segmentace (2.1). Druhá podkapitola je zaměřena na fázi detekce pozice stromů (2.2) a třetí na následnou delineaci plochy korun (2.3).

2.1 Metody přípravy dat

V této podkapitole popíšeme jednotlivé kroky na cestě od surových dat po data vstupující do procesu segmentace korun. Nelze ve všeobecnosti stavět přesnou hranici mezi předzpracováním a proces segmentace, protože nutnost předzpracování pochopitelně vychází z použitých segmentačních metod. Nicméně v následujícím textu do předzpracování řadíme vytvoření mapy výšek ze surového bodového mračna a její následné úpravy.

2.1.1 Od bodového mračna k mapě výšek

Surové bodové mračno nese s každým bodem informaci o jeho třech souřadnicích v prostoru. (Informace o intenzitě odraženého pulzu a případné další parametry full-waveform skenování pomíjíme). Pro určení výšky nadzemních objektů potřebujeme klasifikovat jednotlivé body na odrazy od holé země (roslého terénu) a odrazy od nadzemních objektů. Příklad je na obrázku 2.1. Detailní rozbor způsobů této klasifikace (často používaný anglický termín zní „ground filtering“) jde mimo záběr této práce. Laskavý čtenář jej může najít například v [2] či [29]. V principu se jedná o iterativní proces. Na jeho začátku jako body terénu stanovíme nejnížší body v jisté síti a další body přidáváme tak, aby plocha terénu zůstávala přiměřeně spojitá a hladká. Konkrétní nastavení závisí na prostředí, v němž se pohybujeme; jiné bude pro zemědělské plochy v nížině, jiné pro les v horách a jiné pro městskou zástavbu. Při přípravě dat pro praktickou část práce jsme využili skripty *lastools* vyvinuté v Německu (<http://rapidlasso.com/lastools/>), které umožňují klasifikovat terén, napočítat výšky nadzemních bodů a sestavit potřebné rastry, viz dále.



Obrázek 2.1: Výsledek klasifikace bodového mračna na body roslého terénu (červená) a nadzemní objekty (zelená). Na obrázku lze vidět i další specifika horského lesa, členitost terénu a tvary jednotlivých korun v modelu povrchu. Dále vidíme, že prostupnost lesního porostu pro laserový paprsek je značně proměnná. Projevuje se různým počtem bodů odražených od roslého terénu, i v rámci vertikálního členění korun. Liší se podle stáří porostu, jiná je u mladých a dospělých stromů, liší se podle míry zapojení porostu a extrémně se liší u listnatých stromů v obdobích s listy a bez listů. [Ukázka je z lokality Bílý Kříž v Beskydech.]

Z bodů klasifikovaných jako terén sestavujeme tzv. digitální model terénu (DTM = digital terrain model). Jednou z možných metod je triangulace provedená nad body te-

rénu. Náhodně rozložené body pak převádíme do pravidelného rastru, při jeho sestavení je klíčový parametr prostorového rozlišení, velikost pixelu. Z bodů klasifikovaných jako nadzemní objekty vybíráme ty nejvyšší a sestavujeme z nich tzv. digitální model povrchu (DSM = digital surface model). Bodů odražených od povrchu je v lesním ekosystému výrazně více než pulzů, které projdou až k terénu. Triangulace povrchu tak má menší prvky, my ji opět převádíme do pravidelného rastru a prostorové rozlišení volíme jemnější nebo stejné jako u modelu terénu.

Mapu výšek (CHM = canopy height model, nebo též nDSM = normalizovaný model povrchu) získáme odečtením $CHM = DSM - DTM$. Tento produkt je nezávislý na nadmořské výšce zkoumaného území, hodnoty jednotlivých pixelů mají význam výšky (nad terénem) v daném místě. Zvolené prostorové rozlišení může ovlivňovat výsledky segmentace, proto se jím v praktické části budeme podrobněji zabývat.

2.1.2 Úpravy mapy výšek


Laserové skenování může být v různých fázích zatíženo určitou chybou, stejně tak následná klasifikace bodového mračka a interpolace modelů terénu a povrchu. Ve výsledné mapě výšek může být přítomný multiplikativní šum, který odstraňujeme vhodným filtrováním.

V datech laserového skenování s vysokým prostorovým rozlišením (vysokou primární bodovou hustotou) jsou zachyceny značné podrobnosti – v našem kontextu až jednotlivé větve stromů. Tyto podrobnosti mohou být na překážku při detekci a delineaci jednotlivých stromů, proto se je snažíme potlačit, opět vhodným filtrováním. Zvolené parametry filtrování mohou ovlivňovat výsledky segmentace, proto se jimi budeme v praktické části podrobněji zabývat.


Komplexní přístup k tvorbě mapy výšek je uveden v článku [16]. Jde o to, že při rasterizaci modelu povrchu s vysokým prostorovým rozlišením dochází ke vzniku silně nespojitě plochy. Je to dáno různou úrovní penetrace paprsku do korunového zápoje. Výše uvádíme, že tento problém lze řešit filtrováním. Místo dodatečného řešení lze též jinak přistoupit k procesu rasterizace. Postup popsany v [16] vychází ze dvou základních kroků.

1. Body bodového mračka nejsou při rasterizaci považovány za body, ale za malé disky vhodného poloměru tak, aby svrchní úroveň zakrývala průstřeily dovnitř koruny stromu.
2. Mapa výšek je sestavována iterativně po jednotlivých výškových úrovních. Do výsledného rastru se tak dostane vždy maximální hodnota v každé buňce.

Problematiku dále ilustrujeme na obrázcích 2.2 a 2.3.




Obrázek 2.2: Ukázka bodového mračna s vysokou hustotou (až 100 b/m²). Vlevo pohled shora, vpravo v perspektivě. Za povšimnutí stojí, jaké podrobnosti uvnitř jednotlivých korun lze rozlišit. [Ukázka je z lokality Bílý Kříž v Beskydech.]



Obrázek 2.3: Rozdíly při běžné (vlevo) a speciální (vpravo) rasterizaci mapy výšek. Vidíme, že speciální model povrchu je kvalitnější, zásadně ubylo nespojitostí vlivem odrazů uvnitř koruny. A jedná se tak o model povrchu hodný svého jména. [Ukázka je z lokality Bílý Kříž v Beskydech.]

2.1.3 Klasifikace typů pokryvu

U malého zájmového území je možné předpokládat, že všechny nadzemní objekty jsou stromy, ale v případě velkoplošného uvažování tomu tak určitě není. Dalším přípravným krokem proto bývá vymaskování území lesa od dalších povrchů (paseka, cesty, zástavba, ap.). Pro odstranění některých tříd pokryvu (paseka, cesta) může stačit prahování určitou minimální hodnotou výšky. Ke správnému klasifikování dalších tříd pokryvu se hodí fúze s obrazovými daty a klasifikace na základě spektrálních projevů. V případě, že máme k dispozici pouze data laserového skenování, můžeme využívat parametry textury a drsnosti (plocha střechy je rovina), případně intenzitu a další parametry z full-waveform záznamu (odraz od střechy má jiný tvar a amplitudu než od listů či jehlic). Příklad klasifikace je na obrázku 2.4.



Obrázek 2.4: Ukázka klasifikace bodového mračka. Zelenou barvou je označena vysoká vegetace (stromy), fialovou barvou holá půda, žluté body zůstaly neklasifikované. Velká prázdná oblast v horní části obrazu je vodní plocha – od té se laserový paprsek neodráží. [Ukázka je z golfového hřiště u Jinačovic.]

2.2 Metody detekce stromů

V této podkapitole popíšeme algoritmy používané k detekci pozice jednotlivých stromů. Právem je největším prostor věnován metodě lokálního maxima, protože tento přístup nejlépe odpovídá geometrické podstatě laserového skenování. Mezi další varianty patří prahování, korelační hledání vzoru a rekonstrukce od kmene.

2.2.1 Hledání lokálního maxima

Přirozeným předpokladem této metody detekce stromů je očekávaná ekvivalence mezi pozicí vrcholku stromů a pozicí lokálních maxim v mapě výšek. Širší diskuze o tomto základním předpokladu bude následovat později, napřed probereme technické aspekty hledání lokálních maxim.

Při hledání lokálního maxima v mapě výšek procházíme okolí zkoumaného pixelu a za maximum jej označíme tehdy, je-li vyšší než všechny pixely z okolí. Pro výsledek je klíčový tvar a velikost okolí. V lese, který není zcela homogenní, je třeba velikost okolí nastavovat adaptivně – nižší/menší stromy hledáme s menším plovoucím oknem, vyšší/větší stromy pak s větším plovoucím oknem.

Optimální je taková velikost plovoucího okna, která přesně odpovídá velikosti koruny stromu v daném místě. Očekávanou velikost koruny můžeme odhadovat podle výšky stromu, tedy podle hodnoty výšky v posuzovaném pixelu. Pro přepočítání mezi výškou stromu a průměrem koruny existují tzv. alometrické rovnice – empiricky odvozené závislosti kalibrované na základě destruktivních měření. Tato závislost se pochopitelně liší podle druhu dřeviny, proto nejpřesnějších výsledků dosáhneme s apriori znalostí o druhovém složení ve zkoumané oblasti.

Když nemáme k dispozici výše zmíněné podpůrné informace o zpracovávaném porostu, stanovujeme velikost plovoucího okna přímou analýzou obrazu – v okolí posuzovaného pixelu. Předpokládáme, že se nacházíme v bodě vrcholku koruny a snažíme se odhadnout její velikost, tedy vzdálenost k okraji koruny. Používáme dvě různé metody, první z nich je spádová metoda. Výška bodů na povrchu stromu klesá od vrcholku směrem k okraji koruny. Konstruuujeme transepty procházející posuzovaným pixelem a okraj koruny v daném směru detekujeme jako místo, kde poprvé přestane být derivace výšky záporná. Ve čtvercovém rastru mapy výšek se přirozeně nabízí osm základních směrů transektů. Za odhad velikosti koruny bereme průměrnou nebo maximální spádovou vzdálenost ze všech transektů.

Druhá metoda pro určení okrajů koruny využívá statistické veličiny soběpodobnosti (semivariance). Opět konstruuujeme transepty vycházející z posuzovaného pixelu. Soběpodobnost vůči startovnímu pixelu narůstá až do určitého bodu, kdy dochází k nasycení. Právě jeho vzdálenost bereme jako odhad velikosti koruny a pro stanovení velikosti plovoucího okna volíme průměrnou nebo maximální hodnotu pro všechny transepty. Logickou variantou je kombinace obou přístupů, kdy odhadneme velikost koruny oběma metodami a velikost plovoucího okna zvolíme podle získaných hodnot.

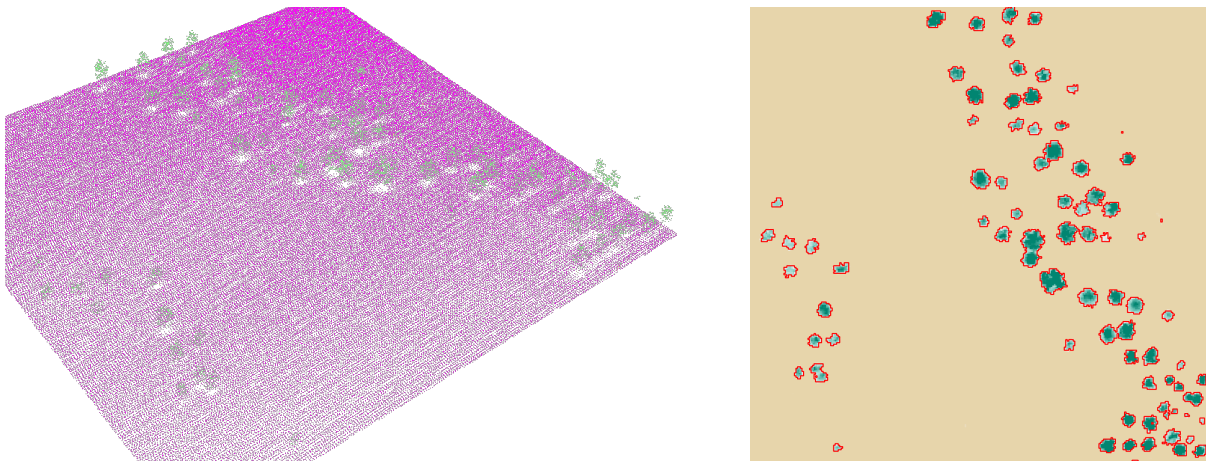
Máme-li k dispozici výsledky klasifikace, můžeme na nalezená lokální maxima apli-

kovat masku a odstranit ta, která například leží na umělých objektech (domy, stožáry a podobně). Další typický krok čištění je odstranění nalezených maxim, která leží příliš blízko sebe – blíže, než by odpovídalo očekávané velikosti korun pro danou výšku – zachováme vyšší z maxim. Pokud jsou hledaná maxima pouze vstupem do kroku delineaace plochy korun, stačí mít uložené jejich obrazové souřadnice; v případě, že se jedná o finální (mezi)produkt, exportujeme nalezené body včetně jejich reálných souřadnic ve stejném geografickém souřadném systému jako měl původní obraz.

Příklady výsledků a rozbor nastavitelných parametrů obsahuje praktická část práce, kapitola 3.2.

2.2.2 Prahování

Ve specifické situaci, kdy spolu jednotlivé stromy přímo nesousedí, postačí k detekci jednotlivých korun binarizace obrazu pomocí prahování. Hodnotu prahu nastavujeme podle minimální výšky hledaných stromů. Na obrázku 2.5 vidíme jednoduchý příklad. Samostatně stojící mladé stromky na golfovém hřišti u Jinačovic jsme se pokusili segmentovat prostým stanovením maximální výšky $h = 1$ m pro pozadí, vyšší pixely považujeme za stromy. Dostáváme 66 jednotlivých korun a 6 neoddělených dvojic, respektive dvojic sousedních stromů touto metodou neoddělitelných.



Obrázek 2.5: Segmentace korun samostatně stojících stromů pomocí prahu minimální výšky. Bodové mračno ve 3D (vlevo) a výsledek prahování (vpravo). [Ukázka je z golfového hřiště u Jinačovic.]

Dovolujeme si doplnit tento krátký odstavec úsměvnou historkou s přesahem vědeckého charakteru. Uvedená metoda segmentace se může jevit naprosto nepraktickou pro podmínky lesů v České republice. Aplikovatelná je, do jisté míry, zcela specificky pro sady ovocných stromů. V zahraniční praxi najdeme více příkladů, například olivové či pomerančové plantáže v jižní Evropě. Tam stojí stromy jednotlivě a můžeme je tedy segmentovat prahováním a spočítat. V jistém italském okrese je reálně zavedeno počítání pomerančovníků na plantážích pomocí dálkového průzkumu za účelem určení počtu stromů a od

něj odvozené dotace pro zemědělce. Zemědělci jsou ovšem vynalézaví a do svých plantáží staví kartonové makety pomerančovníků, aby uměle navýšili počet a s ním i dotaci. Úředník náležitě vzdělaný v teorii dálkového průzkumu by ovšem neměl býti oklamán. Má-li k dispozici alespoň multispektrální obrazová data, rozdíl mezi spektrem listoví a papíru snadno pozná; a lišit se též bude intenzita odražených laserových pulzů.

2.2.3 Hledání vzoru

Když známe očekávaný tvar koruny stromů, které detekujeme (například kuželový tvar koruny smrku), můžeme sestavit jejich model do matice a vypočítat korelační koeficient této matice vůči všem odpovídajícím podmaticím zkoumaného obrazu. Pozice stromů pak detekujeme jako lokální maxima korelace.

Pro ukázkou jsme zvolili výřez z mapy výšek v oblasti Bílý Kříž, kde se vyskytují středněvěké smrky s typickým kuželovým tvarem koruny. Vzhledem k prostorovému rozlišení mapy výšek a po zjištění, že průměrná výška ve zpracovávaném území je 12 metrů, jsme stanovili za vzorový strom rotační plochu definovanou následující maticí:

$$S = \begin{pmatrix} 0 & 0 & 2 & 2 & 2 & 0 & 0 \\ 0 & 2 & 6 & 7 & 6 & 2 & 0 \\ 2 & 6 & 9 & 10 & 9 & 6 & 2 \\ 2 & 7 & 10 & 12 & 10 & 7 & 2 \\ 2 & 6 & 9 & 10 & 9 & 6 & 2 \\ 0 & 2 & 6 & 7 & 6 & 2 & 0 \\ 0 & 0 & 2 & 2 & 2 & 0 & 0 \end{pmatrix}$$


Následně jsme napočítali korelační koeficient mezi maticí S a všemi submaticemi mapy výšek odpovídající velikosti. Potenciální pozici stromů jsme detekovali jako lokální maxima korelace s hodnotou $\rho \geq 0,5$. Výsledek detekce vidíme na obrázku 2.6.

