## SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE Stavebná fakulta

Evidenčné číslo: SvF-5343-87825

## Nové metódy automatickej segmentácie satelitných snímok

Diplomová práca

Študijný program: matematicko-počítačové modelovanie Študijný odbor: matematika Školiace pracovisko: Katedra matematiky a deskriptívnej geometrie Vedúci záverečnej práce: Ing. Michal Kollár, PhD.

Bratislava 2021

Bc. Martin Štefanec

Slovenská technická univerzita v Bratislave Katedra matematiky a deskriptívnej geometrie Stavebná fakulta Akademický rok: 2020/2021 Evidenčné číslo: SvF-5343-87825

## ZADANIE DIPLOMOVEJ PRÁCE

Študent:	Bc. Martin Štefanec
ID študenta:	87825
Študijný program:	matematicko-počítačové modelovanie
Študijný odbor:	matematika
Vedúci práce:	Ing. Michal Kollár, PhD.

### Názov práce: Nové metódy automatickej segmentácie satelitných snímok

Jazyk, v ktorom sa práca vypracuje: slovenský jazyk

Špecifikácia zadania:

Diplomová práca sa bude primárne zaoberať návrhom novej funkcie homogenity v modeli automatickej segmentácie. Budú skúmané alternatívne možnosti definície tejto funkcie, ktoré budú založené na prahovacích metódach a ich modifikáciách. Ich vplyv bude porovnávaný na výsledkoch automatickej segmentácie chránených území európskeho významu (Natura 2000) zo satelitných snímkov družice Sentinel-2. Implementácia metód bude v jazyku C++ a bude použitá v softvéri NaturaSat.

Zoznam odbornej literatúry:

1. Mikula, K. – Urbán, J. – Kollár, M. – Ambroz, M. – Jarolímek, I. – Šibík, J. – Šibíková, M. An automated segmentation of NATURA 2000 habitats from Sentinel-2 optical data. *Discrete and Continuous Dynamical Systems – Series S*, 14. s. 1017–1032.

Riešenie zadania práce od:	01. 10. 2020
Dátum odovzdania práce:	13. 05. 2021

Bc. Martin Štefanec študent  $\operatorname{SvF}$  STUBA

### Čestné vyhlásenie

Prehlasujem, že som diplomovú prácu vypracoval samostatne s použitím citovanej literatúry a s odbornou pomocou vedúceho práce.

V Bratislave, 13.5.2021

.....

Meno Priezvisko

SvF STUBA

### Poďakovanie

Chcel by som poďakovať Ing. Michalovi Kollárovi, PhD. za jeho trpezlivosť, cenné rady a odborné konzultácie počas vypracovania tejto práce.

#### Abstrakt

Diplomová práca sa zaoberá návrhom a implementáciou modifikácií pre metódu automatickej segmentácie zo satelitných snímok. Teoretická časť je venovaná modelu automatickej segmentácie, ktorý je založený na vývoji uzavretej Lagrangeovskej krivky. Súčasťou modelu automatickej segmentácie je funkcia homogenity, ktorá určuje oblasť expanzie pre počiatočnú krivku. Návrh alternatívnej definície funkcie homogenity predstavuje hlavný cieľ práce. Praktická časť sa zaoberá implementáciou navrhnutých modifikácií do softvéru NaturaSat vyvíjaného s podporou Európskej vesmírnej agentúry spolu s modifikáciou modelu na prácu s viacerými optickými kanálmi. Numerické experimenty predstavujú aplikáciu metódy na segmentáciu chránených území európskeho významu Natura 2000 zo satelitných snímok získaných skupinou satelitov Sentinel-2.

**Kľúčové slová**: automatická segmentácia, evolúcia krivky, matica opakovaných výskytov, prahovací algoritmus.

#### Abstract

The thesis discusses the proposition and implementation of the modifications for the automatic segmentation of satellite images. The theoretical part of the thesis explains the curve evolution model in Lagrangian formulation. An essential part of the evolution model is a homogeneity function, which specifies an area of expansion for the initial curve. The main goals of the thesis are to propose alternative definitions of the homogeneity function as well as to modify the evolution model to work with multiple optical channels. The practical part deals with the implementation of the proposed method in software NaturaSat developed in cooperation with European Space Agency. Numerical experiments represent an application of curve evolution model for segmentation of protected areas Natura 2000 from satellite images obtained by Sentinel-2 mission.

Key words: automatic segmentation, curve evolution, co-occurence matrix, thresholding

### SvF STUBA

## DIPLOMOVÁ PRÁCA

# Obsah

1	Úvo	od	1							
<b>2</b>	Moo	del automatickej segmentácie	3							
3	Fun	nkcia homogenity								
	3.1	Funkcia homogenity závislá od mediánu	7							
	3.2	Funkcia závislá od priemeru extrémov	7							
	3.3	ISODATA algoritmus	8							
	3.4	Bernsenova metóda	11							
	3.5	Upravená Bernsenova metóda	14							
	3.6	Metóda založená na entropii matíc opakovaných výskytov	16							
		3.6.1 Matica opakovaných výskytov	16							
		3.6.2 Hľadanie prahovej hodnoty	18							
	3.7	7 Prahovanie diagonály matice opakovaných výskytov								
		3.7.1 Premietanie matice opakovaných výskytov na diagonálu	22							
		3.7.2 Úprava diagonály premietnutej matice	23							
		3.7.3 Thomasov algoritmus	25							
		3.7.4 Hľadanie prahových hodnôt	26							
		3.7.5 Výsledná funkcia homogenity	29							
4	NT		റെ							
4	INUI	Contraction of the second	5 <b>4</b>							
	4.1	Sentinei-2 a Natura 2000	32							
	4.2	Ladenie parametrov								

### SvF STUBA

## DIPLOMOVÁ PRÁCA

	4.3	Určova	anie optimálnych parametrov	36			
	4.4	Ukážk	y výsledkov automatickej segmentácie	39			
		4.4.1	Mäkké lužné lesy	39			
		4.4.2	Tvrdé lužné lesy	42			
	4.5	Modifi	kácia modelu pre 3 kanály	44			
		4.5.1	Modifikácia funkcie homogenity	45			
		4.5.2	Ukážky výsledkov automatickej segmentácie upraveného modelu $\ .\ .\ .$	47			
5	Závo	er		51			
Zoznam použitej literatúry 52							

## 1 Úvod

Úloha automatickej segmentácie patrí medzi jednu z najväčších výziev odboru spracovania obrazu. Algoritmy automatickej segmentácie majú v dnešnej dobre široké zastúpenie vo viacerých voľne šíriteľných, ale aj komerčných aplikáciach určených na prácu s obrazovými dátami. V diplomovej práci sa venujeme možnostiam úpravy už existujúceho matematického modelu automatickej segmentácie, ktorý bol použitý v článku [13]. Tento model je založený na vývoji uzavretej Lagrangeovskej krivky v segmentovanej oblasti. Problematiku vývoja kriviek a jej využitie v aplikáciach popisuje viacero publikácií, spomenuli by sme napríklad [4, 3, 12] a veľa ďalších.

Základnému matematickému modelu automatickej segmentácie je venovaná prvá kapitola práce. Model bol vytvorený za účelom automatickej segmentácie chránených území európskeho významu Natura 2000 zo satelitných snímkov misie Sentinel-2. Implementácia tohto matematického modelu v softvéri NaturaSat [2] nám bude slúžiť ako základ, ktorý budeme modifikovať a rozširovať.

V práci sa zameriavame primárne na modifikáciu funkcie homogenity, ktorá v modeli riadi pohyb počiatočnej krivky smerom k hranici segmentovaného územia. Návrhom alternatívnej definície tejto funkcie je venovaná tretia kapitola práce. V navrhnutej modifikácii sa využíva matica opakovaných výskytov, ktorej upravená diagonála bude slúžiť ako identifikátor homogénnych oblasti v segmentovaných dátach.