Základním předpokladem této metody je dostatečná znalost vzorů, znalost druhového složení v dané oblasti, znalost typologie tvarů korun. Také zde je možná silná adaptivita přístupu, vhodný vzor můžeme volit podle výšky a dalších lokálních charakteristik obrazu.

2.2.4 Hledání kmenů

V datech laserového skenování s velmi vysokou hustotou je možné také postupovat zdola nahoru. Pozici jednotlivých stromů pak detekujeme jako pozici kmenů v řezu těsně nad terénem a jednotlivé koruny budujeme odspodu. Základní podmínkou je dostatek lidarových bodů, které projdou porostem až k holé zemi – například při skenování listnatých porostů v období bez listů.

Na obrázku 2.7 vidíme řez bodovým mračnem vysoké hustoty. Jedná se o dospělý bukový porost. Odfiltrovány byly body s výškou nad zemským povrchem nižší než 1,5 m nebo vyšší než 15 m. Byly zahrnuty pouze body, které jsou posledním odrazem (vzhledem k dekompozici vlny), tedy odrazem od něčeho pevného. Na pravém obrázku můžeme




Obrázek 2.6: Pozice stromů detekované metodou hledání vzoru. [Ukázka je z lokality Bílý Kříž v Beskydech.]

snadno vidět jednotlivé kmeny buků. K automatické detekci použijeme kumulativní průmět shora. Ve zvolené čtvercové síti, s velikostí pixelu například 15 cm, počítáme počet bodů v kvádru nad každou buňkou. Výsledný obraz korelujeme s očekávaným kruhovým tvarem průmětu kmene. Pozice stromů detekujeme jako lokální maxima korelace.


Na obrázku 2.8 vidíme vizualizaci počtu bodů v jednotlivých prostorových buňkách s označením míst maximální korelace vůči kruhovému průřezu kmenem (vlevo). Počet detekovaných stromů přiměřeně odpovídá skutečnosti. Na obrázku 2.8 vpravo jsme promítli pozice kmenů na mapu výšek, tedy na povrch korun stromů. Souvislost mezi těmito pozicemi a korunami buků v podstatě není vidět. Není to příliš překvapivé vzhledem ke dvěma skutečnostem:

1. Štíhlé buky v dané lokalitě nerostou vždy přímo vzhůru (což též zpochybňuje původní předpoklad o kruhovém průřezu kmene v kolmém průmětu).
2. Jedná se o výrazně zapojený porost, kde hranice mezi jednotlivými korunami jsou velmi nevýrazné.

(Tuto datovou sadu jsme i přesto vybrali k ukázce, neboť jsme potřebovali vysokou bodovou hustotu a dostatek bodů prostřelených až ke kmenům stromů.)



Obrázek 2.7: Kmeny buků. Vlevo pohled shora, vpravo v perspektivě. [Ukázka je z lokality Štítná v Bílých Karpatech.]



Obrázek 2.8: Detekce kmenů. Vlevo kumulativní průmět bodů, vpravo pozice kmenů promítnuté na povrch korun. [Ukázka je z lokality Štítná v Bílých Karpatech.]

2.3 Metody delineaace korun

V této podkapitole popíšeme algoritmy používané k delineaci plochy korun. Delineací zde i v dalším máme na mysli určení hranice jednotlivých korun. Ne tak ve smyslu nějaké spojité funkce, spíše v kontextu diskrétních obrazových dat. O každém pixelu tedy rozhodujeme, zda patří do té či jiné koruny, případně do plochy pozadí.

Rozebereme tři používané postupy. Nejsnáze implementovatelná je metoda zaplavování. Analogií k hledání lokálních maxim při detekci je metoda minimové sítě. Největší prostor bude věnován růstovému algoritmu v kombinaci s využitím aktivní kontury pro modelování hranice koruny. Jedná se o klíčový algoritmus, vyvinutý v rámci této dizertační práce.

2.3.1 Zaplavování

Postup nazývaný zaplavování (anglicky „watershed“) je převzatý z hydrologických aplikací. Základní myšlenka spočívá v tom, že mapu výšek vynásobíme mínus jedničkou. Původní lokální maxima (vrcholky korun) se tím změni na lokální minima. Vzniklou 3D strukturu následně virtuálně zaplavujeme. Zdroje vody umísťujeme do detekovaných vrcholů (nyní lokálních minim). Hranice korun pak vznikají na hranicích jednotlivých subpovodí odpovídajících jednotlivým zdrojům.

Technicky se využívá tzv. značkovací algoritmus. V prvním kroku označíme každý startovní pixel (vrcholek stromu) unikátním číslem a zařadíme jej do seznamu. Následuje iterační krok. Ze seznamu vybereme pixel s nejvyšší hodnotou výšky. Projdeme jeho sousední pixely. Pokud dosud nebyly označovány, a přitom mají nižší výšku, přiřadíme jim jeho číslo a zařadíme je do seznamu. Pak aktuální pixel vyřadíme ze seznamu. Iterativní proces končí po vyprázdnění seznamu. Oblasti obrazu označené shodným číslem tvoří jednotlivé koruny.

Ukázka výsledků segmentace metodou zaplavování a rozbor jednotlivých parametrů se nachází v praktické části práce, v odstavci 3.3.1.

2.3.2 Metoda minimové sítě

Metodu minimové sítě (anglický termín „valley following“) navrhl v devadesátých letech minulého století kanadský expert na dálkový průzkum a lesnictví F. Gougeon (viz [10]). Základní myšlenkou je sestavení hranice koruny propojením sítě lokálních minim. Pro praktickou část dizertační práce jsme použili níže popsany algoritmus, který vychází z práce Gougeona, a modifikovali jej pro aplikaci na data laserového skenování. (Primárním obrazem Gougeona byl družicový multispektrální snímek.)

První část algoritmu se zaměřuje na odlišení plochy stromů od pozadí, druhá pak dolaďuje hranice jednotlivých korun.

1. (Inicializace) Vstupem je mapa výšek. Výstupní obraz stejného rozměru má binární charakter, ve výsledku rozlišuje plochu lesa a zbývající plochu – v analýze obrazu se používá termín pozadí.

2. (Pozadí) Do plochy pozadí zařazujeme pixely podle určitého výškového prahu, například $h < 1$ m. Další možností je využití klasifikace pokryvu na základě hyperspektrálních dat, viz kapitola 2.1.3.
3. (Lokální minima) V ploše lesa detekujeme lokální minima. S plovoucím oknem velikosti 3 krát 3 označíme středový pixel jako minimum, pokud je jeho výška nižší než u všech osmi sousedů.
4. (Údolí) Následně v mnoha iteracích procházíme body pozadí a minimové sítě. Body, které jsou prvkem údolí, tj. mají z obou stran vyššího souseda, přidáváme do minimové sítě.
5. (Dokončení) Podle sady pravidel je sledována hranice každé potenciální koruny. Preferovaný pohyb je po směru hodinových ručiček. Smyslem je doplnit místa, kde je minimová síť z nějakého důvodu přerušena (např. dvě blízko sousedící koruny); a naopak odstranit ze sítě slepé konce.
6. (Koruny) Dosavadní postup měl za výsledek binární informaci o tom, kde jsou koruny (1) a kde je pozadí (0). Jednotlivé koruny pak extrahujeme jako souvislé podoblasti plochy korun (1).

Ukázka výsledků segmentace metodou minimové sítě a rozbor jednotlivých parametrů se nachází v praktické části práce, v odstavci 3.3.2.

2.3.3 Růstový algoritmus

Základní princip této metody je trefně vystižen v používaném anglickém termínu – „seeded region growing“, který můžeme přeložit jako rozrůstání oblasti ze semínka. Vycházíme z lokálních maxim – detekovaných vrcholků korun – a plochu koruny rozrůstáme postupným připojováním sousedních pixelů. (Viz obrázek 2.9.)



Obrázek 2.9: Základním principem růstového algoritmu je iterativní připojování pixelů do plochy koruny.

Pro každý potenciálně připojovaný pixel, který je 4-sousedem dosavadní plochy, posuzujeme sadu tzv. stopovacích podmínek. V případě kladného výsledku posuzovaný pixel připojíme k dané koruně. Mezi typické podmínky v kontextu dat laserového skenování patří minimální výškový limit, vzdálenost od vrcholku a vzdálenost od sousedních korun. Právě třetí podmínka je charakteristickým rysem růstového algoritmu – při budování

plochy jedné koruny bereme ohled i na koruny sousední. Z toho plyne další prvek technického řešení – je nutné všechny koruny narůstat současně – jen tak zajistíme korektní vztah dvou blízko stojících korun. Z hlediska implementace a vlivu na výpočetní náročnost se k tomuto prvku vyjadřujeme v praktické části, v kapitole 3.7.

Konkrétní podoba stopovací podmínky může být různá, příklady nalezneme ve studiích různých světových autorů. Podmínky musí být přizpůsobeny také charakteru vstupních DPZ dat. Příklad aplikace této segmentační metody pro hyperspektrální snímky lze nalézt v článku [23], starší práci autora tohoto textu.

V dalším popíšeme komplexní růstový algoritmus, který jsme vyvinuli v rámci této dizertační práce a poprvé publikovali v [25]. Inovativní postup přebírá také prvky aktivní kontury (viz teoretická kapitola 1.1.5).

Pro řízení procesu narůstání pro každou korunu v každém čase definujeme umělou hodnotu energie následujícím vztahem:

$$E = A_H E_H + A_B E_B + A_S E_S + A_N E_N.$$

Jednotlivé komponenty odrážejí různé podstatné parametry koruny a jednotlivé koeficienty A určují jejich váhu. Komponenty E_B a E_S představují ve fyzikální analogii vnitřní energii odvozenou od tvaru koruny, respektive její hranice. Komponenty E_H a E_N představují vnější energii, tíhu působící na okraj koruny a tlak sousedících korun. Komponenta E_H je definována jako průměrná výška hraničních pixelů, komponenta E_B je definována jako délka hranice koruny, komponenta E_S je odvozena z tvaru koruny (kruhovitost, excentricita), komponenta E_N je odvozena z tlaku (vzdálenosti) sousedících korun.

Smysl jednotlivých komponent je následující: E_H táhne hranici koruny dolů (gravitační analogie), E_B a E_S udržují přirozený tvar koruny, E_N řídí vzájemnou polohu sousedících korun, brání jejich překrývání. Jak plocha koruny postupně narůstá, hodnota E_H klesá se snižující se průměrnou výškou na hranici, hodnota E_B mírně roste v souvislosti s prodlužováním hranice, hodnota E_S se mění různě podle změn tvaru koruny a konečně hodnota E_N vzrůstá, když se k sobě přibližují koruny dvou sousedících stromů.

Postup segmentace:

- (Inicializace) Každou korunu zakládáme jako kříž 4-sousedů lokálního maxima. Vypočítáme pro každou korunu základní hodnotu energie. Podle konkrétní zpracovávané oblasti nastavujeme koeficienty energetické bilance a stopovací prahy. Následující čtyři kroky jsou iterační, opakují se tak dlouho, dokud existují neuzavřené koruny.
- (Výběr koruny) Ze seznamu neuzavřených korun vybíráme strom pro růstový krok. Řídíme se podle poměru výška vrcholku ku ploše koruny. To znamená, že nejvyšší a nebo nejméně rozvinuté koruny jsou narůstány dříve. Což odpovídá přirozené konkurenci v přírodě.
- (Kandidáti) Pro vybranou korunu sestavujeme množinu kandidátů, která zahrnuje všechny možnosti připojení jednoho pixelu k dosavadní ploše koruny. Pro každého kandidáta vypočítáme novou hodnotu energie.

- (Ukončovací podmínky) Korunu označíme jako uzavřenou v okamžiku, kdy energie všech kandidátů přesahuje dopředu stanovený ukončovací práh. Nebo v okamžiku, kdy u všech kandidátů vzniká nárůst energie oproti původní hodnotě o více než je předem stanoveno.
- (Růstový krok) Podle principu minimalizace energie vybíráme z množiny kandidátů korunu s nejnižší energií a prohlašujeme ji za další iteraci.

Ukázka výsledků segmentace pomocí růstového algoritmu a detailní rozbor jednotlivých parametrů se nachází v praktické části práce, v odstavci [3.3.3](#).

Kapitola 3

Praktická část

V této kapitole aplikujeme výše popsané postupy na reálná data a posuzujeme jejich účinnost. V první podkapitole uvedeme charakteristiku reálných dat dálkového průzkumu (především leteckého laserového skenování), pořízených Centrem výzkumu globální změny AVČR, na nichž byly jednotlivé postupy otestovány. Druhá podkapitola rozebírá vliv jednotlivých parametrů předzpracování a postup detekce stromů hledáním lokálního maxima výšky. Třetí podkapitola představuje praktické výsledky segmentace třemi výše popsanými delineačními algoritmy, především u růstového algoritmu je zanalyzován vliv každého parametru.

Další doplňující pasáže se týkají hodnocení kvality segmentace, aplikovatelnosti pro jiné datové zdroje a využitím výsledků segmentace v lesnické praxi. Závěrečná podkapitola popisuje počítačovou implementaci jednotlivých kroků, neboť součástí práce jsou také počítačové aplikace použitelné pro zpracování reálných dat.

3.1 Použitá reálná data

V této kapitole popíšeme konkrétní datové zdroje používané v praktické části práce k demonstraci jednotlivých algoritmů.

3.1.1 Data laserového skenování

V praktické části práce budeme používat data ze tří lokalit v ČR, vybraných pro vhodnou (pestrou) skladbu lesů. Druhým omezením při výběru byla, pochopitelně, dostupnost datových zdrojů. Primárním důvodem (nákladného) pořízení dat nebyla tato dizertační práce, ale především jiné širší, projektové záměry Centra výzkumu globální změny, AV ČR.

Data byla pořízena za finanční podpory Ministerstva školství, mládeže a tělovýchovy v rámci projektů COST OC09001, CzeCOS infrastructure LM2010007, CzechGlobe – Centre for Global Climate Change Impacts Studies, Reg. No. CZ.1.05/1.1.00/02.0073 a dále z programu NPU I, číslo projektu LO1415. Budiž za to dík.

Lokalita Bílý Kříž

- Leží v Beskydech na hranicích ČR a SR (obrázek 3.1), jedná se především o smrkový les, jeho části zahrnují dospělý, mladý i směsný porost.
- K dispozici jsou dvě datové sady: první z roku 2010, druhá z roku 2013.
- První sada byla pořízena skenerem Leica, s diskretní formou ukládání (první a poslední odraz pro každý pulz) a bodovou hustotou 5 bodů na m².
- Druhá sada byla pořízena skenerem Riegl, s full-wave formou ukládání (kompletní odražená vlna) a bodovou hustotou 50 bodů na m².

Lokalita Štítná

- Leží v Bílých Karpatech na hranicích ČR a SR (obrázek 3.1), jedná se především o stejnověký bukový les.
- K dispozici jsou tři datové sady: první z roku 2010, druhá a třetí z roku 2013.
- První sada byla pořízena skenerem Leica, s diskretní formou ukládání (první a poslední odraz pro každý pulz) a bodovou hustotou 5 bodů na m².
- Druhá i třetí sada byla pořízena skenerem Riegl, s full-wave formou ukládání (kompletní odražená vlna) a bodovou hustotou 50 bodů na m². Podstatný rozdíl činí přesný termín skenování, u druhé sady je to duben, kdy jsou buky bez listů, a u třetí sady září, kdy stromy listů mají.

Lokalita Rájec

- Leží v Dražanské vrchovině nedaleko od Brna (obrázek 3.1), jedná se především o dospělý smrkový les.
- K dispozici jsou data pořízená v roce 2013 skenerem Riegl, s full-wave formou ukládání (kompletní odražená vlna) a bodovou hustotou 10 bodů na m².

3.1.2 Podpurná data

Mezi podpurná data patří obrazová data, tj. letecké snímky daných lokalit; a dále výsledky pozemních šetření sloužící k verifikaci výsledků automatické segmentace stromů.