Posledná kapitola je venovaná numerickým experimentom. Úvod kapitoly popisuje samotné dáta reprezentujúce vybraný obrazový kanál satelitnej snímky, ako aj základné informácie o vybraných biotopov Natura 2000. Pre potreby nájdenia optimálnych parametrov modelu bol vytvorený algoritmus na ich ladenie. Súbor nájdených parametrov bol následne štatisticky spracovaný za účelom nájdenia spoločných charakteristík. Na základe výsledkov ladiaceho algoritmu vieme definovať odporúčané rozmedzie hodnôt pre vybrané parametre modelu, ktoré môžu slúžiť ako prednastavené používateľské hodnoty v užívateľskom prostredí programu

#### $\operatorname{SvF}$ STUBA

### DIPLOMOVÁ PRÁCA

NaturaSat. Ďruhá časť kapitoly je venovaná ukážkam výsledkov automatickej segmentácie oblasti vybraných biotopoch a porovnaniu s referenčnými krivkami, ktoré boli dodané botanikmi z Botanického ústavu Slovenskej akadémie vied. Záver kapitoly je venovaný modifikácii modelu automatickej segmentácie na prácu s viacerými optickými kanálmi spolu s porovnaním s referenčnými krivkami a krivkami získanými z pôvodného evolučného modelu.

## 2 Model automatickej segmentácie

Matematický model automatickej segmentácie použitý v článku [13] je založený na vývoji uzavretej Lagrangeovskej krivky. Tento vývoj je daný rovnicou

$$\frac{\partial \mathbf{x}}{\partial t} = \mathbf{V}(\mathbf{x}, t),$$
 (2.1)

kde **x** reprezentuje bod na vyvíjajúcej sa krivke, t je čas<br/>, $\frac{\partial \mathbf{x}}{\partial t}$  je časová derivácia **x** a  $\mathbf{V}(\mathbf{x},t)$  je vhodne zvolené vektorové pole určujúce smer a rýchlosť pohybu bodu. V našom prípade volíme vektorové pole **V** ako

$$\mathbf{V}(\mathbf{x},t) = (1 - \lambda(t))g_2(\mathbf{x})\mathbf{N}(\mathbf{x},t) - \lambda(t)\nabla g_1(\mathbf{x}) - \delta(t)k(\mathbf{x},t)\mathbf{N}(\mathbf{x},t).$$
(2.2)

Člen  $g_2(\mathbf{x})\mathbf{N}(\mathbf{x},t)$  riadi rozpínanie počiatočnej krivky v smere jej vonkajšej normály  $\mathbf{N}(\mathbf{x},t)$ smerom ku hranici segmentovanej oblasti, zatiaľ čo člen  $-\nabla g_1(\mathbf{x})$  riadi evolúciu krivky vzhľadom na hrany štruktúr v segmentovaných dátach. Parameter  $\lambda(t) \in [0,1]$  je funkcia závislá od času, reprezentujúca váhu vplyvu týchto dvoch členov na výsledný vývoj. Keďže vstupné obrazové dáta môžu byť zašumené, tak pre zachovanie určitej miery hladkosti vyvíjajúcej sa krivky je zavedený člen  $k(\mathbf{x},t)\mathbf{N}(\mathbf{x},t)$ , kde  $k(\mathbf{x},t)$  je znamienková krivosť krivky v bode  $\mathbf{x}$  v čase t. Podobne ako pri parametri  $\lambda(t)$ , môžeme pomocou  $\delta(t)$  meniť vplyv krivosti s meniacim sa časom.

Funkcia  $g_1(\mathbf{x})$  vystupujúca v člene  $-\nabla g_1(\mathbf{x})$  v rovnici (2.2) je definovaná ako

$$g_1(\mathbf{x}) = G_{\sigma_1} * g(s, K_1), \tag{2.3}$$

kde

$$g(s, K_1) = \frac{1}{1 + K_1 s^2} \qquad \text{a} \qquad s(\mathbf{x}) = \left| \nabla \left( G_{\sigma_0} * I^0 \right) \right| (\mathbf{x}). \tag{2.4}$$