Hyperspektrální snímky

- Tato data jsou chápána jako podpurná, slouží mj. k vizuální interpretaci a validaci výsledků. Dále přijdou na řadu v těch pasážích, kdy pracujeme kromě 3D informace i se spektrálními profily.

- Pro lokality Bílý Kříž a Štítná máme kompletní časovou řadu, každoročně je snímáme hyperspektrálním skenerem AISA Eagle, jehož základní technické parametry jsou následující: prostorové rozlišení 0,4 m, spektrální rozlišení 9 nm a spektrální rozsah 400 až 1000 nm.
- Pro lokalitu Bílý Kříž je také možné využít letecké snímky s vysokým prostorovým rozlišením (0,2 m) pořízené čtyřkanálovou kamerou UltraCam.

Pozemní měření

- Pro lokality Bílý Kříž a Štítná máme k dispozici výsledky pozemních šetření provedených Ústavem pro hospodářskou úpravu lesů (<http://www.uhul.cz/>) a Ústavem pro výzkum lesních ekosystémů (<http://www.ifer.cz/>).
- Jejich produktem je přesné zaměření pozice stromů a záznam základních parametrů, z nichž jsou pro nás klíčové výška a průmět koruny.



Obrázek 3.1: Umístění lokalit v rámci ČR. Lokalita B = Bílý Kříž v Beskydech, lokalita S = Štítná v Bílých Karpatech, lokalita R = Rájec v Drahanské vrchovině, lokalita G = golfové hřiště v Jinačovicích u Brna.


3.2 Detekce pozice stromů

Pro detekci pozice stromů využíváme hledání lokálního maxima výšky. Technicky je implementován následující řetězec akcí:

1. Filtrování mapy výše pomocí low-pass filtru.
2. Vyhledání lokálních maxim plovoucím oknem velikosti 3x3 pixely.
3. Určení očekávané velikosti koruny pro každé maximum.
4. Výběr z množiny maxim seřazených podle výšky.
5. Export výsledných pozic.


3.2.1 Filtrování

Srovnajme vliv různého filtrování. Na obrázku 3.2 vidíme původní obraz filtrovaný pomocí mediánu z okolí řádu 3 a mediánu z okolí řádu 7. Na obrázku 3.3 vidíme původní obraz filtrovaný gaussovským jádrem řádu 3 ($\sigma = 1$) a gaussovským jádrem řádu 7 ($\sigma = 2$). Na obrázku 3.4 srovnáváme nalezená lokální maxima v obrazech filtrovaných mediánem řádu 3 a 7, lokální maxima v obrazech filtrovaných gaussovským jádrem řádu 3 a 7 a lokální maxima v obrazech filtrovaných mediánem a gaussovským jádrem.




Obrázek 3.2: Filtrování mediánovým filtrem. Vlevo vstupní obraz, mapa výšek s prostorovým rozlišením 40 centimetrů. Uprostřed je obraz vyhlazený mediánem z okolí řádu 3, vpravo obraz vyhlazený mediánem z okolí řádu 7. V obou případech dochází k odstranění impulzního šumu. Ve druhém případě již dochází ke stírání hranic mezi sousedními korunami, což v principu nemusí být na překážku při samotné detekci. V obou případech dochází ke snížení hodnot v jednotlivých pixelech, což je třeba mít na paměti, pokud nás zajímají reálné výšky detekovaných stromů.

Můžeme říci, že vliv filtrování na fázi detekce není velký, pokud hovoříme o primární množině maxim (v okně 3 krát 3, viz následující odstavec 3.2.2). Primární smysl filtrování – odstranění šumu a nežádoucích podrobností – je naplněn každým z filtrů. Nicméně míra



Obrázek 3.3: Filtrování gaussovským jádrem. Vlevo vstupní obraz, mapa výšek s prostorovým rozlišením 40 centimetrů. Uprostřed je obraz vyhlazený gaussovským jádrem řádu 3 ($\sigma = 1$), vpravo obraz vyhlazený gaussovským jádrem řádu 7 ($\sigma = 2$). V obou případech dochází k odstranění impulzního šumu. Oproti obrázku 3.2 není ani při vyšším řádu výrazné setřetí hranice mezi korunami. Zároveň díky normalizaci gaussovského jádra můžeme počítat s minimálním ovlivněním absolutních hodnot výšky.

vyhlazení obrazu ovlivňuje lokální charakteristiky obrazu, které používáme při stanovení očekávané velikosti koruny. Na obrázku 3.4 zobrazujeme výslednou množinu maxim po probírce (viz následující odstavec 3.2.3), proto se změna počtu a pozice maxim jeví výrazná. Za filtr, který se na našich datech nejvíce osvědčil můžeme označit gaussovské jádro řádu 3 ($\sigma = 1$), protože primární účel naplňuje s minimálním vlivem na skutečné vrcholky korun.




Obrázek 3.4: Různé metody filtrování. Vlevo srovnáváme mediánový filtr řádu 3 a řádu 7, uprostřed gaussovský filtr řádu 3 a řádu 7 a vpravo gaussovský filtr řádu 3 a mediánový filtr řádu 3. Vždy platí, že modré body byly označeny jako maximum v prvním obraze, červené body ve druhém a zelené jsou shodné pozice maxim při obou způsobech filtrování.

3.2.2 Prvotní vyhledání maxim

Do prvotní množiny lokálních maxim zařazujeme všechny pixely, které mají vyšší hodnotu než všechny sousední z okolí řádu 3. Jediným vyřazovacím kritériem je minimální výška maxima odvozená od výškového složení zkoumaného porostu.

Na obrázku 3.5 vidíme, jak změní množinu lokálních maxim výškový limit $h \geq 5$, $h \geq 10$ a $h \geq 15$.



Obrázek 3.5: Prvotní vyhledání lokálních maxim

3.2.3 Očekávané rozměry koruny


Očekávané rozměry koruny odpovídající každému jednomu lokálnímu maximu určujeme třemi metodami.

1. Pomocí alometrických rovnic mezi výškou stromu a průměrem koruny.
2. Pomocí hledání hranice klesání.
3. Pomocí analýzy soběpodobnosti.


Pro mladé smrky (nižší než 15 metrů) používáme následující alometrickou rovnici ([27]): $CD = 18.621 H + 116.21$. Pro dospělé smrky (vyšší než 15 metrů) používáme následující alometrickou rovnici ([30]) $H = 11,5CD - 10,5$. Pro buky používáme následující alometrickou rovnici ([30]) $H = 19,3 \ln(CD) - 0,9$. Kde vždy H je výška stromu a CD je průměr koruny.

Na obrázku 3.6 vidíme navrhovanou velikost koruny dle alometrických rovnic pro různá lokální maxima. Vidíme, že u stromů, které nestojí samostatně, ale v zápoji, je navržený průměr koruny nadhodnocený. Proto budeme v dalším záměrně u této položky snižovat váhu.

Druhá metoda konstruuje transepty ve čtyřech základních směrech a hledá na nich nejbližší místo od středu (lokálního maxima), kde výška přestane klesat. Vizualizaci vidíme na obrázku 3.7. Jako návrh průměru koruny bereme průměrnou hodnotu ze čtyř transektů.




Obrázek 3.6: Velikost koruny navržená podle alometrické rovnice.



Obrázek 3.7: Velikost koruny navržená podle metody spádu.

Na obrázku nejvíce vlevo vidíme, že tato metoda je poměrně citlivá na filtrování vstupní mapy výšek. Je-li zhlazení nedostatečné, první derivace podél transektu osciluje a spádová metoda se zarazí na podrobnostech uvnitř koruny, ne na jejím okraji.

Třetí metoda na týchž transektech hledá hranici nasycení křivky semivariance. Vizualizaci vidíme na obrázku 3.8. Jako návrh průměru koruny bereme průměrnou hodnotu ze čtyř transektů.




Obrázek 3.8: Velikost koruny navržená podle metody soběpodobnosti.

3.2.4 Výběr z množiny maxim


Při výběru z množiny maxim procházíme jejich seznam seřazený podle velikosti od nejvyššího. Podle očekávané velikosti koruny určíme okolí maxima, kde nepředpokládáme výskyt dalšího stromu. Proto vyřazujeme z množiny nižších maxim všechna, která jsou geometricky blíže než daný poloměr okolí. Očekávaný poloměr koruny stanovujeme metodami zmíněnými v předchozím odstavci. Jednotlivé doporučené hodnoty kombinujeme

pomocí váhových koeficientů. Poloměr $\rho = w_1\rho_1 + w_2\rho_2 + w_3\rho_3$ určujeme jako vážený průměr poloměrů w_i doporučených dle alometrických rovnic, spádu a soběpodobnosti. Poměr mezi koeficienty určuje váhu jednotlivých doporučení a součtem $\sum w_i$ můžeme korigovat absolutní sílu probírky v prvotní množině lokálních maxim.




Obrázek 3.9: Probírka v množině lokálních maxim.


Na obrázku 3.9 ilustrujeme výslednou množinu lokálních maxim ve srovnání s množinou prvotní. Vpravo jsou červenou barvou znázorněna maxima, která byla vyřazena, protože se blízko od nich vyskytuje maximum významnější. Další obrázky (3.10, 3.11, 3.12) pak srovnávají vliv jednotlivých metod určení očekávaného poloměru koruny. Jednotlivé parametrizace kódujeme schématem $w_1/w_2/w_3$, kde w_1 je váha podle alometrické rovnice, w_2 váha podle spádové metody a w_3 váha podle metody semivariance.



Obrázek 3.10: Probírka v množině lokálních maxim pomocí alometrické rovnice. Červeně označená maxima byla vyřazena. Vlevo je parametrizace 0,9/0/0, vpravo parametrizace 0,6/0/0.



Obrázek 3.11: Probírka v množině lokálních maxim pomocí spádové metody. Červeně označená maxima byla vyřazena. Vlevo je parametrizace $0/0,9/0$, vpravo parametrizace $0/0,6/0$.



Obrázek 3.12: Probírka v množině lokálních maxim pomocí soběpodobnosti. Červeně označená maxima byla vyřazena. Vlevo je parametrizace $0/0/0,9$, vpravo parametrizace $0/0/0,6$.

3.2.5 Export výsledných pozic

Pro export výsledných pozic k dalšímu zpracovávání je nezbytné nastavení geografického souřadného systému a typický výstup pak vypadá následovně (obrázek 3.13). Na každém řádku jsou souřadnice maxima v obraze (img x, img y), souřadnice maxima v geografickém souřadném systému (real x, real y), výška v původním (real h) a ve zfiltrovaném obraze (flt h). Obrazové souřadnice využíváme, když pokračujeme fází delineaace. Reálné souřadnice slouží k nahrání pozice stromů do GIS softwarů a následnému překrytí s jinými vrstvami z dat DPZ. Můžeme si povšimnout, že výška odečtená po vyhlazení je vesměs nižší než výška původní. Jedinou výjimku tvoří situace s impulzním šumem, kdy hodnota adaptivně dopočítaná z okolí může představovat lepší odhad výšky stromu než vadná hodnota původní.

img x	img y	real x	real y	real h	flt h
361	36	756055,211	5489783,682	25,86999893	25,28921127
340	34	756046,811	5489784,482	25,40999985	25,04736519
380	82	756062,811	5489765,282	25,61999893	24,89453506
294	37	756028,411	5489783,282	24,63999939	24,33397293
397	23	756069,611	5489788,882	24,6099987	24,12443352
329	22	756042,411	5489789,282	25,23999977	23,85752869
196	8	755989,211	5489794,882	24,13999939	23,80178261
112	374	755955,611	5489648,482	24,93000031	23,65045547
286	56	756025,211	5489775,682	24,03999901	23,63976097
87	399	755945,611	5489638,482	24,10000038	23,54184151
387	141	756065,611	5489741,682	24,14999962	23,19896698
314	28	756036,411	5489786,882	24,52999878	23,0206337
114	20	755956,411	5489790,082	23,45999908	22,80926704
143	399	755968,011	5489638,482	22,51000023	22,44408989
228	66	756002,011	5489771,682	22,65999985	22,29325294
356	5	756053,211	5489796,082	23,28999901	22,28190804
389	37	756066,411	5489783,282	22,77999878	22,26750183
348	6	756050,011	5489795,682	22,65999985	22,18476677
308	17	756034,011	5489791,282	22,72999954	22,16975403
375	10	756060,811	5489794,082	22,57999992	21,86519814
239	59	756006,411	5489774,482	22,26999855	21,81079865
364	60	756056,411	5489774,082	22,18000031	21,74905014
381	124	756063,211	5489748,482	22,48999977	21,68046951
304	72	756032,411	5489769,282	22,60000038	21,57925415
385	6	756064,811	5489795,682	22,21999931	21,56807518
334	45	756044,411	5489780,082	21,57999992	21,42313385
51	361	755931,211	5489653,682	22,23999977	21,18601418
294	63	756028,411	5489772,882	21,36999893	21,0179882
321	2	756039,211	5489797,282	21,63999939	20,98177338
60	371	755938,411	5489648,682	21,53000046	20,87252800

Obrázek 3.13: Výpis seznamu lokálních maxim.

3.3 Delineace plochy korun


Pro následné srovnání byly implementovány všechny tři základní metody – zaplavování (2.3.1), minimová síť (2.3.2) a růstový algoritmus (2.3.3).

3.3.1 Zaplavování

Metodu zaplavování jsme implementovali podle značkovacího algoritmu popsaného v odstavci 2.3.1. Vstupní množinu tvoří lokální maxima. Dále přidáváme jejich 4-sousedy, pokud splňují čtyři podmínky:

1. Nevychází za hranice zpracovávaného obrazu.
2. Nebyli dosud zařazeni do některé koruny.
3. Jejich výška neklesá pod zadaný minimální limit.
4. Jejich výška není vyšší než výška mateřského pixelu.

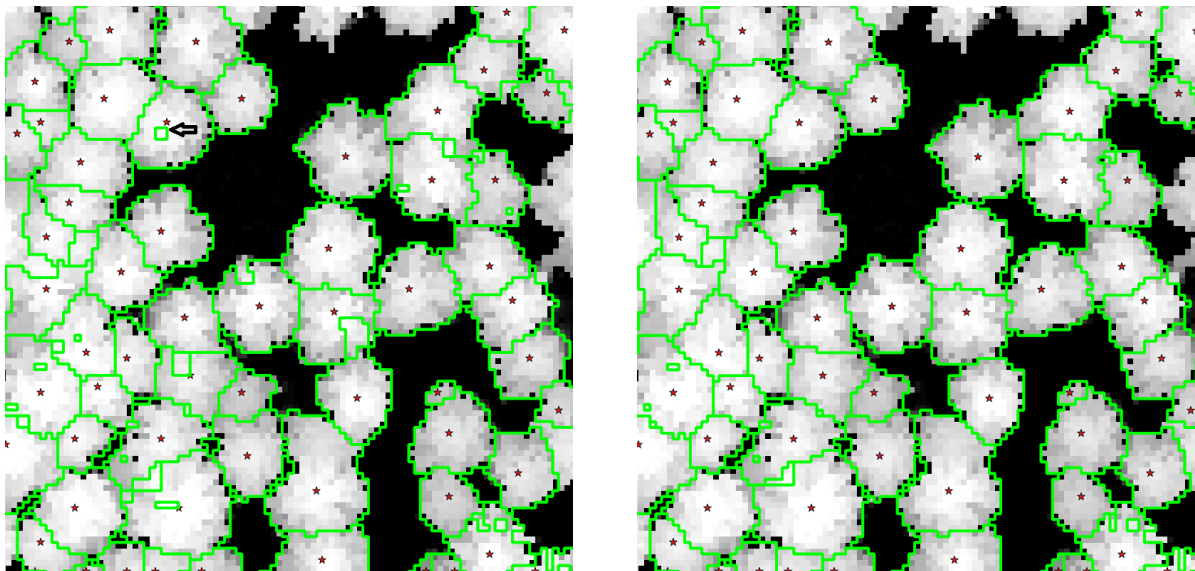
Podmínky 1) a 2) jsou očividné. Limit z podmínky 3) by měl odpovídat výšce okrajů koruny, což je pochopitelně číslo odlišné pro různé druhy stromů a závisí též na věku a zapojení stromů v porostu. Limit můžeme nastavovat fixně, nebo jako procento z výšky daného stromu. Na obrázku 3.14 vidíme vliv tohoto limitu na nalezené hranice korun, vlevo byl limit 4,4 m a vpravo 9,9 m; v obou případech u dospělých smrků průměrné výšky okolo 30 m.