Člen  $G_{\sigma_0} * I^0 = I^{\sigma_0}$  predstavuje konvolúciu obrázku  $I^0 : U \to [0,1]$  (prípadne  $I^0 : U \to [0,255]$ ), kde  $U = [1, M] \times [1, N]$  a M, N sú rozmery obrázka, s Gaussovou funkciou s rozptylom  $v = 2\sigma_0$ definovanou v d dimenzionálnom priestore ako

$$G_{\sigma_0}(\mathbf{x}) = \frac{1}{(4\pi\sigma_0)^{d/2}} e^{-|\mathbf{x}|^2/4\sigma_{0.}}$$
(2.5)

3

#### SvF STUBA

Takto definovaná konvolúcia predstavuje rovnomernú Gaussovú filtráciu obrázka  $I^0$ . Keďže funkcia (2.5) pre  $t = \sigma_0$  reprezentuje fundamentálne riešenie lineárnej rovnice vedenia tepla

$$\frac{\partial u(\mathbf{x},t)}{\partial t} = \Delta u(\mathbf{x},t), \qquad (2.6)$$

tak je možné konvolúciu nahradiť riešením rovnice vedenia tepla s časovým krokom  $t = \sigma_0$ a počiatočnou podmienkou  $u^0 = I^0$  [10].

Funkcia  $g(s, K_1)$  v rovnici (2.4) predstavuje hranový detektor. Parameter  $K_1$  určuje citlivosť hranového detektora na vysoké hodnoty noriem gradientov  $|\nabla(G_{\sigma_0} * I^0)|$ . Na dosiahnutie hladkého priebehu funkcie hranového detektora na zašumenom obrázku, je možné funkciu  $g(s, K_1)$  prefiltrovať, čím dostaneme výsledný hranový detektor definovaný rovnicou (2.3).

Uvažujme rovnicu (2.2) bez prvého člena, čiže v tvare

$$\mathbf{V}(\mathbf{x},t) = -\lambda(t)\nabla g_1(\mathbf{x}) - \delta(t)k(\mathbf{x},t)\mathbf{N}(x,t).$$
(2.7)

Funkcia  $g_1(\mathbf{x})$  nadobúda hodnoty blízke 1 v homogénnych oblastiach bez hrán a naopak hodnoty blízke 0 v blízkosti hrán segmentovaných štruktúr. Z definície vidíme, že člen  $-\lambda(t)\nabla g_1(\mathbf{x})$  riadi krivku opačným smerom, než akým smeruje gradient detektoru hrán, čiže smerom ku hranám. Ako bolo už spomenuté, druhý člen zachováva hladkosť krivky pomocou riadenia vyvíjajúcej sa krivky na základe jej krivosti. V nehomogénnych oblastiach s mnohými hranami by mohol byť daný model postačujúci. Avšak v situácii, kde sa počiatočná krivka nachádza uprostred veľkej homogénnej oblasti tak, že hodnota detektoru hrán je vo všetkých jej bodoch príliš malá, takýto model nepostačuje. V tomto prípade sa krivka bude riadiť iba jej krivosťou, čo znamená, že sa začne zmenšovať, až nakoniec zanikne. Tomuto sa dá predísť, a preto bol v modeli zavedený člen  $g_2(\mathbf{x})\mathbf{N}(\mathbf{x},t)$ , ktorého úlohou je rozpínať krivku v smere vonkajšej normály **N** smerom k hľadaným hranám.

Funkcia  $g_2(\mathbf{x})$  v rovnici (2.2) reprezentuje funkciu rýchlosti rozpínania krivky a je definovaná ako

$$g_2(\mathbf{x}) = G_{\sigma_2} * (H(\mathbf{x})g_1(\mathbf{x})), \qquad (2.8)$$

kde funkcia  $H(\mathbf{x})$  reprezentuje funkciu homogenity. Hlavnou úlohou tejto funkcie je čo najpresnejšie matematicky určiť homogénne oblasti (alebo oblasti s určitými homogénnymi štatistickými vlastnosťami). Model uvedený v článku [13] pracuje s predpokladom, že hodnoty intenzít vnútri počiatočnej krivky sa podobajú hodnotám v segmentovanej oblasti. Preto je možné funkciu  $H(\mathbf{x})$  definovať jednou z výpočtovo najjednoduchších možností ako