Obrázek 3.14: Vliv limitu minimální výšky na hranice korun.

Čtvrtá podmínka tak, jak je doslova zapsaná výše, je příliš tvrdá. Nebere totiž v potaz, že při probírce mezi maximy (3.2.4) jsme hledali koruny, na nichž jsou detekovány dva


vrcholky. Takové falešné vrcholky budou totiž při aplikování podmínky 4) ze „zaplavované“ plochy vyloučeny. Což můžeme vidět na obrázku 3.15 vlevo (jeden příklad je označený šipkou). Podmínku 4) proto prakticky zeslabujeme tolerováním mírného nárůstu výšky. Například pro analýzu na obrázku 3.15 vpravo byla použita tolerance 10 cm.



Obrázek 3.15: Vliv falešných vrcholků na polygony korun.


3.3.2 Minimová síť

Tato metoda byla implementována podle algoritmu popsaného v odstavci 2.3.2. Na obrázku 3.16 vidíme výřez z rozsáhlejší mapy výšek z oblasti dospělého smrkového lesa u Rájce-Jestřebí, na němž budou následně demonstrovány jednotlivé kroky algoritmu.



Obrázek 3.16: Vstupní obraz pro segmentaci pomocí minimové sítě. Vlevo mapa výšek, uprostřed zfiltrovaný obraz, vpravo detekovaná lokální maxima – pozice jednotlivých stromů.

Společným jmenovatelem procesu segmentace pomocí minimové sítě je odlišování hledaných objektů – korun stromů od pozadí. V prvním kroku do plochy pozadí zařazujeme všechny pixely s výškou nižší než určitý zvolený limit (obrázek 3.17 vlevo), konkrétně v tomto případě jsme použili minimální výšku okrajů koruny rovnu 9 m. (Je to relativně hodně, ale jedná se o dospělé stromy, takže i takové číslo je adekvátní.)




Obrázek 3.17: Aplikace limitu minimální výšky – červené podbarvení na obrázku vlevo. Detekce lokálních minim – zelené tečky na obrázku vpravo.

V dalších krocích hledáme hranice mezi korunami v podobě tzv. minimové sítě. Druhým krokem je tak detekce lokálních minim, neboli bodů v obraze, které jsou nižší než všech 8 jejich sousedů. Na obrázku 3.17 vpravo vidíme, že takových bodů – které následně tvoří základ minimové sítě – nebývá mnoho. Každopádně tyto body také zařazujeme do pozadí.

Třetím krokem je připojení tzv. bodů údolí – formulačně tento algoritmus sleduje analogii mezi povrchem lesa a hornatou krajinou. Bod údolí musí splňovat dvě podmínky, zaprvé navazuje v určitém směru (stranou či rohem) na nějaký bod pozadí dle předchozích kroků, zadruhé je z obou stran ve směru kolmém k předchozímu ohraničený vyššími pixely. Rozlišujeme řád údolí podle vzdálenosti těchto vyšších pixelů. Jsou-li to přímí sousedé, hovoříme o řádu 1; ob jeden pixel je to řád 2 a tak dále. Iterativním průchodem (se sledováním počtu změn) se minimová síť postupně rozrůstá z lokálních minim dále podél údolí. Až se nakonec tato údolí také spojí se souvislými plochami pozadí v oblastech mimo stromy. Viz obrázek 3.18 vlevo – modrou barvou je zakreslena minimová síť, konkrétně řádu 2.

Také celou minimovou síť zařazujeme do pozadí a definitivně rozkládáme obraz na dvě disjunktní podmnožiny, jak je znázorněno na obrázku 3.18 vpravo. Červené pozadí odděluje zelené plochy jednotlivých korun. Přesněji řečeno, vidíme, že oddělení některých korun není dokonalé, ani některé konkrétní tvary, proto je součástí algoritmu další fáze –




Obrázek 3.18: Propojení minimové sítě pomocí bodů, které splňují vlastnosti údolí – modré znázornění na obrázku vlevo. Oddělení plochy korun od pozadí – zelená vs. červená na obrázku vpravo.


finalizace jednotlivých korun. K průběžnému posouzení kvality segmentace si pomáháme lokálními maximy detekovanými v předstihu (viz obrázek 3.16 vpravo). Pro každý segment spočítáme, kolik stromů (lokálních maxim) jeho plocha pokrývá. Tyto počty jsou barevně ilustrovány na obrázku 3.19 vlevo – černě jsou segmenty bez maxima, korespondence 1:1 je označena zeleně, modré segmenty obsahují několik maxim.

Černé segmenty, tj. segmenty bez detekovaného maxima, jednoduše vypouštíme, řadíme je mezi pozadí. Při finalizaci zbylých korun pak aplikujeme opravy dvou nedokonalostí primární segmentace tak, jak je také naznačuje obrázek 3.19 vlevo žlutými šipkami. Některé dvojice korun je potřeba oddělit – odstříhujeme taková místa, kde jednopixelová část „koruny“ sousedí přímo z obou stran s pozadím. Naopak u některých korun je potřeba potlačit „slepá údolí“ zakousnutá do přirozené plochy koruny. V tomto kroku zaplňujeme pixely pozadí, které sousedí stranou s alespoň třemi pixely stejné koruny. Výsledek finalizace vidíme na obrázku 3.19 vpravo. Až na dvě výjimky všechny segmenty odpovídají, dle detekce, jedinému stromu. Dodejme, že Gougeon v původní citované práci [10] používá jiný finalizační postup, my jsme z ilustrativních důvodů u nepreferované delineační metody sáhli k výše popsanému zjednodušení.

Na posledním obrázku (3.20) vidíme vektorové znázornění výsledku detekce a delineaace korun stromů metodou minimové sítě. V levé části zůstaly tři segmenty, kde nedošlo k oddělení pro neexistenci dostatečně výrazného „údolí“ mezi korunami. Na některých místech také pozorujeme ne zcela přirozený tvar delineaované koruny. Tyto problémy vesměs řeší růstový algoritmus prezentovaný v příštím odstavci.




Obrázek 3.19: Vlevo vizualizace počtu stromů v rámci jednotlivých segmentů a označení vad primární segmentace. Vpravo výsledná segmentace po finalizaci jednotlivých korun.



Obrázek 3.20: Výsledek detekce a delinace korun stromů metodou minimové sítě.

3.3.3 Růstový algoritmus

Metodu *seeded region growing* jsme implementovali podle našeho algoritmu popsaného v odstavci 2.3.3. Vstupem je množina lokálních maxim, okolo každého zakládáme korunu stromu jako kříž 4-sousedů maxima, viz obrázek 3.21. Dále nastavujeme koeficienty energetické bilance a ukončovací podmínky. Vliv těchto faktorů nyní rozebereme podrobněji.




Obrázek 3.21: Inicializace růstového algoritmu. Každou korunu zakládáme jako kříž 4-sousedů maxima.

Pro testování citlivosti jednotlivých parametrů (anglicky *sensitivity analysis*) jsme připravili v počítačové aplikaci samostatný modul, který umožňuje provést opakované zpracování shodného výřezu s nastavením shodným až na jeden nebo dva parametry. Výsledky pak porovnáváme a posuzujeme vliv různého nastavení energetické bilance.

První skupinu koeficientů tvoří faktory tvaru (koeficienty c_D a c_K), které působí společně a můžeme na ně pohlížet jako na jeden celek. V tabulce 3.1 uvádíme soupis srovnávaných nastavení. V popisku tabulky 3.1 také přesně definujeme 11 veličin používaných k parametrizaci energetické bilance. Stejně značení budeme používat v celé této kapitole. Na obrázku 3.22 vidíme dvě kontrastující situace, nastavení $ID = 2$ a $ID = 9$ dle tabulky 3.1. Je-li kladen vyšší důraz na délku hranice a kulatost plochy korun (vpravo), u některých segmentovaných korun dochází k výrazné úpravě tvaru, jinde převládá vliv ostatních koeficientů celkové bilance. Do dalších analýz přebíráme jako optimální nastavení pro naše ukázková data hodnoty $c_D = 3$ a $c_K = 4$.

Tabulka 3.1: Citlivostní analýza pro koeficienty tvaru. Význam jednotlivých parametrů energetické bilance je následující: ID = číslo analýzy, E_M = horní limit celkové energie, E_n = maximální přípustný nárůst energie v jednom kroku, c_V = koeficient (váha) výšky, v_m = minimální výška okraje koruny, c_D = koeficient (váha) délky hranice, c_K = koeficient (váha) kulatosti koruny, c_E = koeficient (váha) excentricity koruny, c_O = koeficient (váha) vlivu okolí, o_i = váha sousedních korun vzdálených o 3, 2, 1 pixel.

ID	E_M	E_n	c_V	v_m	c_D	c_K	c_E	c_O	o_1	o_2	o_3
1, 2, 3	25	0,15	5	3	2, 3, 4	2	1	1	1	3	9
4, 5, 6	25	0,15	5	3	2, 3, 4	4	1	1	1	3	9
7, 8, 9	25	0,15	5	3	2, 3, 4	6	1	1	1	3	9




Obrázek 3.22: Vliv změny koeficientů tvaru na výslednou segmentaci.

Specifickým faktorem tvaru je excentricita – koeficient c_E . Počítá se totiž pevně vůči detekovanému lokálnímu maximu coby středu koruny. Provedenou citlivostní analýzu shrnuje tabulka 3.2. Na obrázku 3.23 vidíme dvě kontrastující situace, nastavení ID = 1 a ID = 3 dle tabulky 3.2. Je-li na excentricitu kladen v energetické bilanci velký důraz (pravý obrázek), může to vést k výrazné redukci plochy segmentů (viz vpravo nahoře). Přitom excentrický tvar koruny nemusí být nepřirozený, obzvláště v situaci, kdy stojí stromy blízko u sebe (viz vlevo nahoře). Na zajímavý efekt komplexního růstového algoritmu poukazujeme vpravo dole. Po ústupu jedné koruny z jejího excentrického výběžku se do uvolněného prostoru rozšiřuje koruna sousední. To je výhoda simultánního narůstání všech korun zároveň.

Další skupinu koeficientů tvoří faktory výšky. Podobně jako u zaplavovacího algoritmu (viz rozbor v odstavci 3.3.1) nastavujeme limit minimální výšky na okraji koruny – koefi-

Tabulka 3.2: Citlivostní analýza pro koeficient excentricity.

ID	E_M	E_n	c_V	v_m	c_D	c_K	c_E	c_O	o_1	o_2	o_3
1, 2, 3, 4	25	0,15	5	3	3	4	1, 2, 3, 4	1	1	3	9



Obrázek 3.23: Vliv změny koeficientu excentricity na výslednou segmentaci.


cient v_m . Udává se přímo v metrech, na rozdíl od ostatních koeficientů, které jsou de facto bezrozměrné. Provedenou citlivostní analýzu shrnuje tabulka 3.3. Na obrázku 3.24 vidíme dvě kontrastující situace, nastavení ID = 1 a ID = 4 dle tabulky 3.3. Na obrázku vlevo je minimální výška posazena níže, u některých korun je vliv na segmentaci přímý, jinde se projeví v rámci iterativního růstového procesu komplexněji. Do dalších analýz přebíráme jako optimální nastavení pro naše ukázkové území hodnotu $v_m = 3$ m.

Koeficient c_V , který určuje váhu průměrné výšky na okraji koruny v rámci energetické bilance, stanovujeme obecně vyšší než koeficienty ostatní, protože právě výška na okraji koruny je nejdůležitější hybnou silou růstového procesu vzhledem k analogii s principem adaptivní kontury. Provedenou citlivostní analýzu shrnuje tabulka 3.3, v použitém rozmezí byl určující vliv této složky energie na našich datech vždy dostatečný. Do dalších analýz používáme jako optimální hodnotu $c_V = 5$.

Tabulka 3.3: Citlivostní analýza pro minimální výšku na okraji koruny a koeficient průměrné výšky.

ID	E_M	E_n	c_V	v_m	c_D	c_K	c_E	c_O	o_1	o_2	o_3
1, 2, 3, 4	25	0,15	5	2, 3, 4, 5	3	4	1	1	1	3	9
5, 6, 7, 8, 9	25	0,15	3, 4, 5, 6, 7	3	3	4	1	1	1	3	9

Celkové chování růstového algoritmu nejvíce ovlivňuje nastavení ukončovacích podmínek. Hodnota koeficientu E_n určuje maximální přípustný nárůst energie během jedné

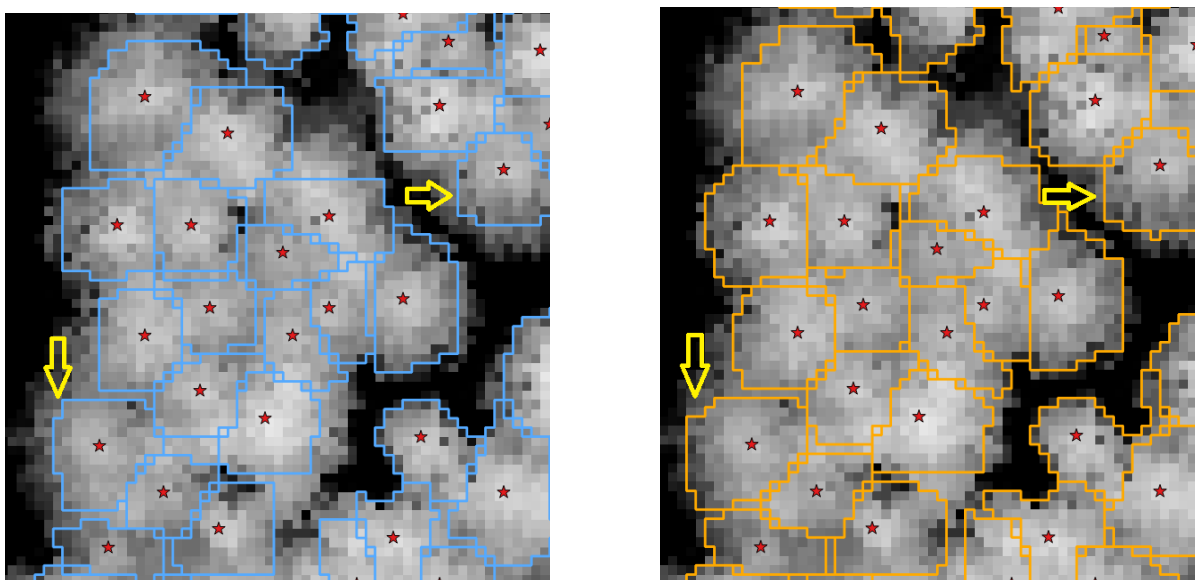


Obrázek 3.24: Vliv změny minimální výšky na okraji koruny na výslednou segmentaci.

iterace. Ta může být nastavena relativně pevně. Dle níže uvedené analýzy citlivosti se pro náš testovací výřez osvědčily hodnoty mezi 10 a 15 procenty. Hodnota koeficientu E_M určuje maximální absolutní hodnotu energie. Ta je sice vynásobena výškou daného stromu a není tak pro všechny stejná, přesto se jedná o hodnotu, kterou nelze určit dopředu. Je třeba otestovat různá nastavení podle druhového a věkového složení porostu ve zpracovávané oblasti. Provedenou citlivostní analýzu shrnuje tabulka 3.4. Na obrázku 3.25 vidíme dvě kontrastující situace, nastavení $ID = 13$ a $ID = 10$ dle tabulky 3.4. Na pravém obrázku vidíme obecně vyšší rozsah segmentovaných korun vzhledem k volnějším nastavením ukončovacích limitů. Podle vizuální interpretace, případně podle dílčího terénního šetření je třeba rozhodnout, který limit vede k výsledku lépe odpovídajícímu realitě.

Tabulka 3.4: Citlivostní analýza pro stopovací limity.


ID	E_M	E_n	c_V	v_m	c_D	c_K	c_E	c_O	o_1	o_2	o_3
1, 2, 3, 4, 5	15, 20, 25, 30, 35	0,05	5	3	3	4	1	1	1	3	9
6, 7, 8, 9, 10	15, 20, 25, 30, 35	0,10	5	3	3	4	1	1	1	3	9
11, 12, 13, 14, 15	15, 20, 25, 30, 35	0,15	5	3	3	4	1	1	1	3	9
16, 17, 18, 19, 20	15, 20, 25, 30, 35	0,20	5	3	3	4	1	1	1	3	9
21, 22, 23, 24, 25	15, 20, 25, 30, 35	0,25	5	3	3	4	1	1	1	3	9



Obrázek 3.25: Vliv změny stopovacích limitů na výslednou segmentaci.