$$H(\mathbf{x}) = \begin{cases} 1, & \text{ak } I^{\sigma_0}(\mathbf{x}) \in (\rho - \epsilon \rho, \rho + \epsilon \rho), \\ 0, & \text{inak}, \end{cases}$$
(2.9)

kde  $\rho$  je priemerná hodnota intenzity v počiatočnej krivke a parameter  $\epsilon$  mení vzdialenosť od priemernej hodnoty, ktorá určuje, ktoré intenzity budú tvoriť homogénnu oblasť. Funkciu  $H(\mathbf{x})$  v tomto prípade budeme nazývať **funkciou homogenity závislou od strednej hodnoty**. Ďalšou jednoduchou možnosťou, ako definovať funkciu  $H(\mathbf{x})$ , je nájdenie maximálnej a minimálnej intenzity  $\rho_{max}$ , resp.  $\rho_{min}$  a určenie parametra  $\epsilon$  opäť umožňujúceho meniť rozsah pre zaradenie intenzíť do homogénnej oblasti. V tomto prípade môžeme funkciu  $H(\mathbf{x})$ definovať ako

$$H(\mathbf{x}) = \begin{cases} 1, & \text{ak } I^{\sigma_0}(\mathbf{x}) \in (\rho_{min} - \epsilon, \rho_{max} + \epsilon), \\ 0, & \text{inak.} \end{cases}$$
(2.10)

Takto definovanú funkciu budeme v ďalších kapitolách volať ako **funkcia homogenity závislá od minima a maxima**.

V ideálnom prípade by bola funkcia  $g_2(\mathbf{x})$  vnútri segmentovanej oblasti blízka hodnote 1, s približovaním sa ku hranám by sa zmenšovala a mimo segmentovanej oblasti by bola nulová. Takýto priebeh funkcie je v rovnici (2.8) zabezpečený vynásobením funkcie  $H(\mathbf{x})$  hranovým detektorom  $g_1(\mathbf{x})$  definovaným rovnicou (2.3). Nakoniec pre zabezpečenie hladkého priebehu funkcie  $H(\mathbf{x})g_1(\mathbf{x})$  je možné ju prefiltrovať, čím dostávame výslednú formu funkcie rýchlosti rozpínania definovanú rovnicou (2.8).

Keďže funkcie (2.9) a (2.10) nadobúdajú iba hodnoty 0 a 1, ktoré rozdeľujú intenzity obrázku do dvoch skupín, môžeme ich označiť ako jednoduché prahovacie metódy.

## 3 Funkcia homogenity

V tejto časti diplomovej práce sa venujeme návrhom a štúdiou alternatívnych definícii funkcie homogenity  $H(\mathbf{x})$  z rovnice (2.8). Používame už existujúce prahovacie metódy a navrhujeme ich modifikácie za účelom lepšieho popísania homogénnych oblastí. Bola vybraná náhodná satelitná snímka získaná satelitom Sentinel-2 [15]. Na tejto snímke bola vybraná oblasť lesa obkoleseného poľami rôznych farieb, ktorý mal zároveň určitú vnútornú štruktúru. Vybraný optický kanál takejto časti snímky nám bude slúžiť ako testovací obrázok, na ktorom budeme podrobne pozorovať priebeh navrhnutej funkcie. V tejto kapitole sa zameriavame hlavne na definíciu a na vizuálne porovnanie navrhnutých funkcií homogenity. Ich využitie pri automatickej segmentácii spolu s detailnejším popisom misie Sentinel-2 a popisom súboru chránených území Natura 2000 sú uvedené v kapitole Numerické experimenty.

Na začiatok si ukážeme vizualizácie funkcií (2.9) a (2.10) aplikované na prefiltrované testovacie dáta  $I^{\sigma_0}$ . Pri funkcii homogenity závislej od strednej hodnoty bol zadaný parameter  $\epsilon = 0.05$ . Pri funkcii homogenity závislej od minima a maxima bol takisto zadaný parameter  $\epsilon = 0.05$ .