3.3.4 Srovnání delineačních algoritmů

Objektivní srovnání delineačních algoritmů je možné pouze na shodné datové sadě. Dále musí být parametrizace jednotlivých metod srovnatelně vyladěná pro dané území, pro což nejsou vždy dostatečné podklady. Přebíráme zde jedno srovnání z článku [25], na kterém vyložíme charakteristické rysy metody zaplavování a růstového algoritmu (viz obrázek 3.26).



Obrázek 3.26: Srovnání dvou delineačních algoritmů.

Na levém obrázku je výsledek segmentace metodou zaplavování, na pravém výsledek segmentace pomocí řízeného růstového algoritmu.

U zaplavování vidíme, že segmenty jednotlivých korun se takřka beze zbytku podělí o celou plochu lesa, vynechají pouze pixely nižší zadaného výškového prahu. Takový přístup je poměrně korektní u zapojeného porostu, kde na sebe jednotlivé koruny opravdu navazují. Nicméně, nebere se pak ohled na možnou chybu opomenutí ve fázi detekce, kterou na několika místech ukázkového výřezu vidíme a která se projeví jedním segmentem přes několik korun. Dále, vzhledem ke geometrické podstatě delineačního procesu, jsou hranice segmentů přímočaré do té míry, že to nepůsobí přirozeně.

U růstového algoritmu vidíme, že každý korunový segment vychází ze svého středového bodu. Tvar korunových segmentů je přirozenější (hladší), přičemž se na mnoha místech přizpůsobí i realitě sousedících korun excentrického tvaru. Plocha uvolněná opomenutými vrcholky není nutně zabrána, tlak okolí tomu nebrání, ale gravitační síla působící na hraniční konturu ano.

V obou případech samozřejmě odhlížíme od artefaktů na okrajích obrázku, taková je běžná situace při dlaždicovém zpracování většího území.


3.4 Hodnocení výsledků segmentace

Výsledky segmentace obvykle posuzujeme vůči vizuální interpretaci snímků, případně vůči lesnickému terénnímu šetření. K prvnímu přístupu uvádíme konkrétní čísla dle článku [25].

3.4.1 Hodnocení kvality detekce

Detekované pozice stromů třídíme do tří kategorií.

1. Korektní. Detekovaná pozice stromu odpovídá pozici stromu ve skutečnosti.
2. Opomenutá. Chyba 1. druhu. Strom zde ve skutečnosti je, algoritmus ale dané místo neoznačil.
3. Nadbytečná. Chyba 2. druhu. Algoritmem označený strom ve skutečnosti neexistuje.



Obrázek 3.27: Hodnocení kvality detekce. Vlevo příklady chyby 1. druhu, vpravo příklady chyby 2. druhu.

Na obrázku 3.27 vlevo jsou označena 2 místa, kde se v realitě strom vyskytuje, ale dané místo nebylo algoritmem detekce označeno. K dané chybě může dojít při nesprávně nastaveném výškovém limitu (opomenutí nižších stromů), s příliš velkým plovoucím oknem při detekci (opomenutí jednoho z více blízko sebe stojících stromů), nebo v situaci, kdy hodnoty v normalizovaném modelu povrchu vykazují nějaké singulární chování a algoritmus tak ani nemůže situaci vyhodnotit správně.

Na obrázku 3.27 vpravo jsou označena 2 místa, kde algoritmem detekovaný bod ve skutečnosti nepředstavuje strom. Může se zdát až nespravedlivé označovat za chybu detekovaný komín (na domě vlevo). Nutno říci, že to je opravdu nejčastější příklad chyby nadbytečnosti. Pokud není před samotnou detekcí provedena klasifikace povrchů, pak nejčastější automaticky detekované nadbytečné stromy jsou jiné objekty, které skutečně představují lokální maxima výšky a samotný detekční algoritmus tak na vině není. Pokud jsou označeny dva vrcholky u jediného reálného stromu, můžete to především značit, že plovoucí okno při detekci nebylo dostatečně velké, jak by odpovídalo výšce stromu daného druhu.

Ve studii [25] bylo zpracováno území tří lokalit, jejich charakteristiky uvádí tabulka 3.5. Ve všech třech případech bylo zpracováno území 500 krát 500 metrů, v tabulce uvádíme počet detekovaných stromů a průměrnou výšku včetně směrodatné odchylky. Vidíme, že na Bílém Kříži se jednalo o mladý porost, v Rájci a ve Štítné o dospělé stromy.

Tabulka 3.5: Tři testovací lokality

Lokalita	druh porostu	počet stromů	statistiky výšky
Bílý Kříž	smrkový les	5305	$11,9 \pm 3,8$ m
Rájec	smrkový les	4538	$27,6 \pm 4,1$ m
Štítná	bukový les	6204	$26,9 \pm 2,6$ m

Účinnost detekce byla posouzena na několika náhodně vybraných podoblastech dané lokality. Vizuální interpretací byly rozlišeny stromy korektně detekované a opomenuté. Výsledky této inspekce shrnuje tabulka 3.6. Dosažená účinnost okolo 85 % je mírně podprůměrná v porovnání s obvyklými čísly ze srovnatelných studií. Důvodem může být, že z adaptivních technik popsaných v kapitole 2.2.1 byla využita pouze alometrická rovnice mezi výškou stromu a očekávaným průměrem koruny.

Tabulka 3.6: Posouzení účinnosti detekce stromů

Lokalita	korektní	opomenuté	účinnost
Bílý Kříž	315	59	85,1 %
Rájec	372	53	87,5 %
Štítná	405	80	83,5 %

3.4.2 Hodnocení kvality delineace

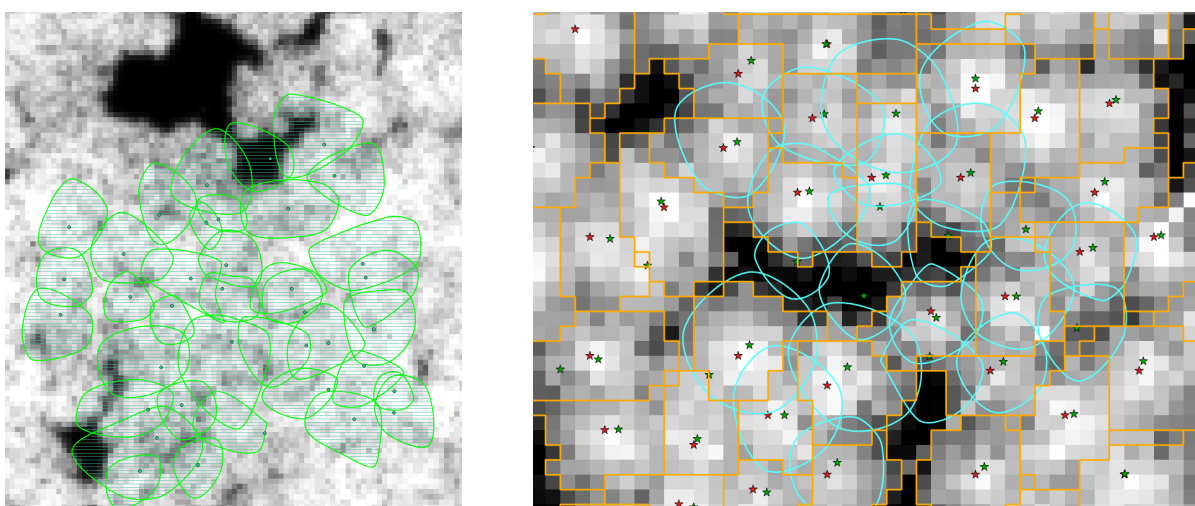
Vizuální interpretace tvaru koruny je náročnější než posouzení pozice stromu. Kromě sledování přesného průběhu hranice koruny je vhodné mít na paměti další účel zpracování. Můžeme se tak například zaměřit na množství biomasy, které by odpovídalo delineované ploše ve srovnání s biomasou odpovídajícího stromu. Ve studii [25] byly při manuálním hodnocení kvality delineace polygony korun tříděny do čtyř kategorií, kde hodnocení 1 znamenalo 95% shody s reálným tvarem koruny, 2 \approx 75%, 3 \approx 50% a 4 \approx 25%. Dosažené výsledky shrnuje tabulka 3.7. Účinnost okolo 80 % je mírně nadprůměrná v porovnání s obvyklými čísly ze srovnatelných studií. Především pro dospělé stromy se podařilo nastavit dobré parametry řízeného růstového algoritmu.

Tabulka 3.7: Posouzení účinnosti delineaace stromů

Lokalita	95 %	75 %	50 %	25 %	účinnost
Bílý Kříž	122	176	54	4	76,8 %
Rájec	177	188	53	10	79,0 %
Štítná	169	294	21	1	80,8 %

3.4.3 Terénní šetření

Při srovnávání výsledků segmentace korun v datech DPZ s lesnickým terénním šetřením je třeba dbát na použití stejného souřadného systému. Obecně může být problém s přesností GPS souřadnic při zaměřování v terénu. Z principu používání laserového dálkoměru plyne spolehlivé zaměření vzájemné pozice stromů v dané lokalitě, ale problematické bývá zaměření pozice této lokality v globálním souřadném systému. Výsledky terénního šetření a letecká DPZ data pak na sebe jednoduše neseďí. Tuto neblahou situaci vidíme na obrázku 3.28 – zaměřené pozice stromů a hranice korun kvůli velké chybě GPS polohy prakticky nelze použít k posouzení kvality automatického zpracování.



Obrázek 3.28: Záznam měření stromů přímo v terénu. Vlevo doklad nesouladu v geometrii způsobeného nepřesností GPS polohy. Vpravo srovnání automatické detekce (červené hvězdy), pozic stromů zaměřených v terénu (zelené hvězdy), automatické delineaace (oranžové linie) a hranic korun zaměřených v terénu (modré linie).

Nadějnější situaci vidíme na obrázku 3.28 vpravo. Zelené hvězdy představují pozice kmenů zaměřené v terénu pomocí GPS. Červené hvězdy představují vrcholky stromů detekované automaticky. Modré linie představují hranice korun vytyčené laserovým dálkoměrem v terénu. Oranžové linie představují automatickou segmentaci pomocí zaplavovacího algoritmu.

Červené a zelené hvězdy se s výjimkou jediného místa (nahore uprostřed) přesně nepřekrývají, nicméně vidíme několik odpovídajících si dvojic. Zbytková chyba může být stále přičtena nepřesnosti GPS polohy, případně faktu, že zaměřená pozice kmene nemusí horizontálně odpovídat pozici vrcholku, který „vidíme“ shora v modelu povrchu. (Odklon kmene může činit až několik metrů.) Několik stromů z terénního šetření nebylo automaticky detekováno a jedná se o chybu detekce prvního druhu. Pozornému čtenáři ale jistě neunikly zelené hvězdy v místech, kde podle mapy výšek strom není (tmavá místa uprostřed zobrazené plochy). Tato nedokonalost ilustrativního příkladu souvisí s tím, že terénní šetření a letecké laserové skenování neproběhlo současně. Bohužel. Terénní kampaň se datuje před a letecká kampaň po polomu větrem, takže na zmíněných místech už v současnosti opravdu stromy nejsou.

Při srovnávání delineaace korun je třeba mít na paměti technické parametry obou přístupů. V terénu se vymezení korun provádí pomocí výtyčky a laserového dálkoměru. Hranice koruny je prokládána několika body zaměřenými na spodním okraji nejdelších větví. Automatická delineaace probíhá pohledem shora na model povrchu lesa a jedním ze základních předpokladů je vzájemné neprostupování jednotlivých korun. Proto modré a oranžové polygony nepředstavují úplně srovnatelné veličiny. V praktické aplikaci je pak třeba mít na paměti, co lze a co nelze danou technikou „změřit“.

3.5 Typ vstupních dat

V kapitole 3.1 jsme za vstup do algoritmů segmentace označili produkty leteckého laserového skenování. Nejedná se ovšem o jediný možný typ vstupních dat pro analýzu lesních systémů s ohledem na segmentaci plochy lesa na jednotlivé stromy. V různých studiích z doby minulé, ale i současné, se kromě dat leteckého laserového skenování používají též data pasivního dálkového průzkumu, především multispektrální a hyperspektrální letecké snímky. Viz tabulka 3.8 dokládající zlomek literární rešerše z článku [24].

Proto v tomto odstavci stručně srovnáme, po ideové stránce, oba typy vstupních dat. Rozebereme jejich charakter a poukážeme na odlišnosti v jejich zpracování.

Tabulka 3.8: Přehled vybraných studií zabývajících se segmentací korun stromů v datech aktivního / pasivního dálkového průzkumu.

Typ vstupních dat	Příklady studií (autor, země a rok vydání)
Pasivní DPZ (multispektrální či hyperspektrální snímky)	Culvenor (Austrálie, 2002) [8] Pitkänen (Finsko, 2001) [26] Erikson (Švédsko, 2003) [9] Pouliot et al. (Kanada, 2005) [28] Bunting & Lucas (Austrálie, 2006) [6] Hirschmugl et al. (Rakousko, 2007) [12]
Aktivní DPZ (data laserového skenování)	Brandtberg et al. (USA, 2003) [3] Chen et al. (USA, 2006) [13] Koch et al. (Německo, 2006) [17] Gupta et al. (Německo, 2010) [11] Korpela et al. (Finsko, 2010) [18]
Kombinace snímků a laserového skenování	Leckie et al. (Kanada, 2003) [19] Breidenbach et al. (Norsko, 2010) [4]

3.5.1 Skenování versus snímkování

Skenování a snímkování jsou dvě odlišné techniky dálkového průzkumu, jak již bylo předestřeno v teoretickém úvodu (1.2). V prvním případě se jedná o záznam energie odraženého laserového pulzu (nejčastěji z blízké infračervené oblasti elektromagnetického spektra) a především o záznam doby letu, což vede k mračnu 3D bodů a geometricky přesné informaci o struktuře povrchu lesa. Ve druhém případě se jedná o záznam odražené sluneční energie v několika (mnoha) různých vlnových délkách, což vede k radiometricky přesné informaci o odrazových vlastnostech snímaných povrchů. První případ byl rozebírán doposud a není téměř co dodat. Jak ale v druhém případě můžeme dojít k segmentaci

jednotlivých stromů?

Pasivní metody DPZ nepostihují primárně strukturu. Odrazové vlastnosti koruny stromu ale nejsou homogenní. Vrchní část koruny je nejbližší ke zdroji i přijímači sluneční energie, proto zaznamenáme nejvíce odraženého záření. Směrem k okrajům koruny odražená energie klesá. Proto lze i v hyperspektrálním snímku lesa strukturu jednotlivých korun vidět. Charakter dat zůstává oproti laserovému skenování v několika bodech odlišný a s těmito odlišnostmi se musíme v průběhu segmentace vypořádat, což popisuje následující odstavec. V první řadě nemůžeme hodnoty v obraze přímo interpretovat jako výšku nad terénem. A druhým klíčovým rysem pasivního DPZ je vysoká závislost na geometrii snímání, tj. na vzájemné poloze zdroje záření (Slunce), snímaných objektů a snímacího zařízení. Důsledky geometrického uspořádání jsou stíny (nižší hodnoty) na straně korun odvrácené od Slunce a obecně měnící se jasová úroveň napříč odrazem v závislosti na úhlu snímání.

3.5.2 Postup segmentace pro hyperspektrální snímek

Segmentací hyperspektrálních snímků se mj. zabývala diplomová práce autora ([22]), proto zde vynecháme matematické odvození doporučených postupů, pouze vyjmenujeme úpravy postupu segmentace v případě, že se jedná o vstupní data obrazového charakteru.