(a) Pôvodný obrázok

(b) Funkcia homogenity  $H(\mathbf{x})$ závislá od strednej hodnoty

(c) Funkcia homogenity  $H(\mathbf{x})$ závislá od minima a maxima



Z obrázkov 3.1(b) a 3.1(c) vidíme, že obe možnosti označili za homogénnu oblasť väčšinu z lesnej plochy a môžeme ich považovať za vhodné. Mierne nežiadúci výsledok vidíme pri funkcii závislej od minima a maxima, kde sa za vhodnú oblasť reprezentujúcu les (bielou farbou) považujú aj niektoré z okolitých polí. Treba však dať do pozornosti, že výsledky sú veľmi citlivé na voľbu počiatočnej krivky. Stačí, aby bola intenzita niekoľkých pixelov v krivke neprimerane vysoká alebo nízka a výsledky sa budú veľmi líšiť. Funkcia homogenity závislá od minima a maxima je na takéto odchýlky oveľa citlivejšia ako funkcia homogenity závislá od strednej hodnoty.

## 3.1 Funkcia homogenity závislá od mediánu

Ako prvú z alternatívnych funkcií sme testovali len mierne upravenú funkciu homogenity závislú od strednej hodnoty (2.9), kde sme v tomto prípade namiesto priemernej hodnoty zvnútra krivky vypočítali mediánovú hodnotu.  $\rho_{med}$  vypočítame ako  $\rho_{med} = median(C)$ , kde Cje množina pixelov obrázka  $I^{\sigma_0}$  nachádzajúcich sa v krivke. Výsledná funkcia homogenity je definovaná ako

$$H(\mathbf{x}) = \begin{cases} 1 & \text{ak } I^{\sigma_0}(\mathbf{x}) \in (\rho_{med} - \epsilon \rho_{med}, \rho + \epsilon \rho_{med}), \\ 0 & \text{inak.} \end{cases}$$
(3.1)

Pri zadaní parametra  $\epsilon = 0.05$  sme vizualizovali výsledky (obr. 3.2). Z obrázkov môžeme vidieť, že výsledná funkcia homogenity je takmer rovnaká ako v prípade funkcie homogenity závislej od strednej hodnoty. Bez problémov vieme určiť hranice lesa, a dokonca sme odhalili aj niektoré vnútorné štruktúry, čím považujeme algoritmus za vhodný. Vzhľadom na výpočtovo menšiu náročnosť algoritmu na hľadanie priemernej hodnoty v porovnaní s mediánovou hodnotou, kde potrebujeme na výpočet najskôr zoradiť intenzity, je funkcia homogenity závislá od strednej hodnoty vhodnejšia, keďže rozdiel vo výsledkoch je takmer zanedbateľný.

### 3.2 Funkcia závislá od priemeru extrémov

Ďalšou testovanou funkciou bola opäť len mierne upravená funkcia homogenity závislá od strednej hodnoty, kde sa tentokrát priradila parametru  $\rho_{avg}$  hodnota  $\rho_{avg} = \frac{\rho_{max} + \rho_{min}}{2}$ ,



(a) Pôvodný obrázok

(b) Funkcia homogenity  $H(\mathbf{x})$ 

Obr. 3.2: Funkcia homogenity závislá od mediánu. Tyrkysová krivka predstavuje počiatočnú krivku.

kde $\rho_{max}$  <br/>a $\rho_{min}$ sú maximálna, resp. minimálna intenzita pixelov obrázk<br/>a $I^{\sigma_0}$ nachádzajúcich sa v krivke. Výsledná definícia funkcie homogenity má tvar

$$H(\mathbf{x}) = \begin{cases} 1 & \text{ak } I^{\sigma_0}(\mathbf{x}) \in (\rho_{avg} - \epsilon \rho_{avg}, \rho_{avg} + \epsilon \rho_{avg}), \\ 0 & \text{inak.} \end{cases}$$
(3.2)

Funkciu s parametrom  $\epsilon = 0.05$  sme aplikovali na testovací obrázok. Rovnako ako v prípade funkcie homogenity závislej od mediánu (3.1) vidíme, že rozdiel oproti funkcii homogenity závislej od strednej hodnoty (2.9) a funkcii homogenity závislej od minima a maxima (2.10) je takmer nespozorovateľný.