- Ve fázi přípravy obrazu nelze pracovat s prahováním pomocí výšky, naopak se nabízí klasifikace plochy stromů od pozadí pomocí spektrálních charakteristik.
- Pro řešení problematiky zastíněných částí korun doporučuje autor v diplomové práci [22] i článku [23] adaptivní ekvalizaci histogramu.
- Zůstává v platnosti potřeba filtrace obrazu filtrem typu dolní propust pro odstranění nežádoucích vysokých prostorových frekvencí.
- Ve fázi detekce je plně použitelný princip lokálního maxima. Při adaptivní volbě velikosti okolí nelze pracovat s alometrickými rovnicemi, protože nemáme k dispozici výšku stromu. Nicméně techniky spádu a soběpodobnosti fungují.
- Ve fázi delineaace někteří autoři pracují se zaplavovacím algoritmem i minimovou sítí. My doporučujeme růstový algoritmus pro jeho korektnější přístup k vzájemné poloze jednotlivých korun. Navíc jako stopovací podmínka může sloužit vhodná metrika z prostorů spojitých funkcí určující vzájemnou shodu mezi spektrální křivkou startovního vrcholku koruny a připojovaného pixelu.

3.5.3 2D versus 3D

Závěrem této sekce o dalších datových zdrojích dodejme, že aktuální hlasy ve vědecké komunitě laserového skenování kladou otázku: „Proč každý algoritmus začíná rasterizací do 2D, když máme k dispozici 3D bodové mračno s vysokou hustotou?“ Jedná se o otázku oprávněnou, neboť interpolací rastrových modelů terénu a povrchu jistě část informace

ztrácíme. Na druhou stranu se tak dostáváme na probádanou půdu analýzy obrazu. Většinu algoritmů popsaných v této práci by bylo možné do 3D bez větších komplikací převést – lokální maxima lze hledat i mezi jednotlivými body mračna (fáze detekce), stejně tak růstový algoritmus může připojovat sousední body, nejen pixely (fáze delineaace). Bylo by to ovšem za cenu přebudování datové struktury aplikací a patrně též výpočetně náročnější. Zjišťování, zda bychom touto cestou dosáhli kvalitnějších výsledků, jde nad rámec této disertační práce. Problematiky 3D se pouze velmi letmo dotýkáme v odstavci 2.2.4.

3.6 Využití výsledků v praxi

V této kapitole učiníme malý krok mimo teoretický rámec dizertační práce a stručně představíme příklady použití výsledků segmentace v praxi. Budeme mimo jiné vycházet z článku [5].

Máme na mysli využití výsledků segmentace v datech dálkového průzkumu pro lesnickou praxi. Detekce jednotlivých stromů s následnou klasifikací druhů – dle bodového mračna, či lépe s kombinovaným využitím hyperspektrálních snímků – může sloužit k podrobnému mapování lesních porostů. V dalším uvedeme výsledky studie [5] zaměřené na mapování biomasy (~ zásoby dřeva) na základě různých datových zdrojů.


Cílem studie [5] bylo posouzení použitelnosti různých datových zdrojů k mapování biomasy. My se zde pochopitelně zaměříme na zpracování dat leteckého laserového skenování, neboť při něm byl použit algoritmus detekce dle kapitoly 2.2.1. Pod čarou bychom chtěli podotknout, že také zpracování hyperspektrálních dat s cílem mapování biomasy představuje zajímavou úlohu z oboru analýzy obrazu, která se nicméně již pohybuje mimo rámec této dizertační práce.

Zpracovávané území se vyskytuje v Moravskoslezských Beskydech v okolí ekosystémové stanice Bílý Kříž, jedná se o horský, převážně smrkový porost. Data leteckého laserového skenování byla pořízena v květnu 2013 skenerem Riegl LMS-Q680i (<http://www.riegl.com>), geometricky ošetřena pořizovatelem (<http://www.geodis.cz>) a následně předzpracována do podoby mapy výšek. Výsledky automatického zpracování dat dálkového průzkumu byly srovnány s výsledky terénních šetření provedených Ústavem pro hospodářskou úpravu lesů a Ústavem pro výzkum lesních ekosystémů (<http://www.uhul.cz>, <http://www.ifer.cz>).

Postup zpracování měl následující průběh:

1. Bodové mračno s vysokou hustotou (50 bodů v metru čtverečním).
2. Výpočet mapy výšek (viz odstavec 2.1).
3. Detekce pozice stromů (viz odstavec 2.2.1) a odečtení jejich výšky.
4. Odhad biomasy každého jednotlivého stromu.
5. Agregace výsledků na úroveň porostních celků.

K bodu 2 dodejme, že bylo použito prostorové rozlišení rastrové mapy výšek 40 centimetrů, voleno v souladu s prostorovým rozlišením hyperspektrálních dat používaných ve druhé, komplementární části studie. Mapa výšek byla zhlazena pomocí gaussovského filtru. Detekce v bodě 3 probíhala pomocí metody lokálního maxima s adaptivním okolem, jeho velikost se řídila alometrickou rovnicí pro smrk. Vyčtené výšky stromů byly porovnány s terénním šetřením s výsledkem, který uvádí graf na obrázku 3.29. Hodnoty z mapy výšek a údaje měřené přímo v lese mají lineární závislost s vysokým koeficientem determinace a sklonem přímky blízkým 1. Pozorujeme pouze systematický rozdíl minus 43 cm, který souvisí s charakterem dat leteckého laserového skenování. (Odražený pulz nepochází vždy od skutečně nejvyššího bodu koruny. K ponížení výšky vrcholku může také dojít vlivem interpolace do rastrové mapy výšek.)



Obrázek 3.29: Srovnání automaticky určených výšek stromů s realitou. Na vodorovné ose jsou výšky stromů změřené laserovým výškoměrem přímo v lese. Na svislé ose jsou výšky určené laserovým skenováním, vyčtené z mapy výšek v pozici jednotlivých detekovaných stromů. Odpovídající datové páry jsou proloženy regresní přímkou.

Biomasa jednoho stromu (bod 4) je odhadována pomocí tzv. alometrických rovnic. Jedná se o empirické závislosti mezi biomasou a snáze měřitelnými parametry stromů. Koeficienty rovnic se určují na základě destruktivních měření a považují se za platné


pro určitý druh v určitém území a věkovém rozmezí. V citované studii byly testovány a srovnány čtyři různé alometrické rovnice pro smrk převzaté z literatury:

1. $AB = 0.1197 (H \cdot DBH^2)^{0.8134}$ [32]
2. $AB = 0.1085 H^{2.5569}$ [27]
3. $AB = 0.1301 DBH^{2.2586}$ [27]
4. $AB = AB_1 + AB_2 + AB_3 + AB_4$ [30], kde
5. $AB_1(\text{jehlice}) = 1.0849 \cdot 1.0226 \cdot e^{1.9162 \log(DBH) - 3.1963}$
6. $AB_2(\text{větvě}) = 1.1332 \cdot 1.0103 \cdot e^{2.2552 \log(DBH) - 3.9620}$
7. $AB_3(\text{suché větve}) = 1.1146 \cdot 1.1107 \cdot e^{2.0482 \log(DBH) - 3.0906}$
8. $AB_4(\text{kmen}) = 1.0142 \cdot 1.0238 \cdot e^{2.5060 \log(DBH) - 2.5060}$


V rovnicích figurují 3 veličiny: AB je odhadovaná nadzemní biomasa v kilogramech, kterou lze dle 4. rovnice členit na dílčí složky – biomasu jehlic, větví živých a suchých a biomasu kmene; H je výška stromu v metrech; DBH je tzv. výčetní tloušťka, neboli průměr kmene ve výšce 1,3 m, zaznamenávaný v centimetrech. Zkratky jsou z anglických termínů *aboveground biomass*, *height* a *diameter at breast height*.

Z dat leteckého laserového skenování jsme schopni určovat výšku jednotlivých stromů. Nicméně přímé odečítání průměru kmene by bylo vrcholně nespolehlivé, neboť velké většina odrazů laserového paprsku pochází od nejvyšších pater koruny, ne od kmene. Proto také pro převod mezi výškou a průměrem kmene se používá alometrická rovnice, parametrizovaná podle měření v terénu. Mezi zmíněnými veličinami se předpokládá exponenciální závislost. V citované studii byla použita rovnice $DBH[\text{cm}] = 0.98 H^{1.08}[\text{m}]$. Postupným dosazením výšky do jednotlivých rovnic dostáváme odhad biomasy každého detekovaného stromu. Výsledným produktem této fáze je mapa biomasy na úrovni jednotlivých stromů. Její výřez je ilustrován na obrázku 3.30. Barevné kroužky představují detekované pozice jednotlivých stromů, množství biomasy je znázorněno na barevné škále od několika desítek kilogramů až po několik tun u nejstarších stromů.

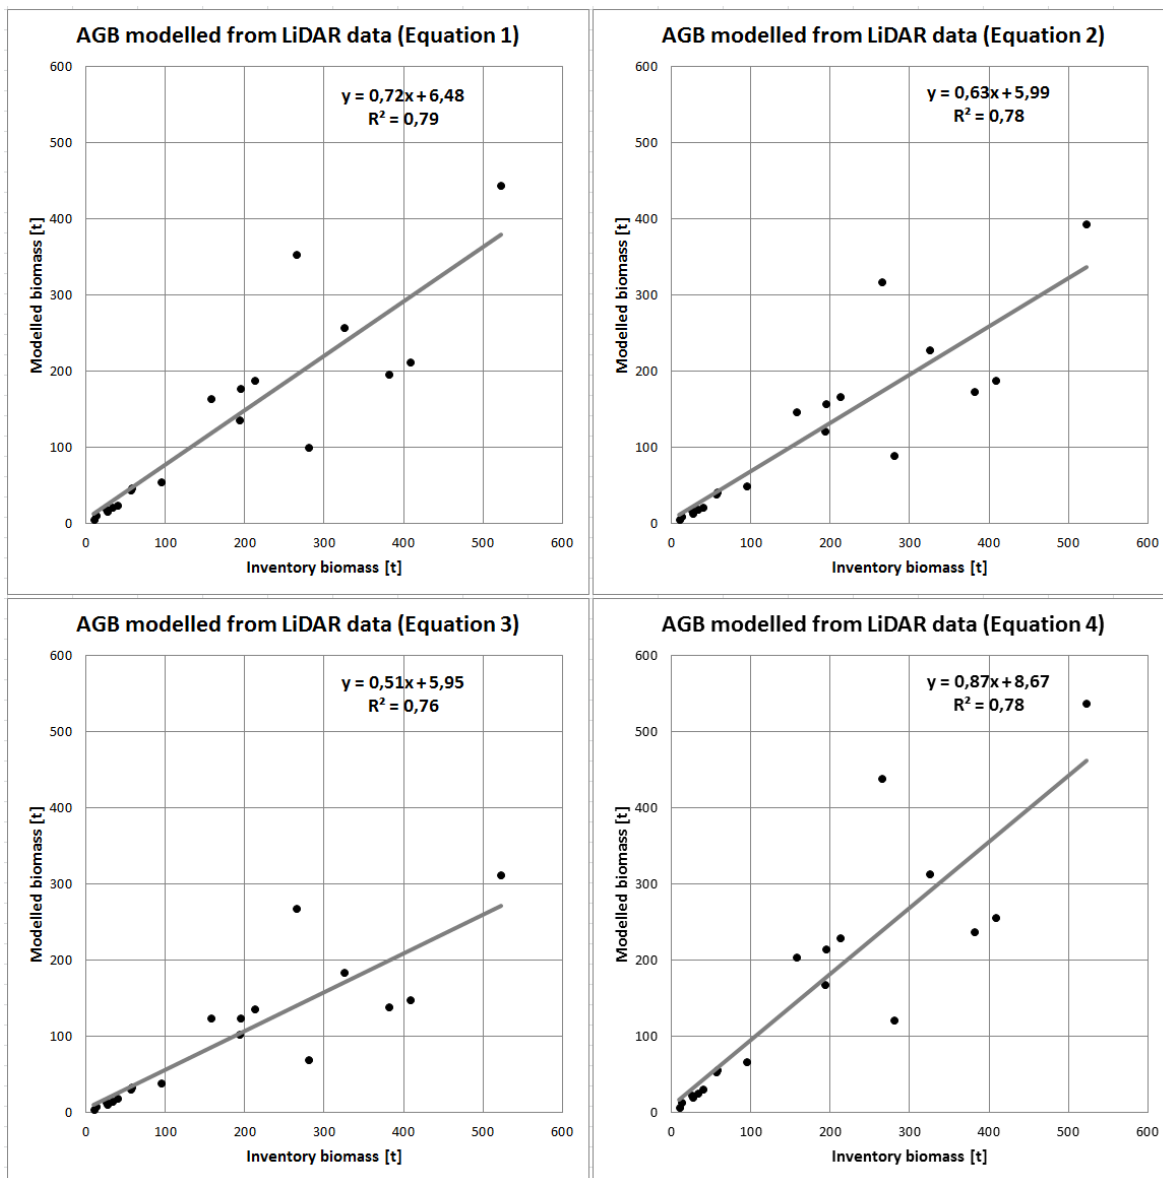
Agregace na úroveň porostních celků jde proti hlavnímu tématu tohoto textu, jímž je segmentace. Nicméně v citované studii bylo možné posoudit odhad biomasy pouze na úrovni porostních celků, které jsou součástí tzv. lesních plánů včetně hodnoty celkové zásoby dřeva zaznamenané při lesní inventarizaci. Jak dopadlo automatické zpracování dat leteckého laserového skenování v kontextu odhadů biomasy samotnými lesníky uvádí graf na obrázku 3.31. Lineární regresní vztah mezi modelovanou a inventární zásobou existuje, nicméně jeho spolehlivost se pohybuje mírně pod 80 procenty u všech testovaných alometrických rovnic. Přitom variabilita u větších porostních celků je výrazná. Agregování tak zjevně nezakrývá nehomogenitu uvnitř porostních celků dostatečně přesvědčivě. Jako nejkvalitnější byl vyhodnocen model čtvrtý vzhledem k nejvyššímu sklonu regresní přímky.



Aboveground biomass per individual tree [kg]



Obrázek 3.30: Mapa biomasy jednotlivých detekovaných stromů.



Obrázek 3.31: Srovnání modelované a tabelované zásoby dřeva pro různé porostní celky v analyzovaném území. Jednotlivé grafy posuzují vlastnosti lineárního modelu odvozeného ze 4 různých alometrických rovnic.

3.7 Počítačová implementace algoritmů

Hlavním cílem této dizertační práce je (teoretický) popis a rozbor segmentačních algoritmů pro konkrétní úlohu z dálkového průzkumu Země. Nicméně zpracování takového úkolu zahrnovalo také nemalé množství programování. V této kapitole se stručně vyjádříme právě k počítačové implementaci algoritmů.

3.7.1 Programovací prostředí Lazarus

Jednotlivé počítačové aplikace jsou zpracovány v prostředí *Lazarus*, ve verzi 0.9.30 pro Windows. Jedná se o volně dostupné vývojové prostředí nad jazykem *Free Pascal*. Volba nebyla motivována specifickými možnostmi práce s obrazovými daty, ani obecnou efektivitou algoritmů, která je skoro jistě vyšší u jiných jazyků a prostředí. Jednoduše rozhodla dostupnost výše uvedených programů na pracovišti autora a jeho dřívější zkušenosti s jazykem *Pascal* a prostředím *Delphi*, o jejichž opensource verzi se jedná. Při programování tak mohlo být navázáno na diplomovou práci [22]. Nad rámec běžných programátorských technik (podmínky, cykly, procedury) a datových struktur (pole, záznamy) vyčnívá pouze práce s obrazovými daty – knihovny *IntfGraphics* a *fpImage*. Také jsme využili možnost zkompilovat stejný zdrojový kód pro platformu Windows i Linux.

3.7.2 Programy, které jsou součástí práce

Součástí práce, na přiloženém CD, jsou tři počítačové programy, které umožňují vyzkoušet výše popsané algoritmy na cvičných datech, případně na datech vlastních. Do podoby finální aplikace včetně vstřícného uživatelského rozhraní jsem zpracoval tři dílčí problematiky, jiné menší programky sloužily pouze k testování a srovnávání jednotlivých algoritmů. Na CD naleznete:

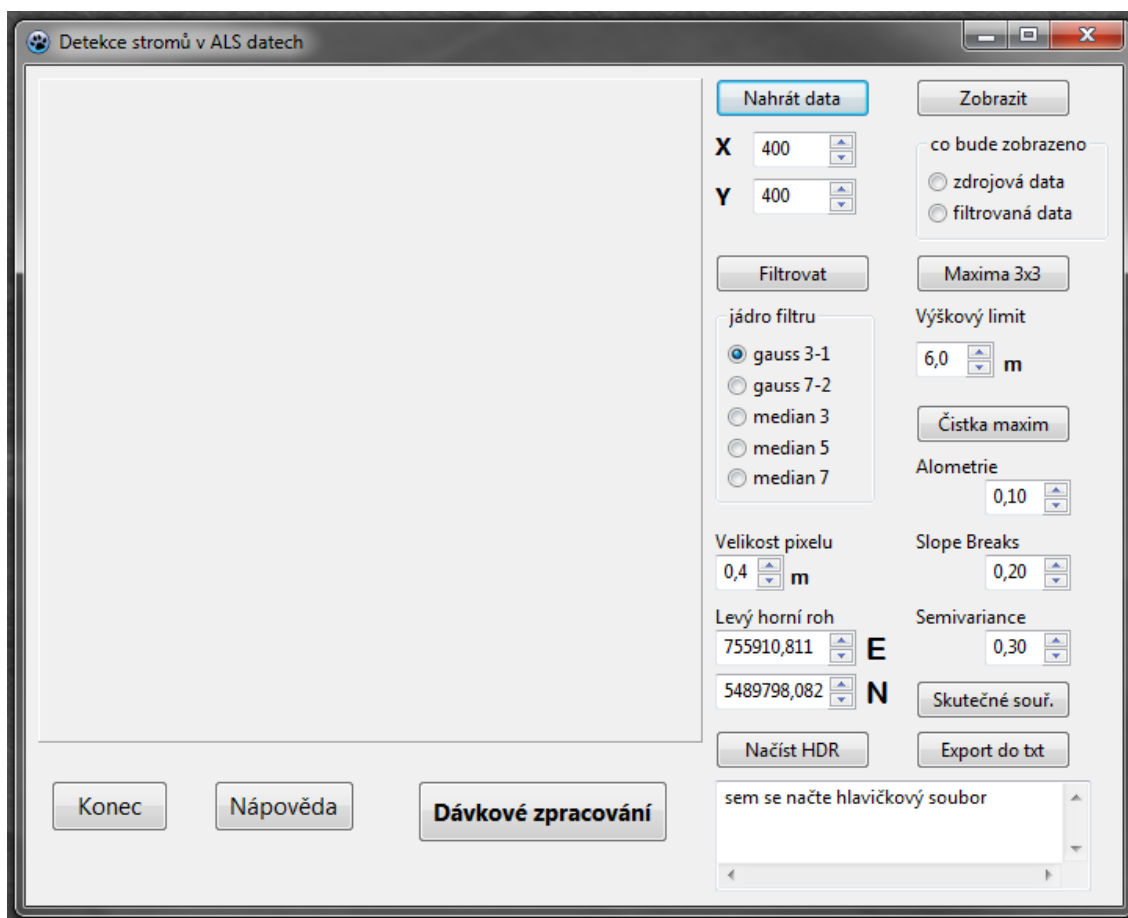
1. Aplikaci *Detekce stromů v ALS datech*.
2. Aplikaci *Delineace korun pomocí zaplavovacího algoritmu*.
3. Aplikaci *Delineace korun pomocí růstového algoritmu*.
4. Vzorová data z lokality Bílý Kříž.

Detekce stromů v ALS datech

V dalším popíšeme uživatelské rozhraní (obrázek 3.32) a použití této aplikace, poté se stručně vyjádříme ke klíčovým programátorským obrátům a strukturám.

V levé části okna programu je plocha pro zobrazení mezivýsledků. Tlačítko „Konec“ ukončí aplikaci. Tlačítko „Nápověda“ spouští textový popis aplikace a jejího nastavení, shodný s těmito odstavci.

Tlačítko „Nahrát data“ spouští dialog pro výběr datového souboru s rastrem výšek. Napřed je nutné v polích pod tlačítkem nastavit rozměry obrazu. Pokud čísla neznáme,



Obrázek 3.32: Uživatelské rozhraní aplikace *Detekce stromů v ALS datech*.

pravděpodobně je vyčteme z hlavičkového souboru. Zda byla data korektně nahrána, můžeme ověřit jejich zobrazením pomocí tlačítka „Zobrazit“ se zaškrtnutou volbou „zdrojová data“.

Tlačítko „Filtrovat“ provede low-pass vyhlazení vstupního obrazu s cílem odstranění šumu a nežádoucích podrobností. Na výběr je 5 variant jádra filtru: gaussovské jádro 3x3 se $\sigma = 1$ a 7x7 se $\sigma = 2$, dále mediánový filtr 3x3, 5x5 a 7x7. Výsledek filtrování lze zkontrolovat po zobrazení se zaškrtnutou volbou „filtrovaná data“. Tlačítko „Filtrovat“ také promazává vnitřní struktury včetně seznamu maxim. Takže jím lze zahájit novou detekci s novými parametry.

Tlačítko „Maxima 3x3“ vyhledá potenciální pozice stromů jako lokální maxima vyšší než okolí 3x3. Tato maxima jsou oříznuta minimální výškou zadanou pod tlačítkem. Tlačítko „Čistka maxim“ vybírá z maxim blízko u sebe to vyšší. Očekávaný průměr koruny, který určí, co je blízko, počítáme jako vážený průměr tří odhadů, jejichž váhy je možné nastavit.

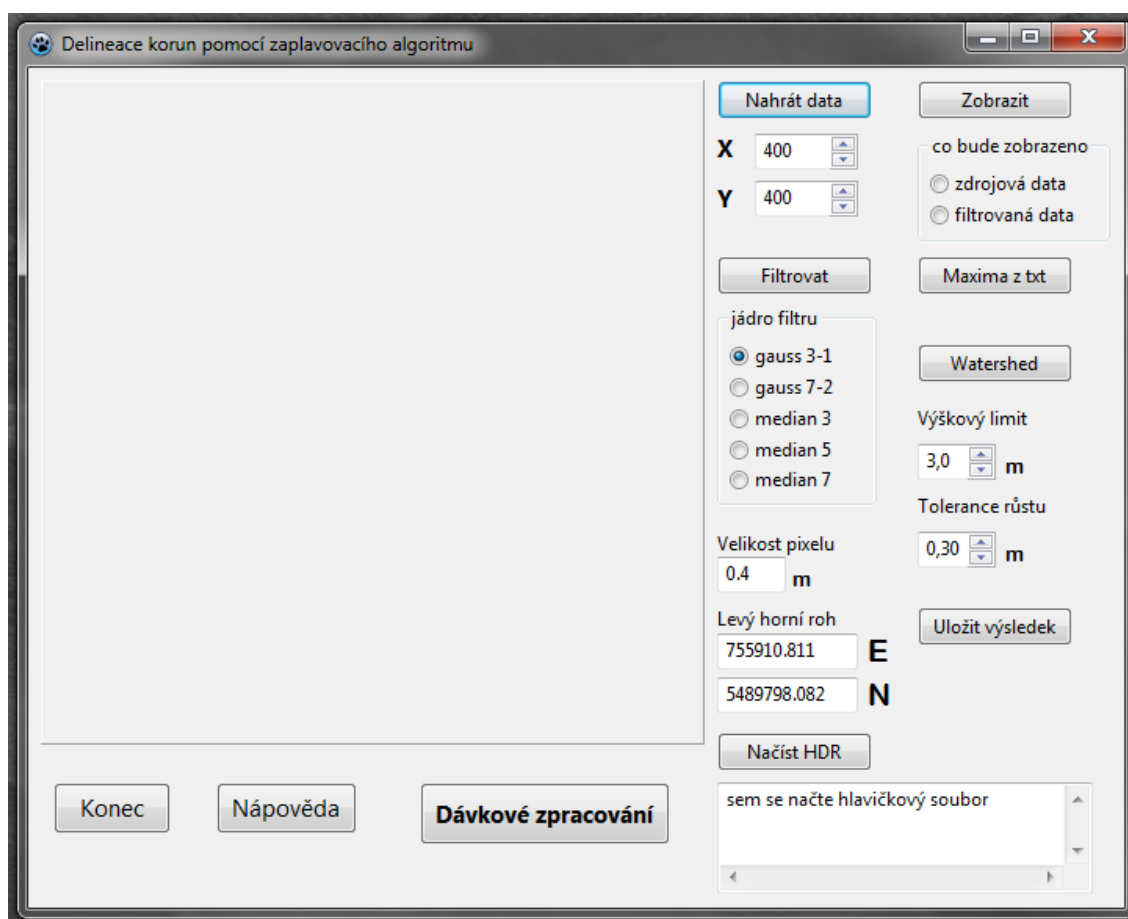
Před exportem pozice detekovaných stromů do textového souboru je nutné vypočítat jejich skutečné souřadnice v globálním souřadném systému (ne pouze v obraze). K tomu

je třeba nastavit souřadnice levého horního rohu obrazu. Pokud čísla neznáme, pravděpodobně je můžeme vyčíst z hlavičkového souboru.

Tlačítko „Dávkové zpracování“ vede k otevření řídicího textového souboru, který obsahuje parametry pro analýzu více souborů, případně analýzu citlivosti postupnou změnou jednotlivých prahů a vah. (Příklad je také na CD.)

Všechny technické postupy jsou popsány v odstavcích 2.2.1 a 3.2, jejich implementace je velmi přímočará. Jediné téma mimo rámec teoretického odvození je práce s okrajem obrazu. Pokud je nutno, používáme přístup pracující s rozšiřování obrazu pomocí zrcadlení podle okraje. Obecně je třeba mít na paměti, že výsledky detekce (i delineace) jsou plně relevantní především ve středu zpracovávaného obrazu, v adekvátní vzdálenosti od okrajů.

Delineace korun pomocí zaplavovacího algoritmu



Obrázek 3.33: Uživatelské rozhraní aplikace *Delineace korun pomocí zaplavovacího algoritmu*.

V dalším popíšeme uživatelské rozhraní (obrázek 3.33) a použití této aplikace, poté se stručně vyjádříme ke klíčovým programátorským obrátům a strukturám.

Rozložení uživatelského okna je shodné s předchozím, stejně jako tlačítka „Konec“, „Nápověda“, „Nahrát data“, „Filtrovat“ a „Zobrazit“.

Lokální maxima, která jsou startovními body do procesu zaplavování, je třeba načíst z textového souboru, který je výstupem detekční aplikace. (Tento modulární přístup byl zvolen z důvodu přehlednosti jednotlivých aplikací.)

Tlačítko „Watershed“ spouští zaplavovací algoritmus, který má dva základní parametry. Hodnota „Výškový limit“ stanovuje minimální výšku okrajů korun. Hodnota „Tolerance růstu“ stanovuje maximální nárůst výšky v daném kroku, který ještě nebrání rozšíření koruny tímto směrem. (Viz odstavec 3.3.1.)

Pro export výsledků do georeferencovaného souboru je třeba zadat velikosti pixelu a souřadnice levého horního rohu vstupního obrazu. Pokud čísla neznáme, pravděpodobně je můžeme vyčíst z hlavičkového souboru.

Tlačítko „Dávkové zpracování“ opět vede k otevření řídicího textového souboru, který obsahuje parametry pro analýzu více souborů, případně analýzu citlivosti postupnou změnou jednotlivých prahů a vah. (Viz příklad na CD.)

Také zde lze říci, že implementace postupu popsaného v odstavci 3.3.1 je doslovná. Zajímavým tématem v tomto i příštím odstavci je export výsledné segmentace. Používáme formát analogický vstupním datům, včetně hlavičkového souboru s popisnými údaji a georeferencí, neboť předpokládáme následnou analýzu výsledků v GIS prostředí, kde je mj. možné převést rastrová data na vektorové hranice korun, jak je prezentujeme na některých obrázcích v této práci (například 3.14).

Delineace korun pomocí růstového algoritmu

V dalším popíšeme uživatelské rozhraní (obrázek 3.34) a použití této aplikace, poté se stručně vyjádříme ke klíčovým programátorským obrátům a strukturám.

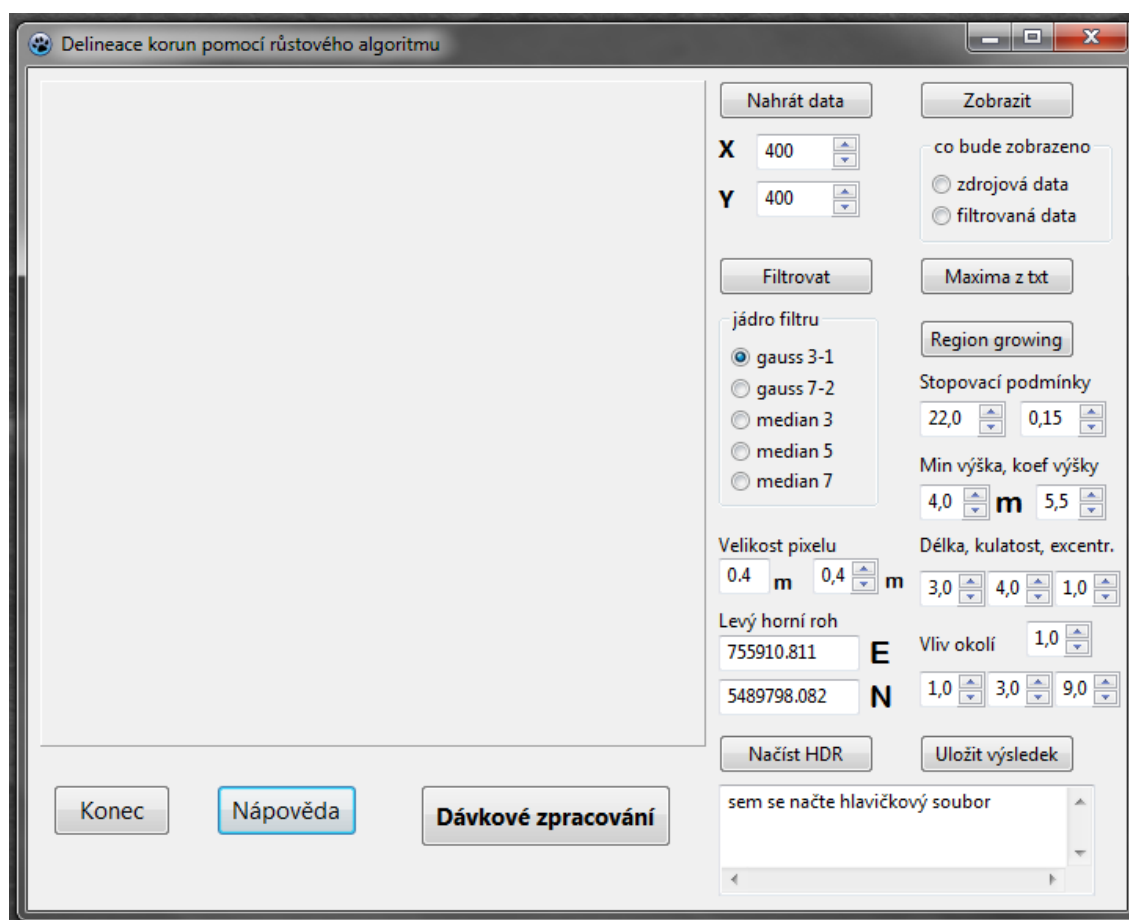
Rozložení uživatelského okna je shodné s předchozími, stejně jako tlačítka „Konec“, „Nápověda“, „Nahrát data“, „Filtrovat“ a „Zobrazit“.

Lokální maxima, která jsou startovními body do procesu narůstání, je třeba načíst z textového souboru, který je výstupem detekční aplikace. (Tento modulární přístup byl zvolen z důvodu přehlednosti jednotlivých aplikací.)

Tlačítko „Region growing“ spouští růstový algoritmus, jehož kompletní nastavení zahrnuje 11 parametrů. Růst korun je korigován pomocí umělé veličiny, energie. V každém kroku je zvolen růst, který minimalizuje tuto energii (viz odstavce 2.3.3 a 3.3.3).

K zastavení růstu slouží dvě stopovací podmínky. První je maximální limit energie (defaultní hodnota 22) – přesněji řečeno je maximální energie stromu defaultně rovna 22 krát výška startovního maxima. Druhá je maximální relativní nárůst energie (defaultně 0,15 – tedy 15 procent).

Samotná energetická bilance koruny je váženým součtem tří složek, vlivu výšky, vlivu tvaru a vlivu okolí. Je možné nastavit minimální výšku okrajů koruny (defaultně 4 m) a váhu výškové složky jako takové (defaultně 5,5). Tvarové veličiny jsou délka hranice, kulatost a excentricita koruny. Je možné nastavit jejich váhy (defaultně 3-4-1). Je možné nastavit váhu vlivu okolních korun (defaultně 1). Do vlivu okolí započítáváme pixely ve vzdálenosti 3, 2 a 1 od zpracovávaného, jejich vliv nastavujeme (defaultně 1-3-9).



Obrázek 3.34: Uživatelské rozhraní aplikace *Delineace korun pomocí růstového algoritmu*.

Pro export výsledků do georeferencovaného souboru je opět třeba zadat velikosti pixelu a souřadnice levého horního rohu vstupního obrazu. Pokud čísla neznáme, pravděpodobně je můžeme vyčíst z hlavičkového souboru.

Tlačítko „Dávkové zpracování“ opět vede k otevření řídicího textového souboru, který obsahuje parametry pro analýzu více souborů, případně analýzu citlivosti postupnou změnou jednotlivých prahů a vah. (Viz příklad na CD.)

Sestavení energetické bilance je popsáno odstavci v 3.3.3, stejně jako kritéria pro volbu pořadí stromů v iterativním procesu narůstání. Pro každý strom používáme samostatnou záznamovou strukturu, která zahrnuje jeho souřadnice, výškové a tvarové parametry, z nich průběžně aktualizuje hodnotu energie. Všechny stromy držíme v jednom statickém seznamu, přičemž dynamicky měníme dvě řídicí pole – seznam aktivních stromů a seznam hotových stromů. Na počátku jsou pochopitelně všechny stromy aktivní, na konci naopak všechny hotové.

3.7.3 Výpočetní náročnost algoritmů

V tomto odstavci pojednáváme o výpočetní náročnosti jednotlivých částí segmentačního procesu, ne tak dle informatické teorie, spíše prakticky.

Zpracování rozsáhlých dat dálkového průzkumu je obecně záležitost výpočetně náročná. Při testování segmentačních algoritmů jsme tuto záležitost obešli výběrem reprezentativních výřezů. Jejich zpracování nevyžadovalo neadekvátní čas a přitom stále poskytovalo dostatečnou představu o účinnosti algoritmů na vybraných typech porostu.

Práci s výřezy, též říkáme s dlaždicemi, doporučujeme i při zpracování reálné úlohy vyššího prostorového rozsahu. K tomu poukazujeme na důležitý rozdíl mezi dvěma fázemi segmentačního algoritmu. Pro detekci vždy posuzujeme lokálně určité okolí pixelu, vliv širšího okolí a vliv dlaždicování je tedy zanedbatelný nebo žádný. Naopak při delineaci hraje v zapojených porostech klíčovou roli vzájemná interakce sousedících korun, na utváření segmentu jedné koruny tak může mít vliv poměrně široké okolí. Běžným řešením i v jiných úlohách dálkového průzkumu je sestavování dlaždic s dostatečným podélným i příčným překryvem. V našem případě to bude i několik metrů, podle typické velikosti korun. Navíc pak musíme rozhodnout o finální úpravě segmentace v překryvných oblastech.

Nejen z výše uvedeného důvodu lze říci, že výpočetní náročnost detekce je řádově nižší než náročnost delineace.

Shrnutí

Tato dizertační práce poskytuje ucelený přehled problematiky segmentace jednotlivých stromů v datech dálkového průzkumu.

Vycházíme z cca 20 let celosvětového výzkumu v této oblasti, přičemž sledujeme především moderní trendy, mezi něž patří přechod od obrazových dat k laserovému skenování a stálé hardwarové pokroky směřující k vyššímu prostorovému rozlišení. V souladu s ostatními autory rozdělujeme proces segmentace na 1) přípravu dat, 2) detekci pozice stromů a 3) delineační plochy korun.

Příprava dat

V bodě přípravy dat (kapitola 2.1) se zaměřujeme na data laserového skenování. Bodové mračno je třeba klasifikovat na body terénu a povrchu, algoritmy se liší podle charakteru porostu (především jeho zapojení), členitosti terénu a přítomnosti umělých struktur (jako jsou budovy). Následně sestavujeme rastrový model povrchu a terénu, jejich odečtením vzniká mapa výšek. Důvodem je mimo jiné úspora datových a výpočetních nároků, proto zatím nebyly algoritmy zpracovány rovnou ve 3D. Klíčovým parametrem rastrových modelů je prostorové rozlišení, jako osvědčené pravidlo doporučujeme alespoň 4 body původního mračna na jeden pixel mapy výšek. Dále doporučujeme speciální rasterizační techniku zmíněnou v odstavci 2.1.2, kdy cíleně omezujeme nespojitosti v modelu povrchu. Dalším poselstvím nesoucím se celou prací je kombinace datových zdrojů, zde například využití obrazových dat pro klasifikaci typů pokryvu a nahlédnutí do porostních map k zjištění druhového složení a základních charakteristik stromů ve zpracovávaném území.

Případné zájemce o problematiku hyperspektrálních obrazových dat odkazujeme na odstavce 3.5, z externích zdrojů na diplomovou práci [22] a článek [23].

Detekce pozice stromů

V bodě detekce pozice stromů (kapitola 2.2) se zaměřujeme na metodu lokálního maxima, přičemž okrajově zmiňujeme také možnost prahování podle výšky, korelační analýzu a 3D segmentaci od kmene vzhůru. Při hledání pozice stromu jako lokálního maxima výšky je možné využít široké spektrum adaptivních technik obrazové analýzy, které zvyšují robustnost v datech s vysokou variabilitou (například ve věkovém či druhovém složení). Při pečlivé parametrizaci lze v konkrétním území dosáhnout kvality detekce přes 95 procent, při plošnějším použití okolo 90 procent. Výsledek detekce pozice stromů je klíčový sám o sobě, i pro pokračování segmentace. Delineační postupy z pozice stromů vycházejí

a jejich chybovost tak není poplatná kvalitě algoritmu jako takového, ale též navazuje na úspěšnost předcházející detekce.

Už výsledek samotné detekce může sloužit jako podklad ke kvantitativní analýze lesních porostů, odkazujeme na odstavce 3.6 a studii [5].

Delineace plochy korun

V bodě delineace plochy korun představujeme a rozebíráme tři různé algoritmy. Metoda kombinující růstový algoritmus s aktivní konturou na hranici koruny byla vyvinuta v rámci této práce a poprvé představena v článku [25]. Mezi její přednosti patří důraz na přirozený tvar korunových segmentů a korektní zpracování vzájemné hranice sousedících stromů. Široká parametrizace umožňuje adaptivní přizpůsobení různým typům porostu včetně smíšených. Během testování bylo dosaženo přesnosti delineace okolo 80 procent.

Také u zbývajících dvou metod – zaplavování a minimové sítě – je v kapitole 2.3 vyložena jejich modifikace pro data laserového skenování s vysokým prostorovým rozlišením a v odstavci 3.3.1 a 3.3.2 rozebrána konkrétní parametrizace.

Přínos a budoucí rozvoj

Obecný přínos práce souvisí s tím, že dané téma je komplexně rozebráno z pohledu současných datových zdrojů a v kontextu typických lesů České republiky, což vhodně shrnuje a rozšiřuje dostupnou zahraniční literaturu. Ambici na širší teoretický přínos své oblasti mají především detekce lokálních maxim adaptivně parametrizovaná podle lokálních vlastností obrazu a druhu dřevin a růstový algoritmus využívající aktivní konturu k aproximaci hranic korun.

Budoucí využití zde představených metod a jejich další rozvoj je zaručen vzhledem k zaměstnání autora v pracovní skupině Dálkového průzkumu Země v Centru výzkumu globální změny AV ČR, kde lesní ekosystém patří mezi klíčová území zájmu a stálý rozvoj techniky dálkového průzkumu směřuje právě od úrovně porostů k jednotlivým stromům.

Jeden z možných směrů dalšího zkoumání vidíme v již zmíněném důsledném převodu algoritmů do trojrozměrné reality bodového mračna, kdy by segmentace na jednotlivé stromy ve výsledku vedla ke klasifikaci bodů mračna podle jejich příslušnosti k jednotlivým stromům a pozadí. Vývoj algoritmů v této oblasti představuje výzvu z hlediska práce s velkými daty a výpočetní efektivity.

Literatura

- [1] Anděl, J.: *Matematická statistika*. Praha: SNTL, 1985.
- [2] Axelsson, P. 2000. *DEM generation from laser scanner data using adaptive TIN models*. International Archives of Photogrammetry and Remote Sensing 33: 110–117.
- [3] Brandtberg, T., Warner, T.A., Landenberg, R.E. and McGraw, J.B. 2003. *Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density lidar data from the eastern deciduous forest in North America*. Remote Sensing of Environment 85: 290–303.
- [4] Breidenbach, J., Naesset, E., Lien, V., Gobakken, T. a Solberg, S. 2010. *Prediction of species specific forest inventory attributes using a nonparametric semi-individual tree crown approach based on fused airborne laser scanning and multispectral data*. Remote Sensing of Environment 114: 911–924.
- [5] Brovkina, O., Novotny, J., Zemek, F., Russ, R. a Cienciala, E. 2014. *Mapping above-ground biomass using airborne data: a case study in the Beskydy Mountains temperate forest*. Manuskript, submitted in International Journal of Remote Sensing.
- [6] Bunting, P. and Lucas, R. 2006. *The delineation of tree crowns in australian mixed species forests using hyperspectral compact airborne spectrographic imager (CASI) data*. Remote Sensing of Environment 101: 230–248.
- [7] Čížek, V.: *Diskretní Fourierova transformace a její použití*. Praha: SNTL - Nakladatelství technické literatury, 1981.
- [8] Culvenor, D.S. 2002. *TIDA: an algorithm for the delineation of tree crowns in high spatial resolution remotely sensed imagery*. Computers and Geosciences 28: 33–44.
- [9] Erikson, M. 2003. *Segmentation of individual tree crowns in colour aerial photographs using region growing supported by fuzzy rules*. Canadian Journal of Forest Research 33: 1557–1563.
- [10] Gougeon, F.A. 1995. *A crown-following approach to the automatic delineation of individual tree crowns in high spatial resolution digital images*. Canadian Journal of Remote Sensing 21: 274–284.

- [11] Gupta, S., Weinacker, H., Koch, B. 2010. *Comparative analysis of clustering-based approaches for 3-d single tree detection using airborne fullwave lidar data*. Remote Sensing 2: 968–989.
- [12] Hirschmugl, M., Ofner, M., Raggam, J., Schardt, M. 2007. *Single tree detection in very high resolution remote sensing data*. Remote Sensing of Environment 110: 533–544.
- [13] Chen, Q., Baldocchi, D., Gong, P., Kelly, M. 2006. *Isolating individual trees in a savanna woodland using small footprint lidar data*. Photogrammetric Engineering and Remote Sensing 72: 923–932.
- [14] Chilés, J.-P. a Delfiner, P.: *Geostatistics – Modeling Spatial Uncertainty*. New York: John Wiley and sons, 1999.
- [15] Jarník, V.: *Diferenciální počet*. Praha: Nakladatelství ČSAV, 1953.
- [16] Khosravipour, A., Skidmore, A.K., Isenburg, M., Wang, T.J., Hussin, Y.A. 2014. *Generating pit-free Canopy Height Models from Airborne LiDAR*. Photogrammetric Engineering and Remote Sensing 80, 863–872.
- [17] Koch, B., Heyder, U., Weinacker, H. 2006. *Detection of individual tree crowns in airborne lidar data*. Photogrammetric Engineering and Remote Sensing 72: 357–363.
- [18] Korpela, I., Orka, H.O., Maltamo, M., Tokola, T., Hyyppä, J. 2010. *Tree species classification using airborne LiDAR—effects of stand and tree parameters, downsizing of training set, intensity normalization, and sensor type*. Silva Fennica 44: 319–339.
- [19] Leckie, D., Gougeon, F., Hill, D., Quinn, R., Armstrong, L., Shreenan, R. 2003. *Combined highdensity lidar and multispectral imagery for individual tree crown analysis*. Canadian Journal of Remote Sensing 29: 633–649.
- [20] Likeš, J. a Machek, J.: *Matematická statistika*. Praha: SNTL, 1983.
- [21] Martišek, D.: *Matematické principy grafických systémů*. Brno: Litera, 2002.
- [22] Novotný, J. 2009. *Multispektrální analýza obrazových dat*. Brno: Vysoké učení technické v Brně, Fakulta strojního inženýrství. Diplomová práce, 49 s. Vedoucí doc. PaedDr. Dalibor Martišek, Ph.D.
- [23] Novotný, J., Hanuš, J., Lukeš, P., Kaplan, V. 2011. *Individual tree crowns delineation using local maxima approach and seeded region growing technique*. Proceedings of Symposium GIS Ostrava 2011, 27–39.
- [24] Novotný, J. a Zemek, F. 2013. *Segmentation of tree crowns from airborne hyperspectral and lidar data: method comparison*. Global Change and Resilience: From Impacts To Responses (Proceedings of the 3rd annual Global Change and Resilience Conference), Brno 2013, ISBN 978-80-904351-8-6, 188–191.

-
- [25] Novotný, J. 2014. *Tree crown delineation using region growing and active contour: approach introduction*. Proceedings of 20th International Conference on Soft Computing MENDEL 2014: 213-216.
- [26] Pitkänen, J. 2001. *Individual tree detection in digital aerial images by combining locally adaptive binarization and local maxima methods*. Canadian Journal of forest research 31: 832–844.
- [27] Pokorný, R., Tomaskova, I. 2007 *Allometric relationships for surface area and dry mass of young Norway spruce aboveground organs*. Journal of Forest Science. 12: 548-554.
- [28] Pouliot, D.A., King, D.J. and Pitt, D.G. 2005. *Development and evaluation of an automated tree detection delineation algorithm for monitoring regenerating coniferous forests*. Canadian Journal of Forest Research 35: 2332–2345.
- [29] Vosselman, G. 2000. *Slope based filtering of laser altimetry data*. International Archives of Photogrammetry and Remote Sensing 33: 935–942.
- [30] Wirth, C., Schumacher, J., Schulze, E.-D. 2004. *Generic biomass functions for Norway spruce in Central Europe – a meta-analysis approach toward prediction and uncertainty estimation*. Tree Physiology 24: 121-139.
- [31] Zemek F. a kol.: *Letecký dálkový průzkum Země*. Brno: Centrum výzkumu globální změny AV ČR, 2014.
- [32] Zianis, D., Muukkonen, P., Makipaa, R., Mencuccini M. 2005. *Biomass and stem volume equations for tree species in Europe*. Silva Fennica. Monographs 4. The Finnish Society of Forest Science and The Finnish Forest Research Institute.
- [33] Žára, J. a kol.: *Počítačová grafika–principy a algoritmy*. Praha: Computer Press, 2004.

Přílohy

Přílohou práce – na CD – jsou tři spustitelné aplikace popsané v kapitole 3.7 a cvičná data. Programy mají podobu spustitelných souborů pro platformu windows. Cvičná data jsou mapa výšek smrkového porostu vytvořená dle odstavce 2.1. Dále lze studovat ukázky dávkových souborů pro jednotlivé aplikace a příklad výsledků detekce a delineaace.

Textovou přílohu tvoří diplomová práce a články autora týkající se problematiky segmentace korun. Doplňujeme též elektronickou verzi této dizertační práce.

1. Spustitelný soubor `./Programy/Prg_detekce.exe`
2. Spustitelný soubor `./Programy/Prg_zaplavovani.exe`
3. Spustitelný soubor `./Programy/Prg_rustovy.exe`
4. Vzorová data `./Data/vstup/BK_cut_A.dat`
5. Hlavičkový soubor vzorových dat `./Data/vstup/BK_cut_A.hdr`
6. Ilustrativní barevný snímek vzorové oblasti `./Data/vstup/BK_cut_A_rgb.tif`
7. Příklad výsledků detekce a delineaace ve složce `./Data/vystup`
8. Příklad řídicích souborů dávkového zpracování ve složce `./Data/davkove`
9. Diplomová práce `./Texty/Novotny_2009.pdf`
10. Článek `./Texty/Novotny_2011.pdf`
11. Článek `./Texty/Novotny_2013.pdf`
12. Článek `./Texty/Novotny_2014.pdf`
13. Dizertační práce `./Texty/Novotny_2015.pdf`