## 3.3 ISODATA algoritmus

Vzhľadom na minimálne rozdiely predošlých funkcií sme sa rozhodli otestovať niektoré z prahovacích algoritmov [6]. Ako prvú prahovaciu metódu sme otestovali ISODATA (Iterative Self-Organizing Data Analysis Technique Algorithm) algoritmus. V tomto prípade a v prípade



(a) Pôvodný obrázok

(b) Funkcia homogenity  $H(\mathbf{x})$ 

Obr. 3.3: Funkcia závislá od priemeru extrémov. Tyrkysová krivka predstavuje počiatočnú krivku.

všetkých nasledujúcich algoritmov treba poznamenať, že sa jedná o algoritmy, ktoré neberú do úvahy užívateľom vloženú počiatočnú krivku, ale hodnoty funkcie homogenity sa počítajú nezávislo od krivky. To znamená, že na rozdiel od predošlých metód, kde sa výsledky môžu dramaticky líšiť pri zmene počiatočnej krivky, v týchto prípadoch je funkcia homogenity vždy rovnaká.

Tento algoritmus je príkladom globálneho prahovacieho (thresholding) algoritmu, čo v jednoduchosti znamená, že daný algorimus vypočíta jeden prah, ktorý bude konštantný pre celý obrázok. ISODATA algoritmus vychádza z predpokladu, že obraz je tvorený dvoma rozdeleniami pixelov, popredie a pozadie, ktoré sú príkladom Gaussovho/normálneho rozdelenia s približne rovnakými rozptylmi.

Algoritmus začína počiatočným odhadom prahu, napríklad priemernou intenzitou obrázka. Pomocou tohto prahu dokážeme rozdeliť obrázok na popredie a pozadie. Ďalej sa vypočíta priemerná intenzita v rámci oboch množín a prah sa upraví na ich priemer (stred priemerov). Tento proces sa opakuje, pokiaľ sa vypočítaný prah medzi iteráciami mení. V okamihu, keď majú dve po sebe idúce iterácie rovnaký prah, považujeme algoritmus za dokončený.

Tento algoritmus je zhrnutý v Algoritme 1, kde q a q' značia prahy terajšej a predošlej iterácie,  $\mu_0$ ,  $\mu_1$  sú priemery popredia, resp. pozadia,  $n_0$ ,  $n_1$  sú početnosti popredia, resp. pozadia, K je počet intenzít obrazu a h je histogram obrazu.

Algoritmus 1 ISODATA [6]

1: Vstup: histogram  $h: [0, K-1] \to \mathbb{N}$ 2:  $K \leftarrow Size(h)$ 3:  $q \leftarrow Mean(h, 0, K-1)$ 4:  $q' \leftarrow -1$ 5: while  $q \neq q'$  do  $n_0 \leftarrow Count(h, 0, q)$ 6:  $n_1 \leftarrow Count(h, q+1, K-1)$ 7:if  $(n_0 \neq 0)$ or $(n_1 \neq 0)$  then 8: 9: return -110: else  $\mu_0 \leftarrow Mean(h, 0, q)$ 11:  $\mu_1 \leftarrow Mean(h, q+1, K-1)$ 12: $q' \leftarrow q$ 13: $q \leftarrow \frac{\mu_0 + \mu_1}{2}$ 14:15:end if 16: end while 17:  $Count(h, a, b) = \sum_{i=a}^{b} h(i)$ 18:  $Mean(h, a, b) = (\sum_{i=a}^{b} i * h(i)) / (\sum_{i=a}^{b} h(i))$ 

Po spustení daného algoritmu na testovacom obrázku sme dospeli ku výsledkom na obrázkoch 3.4.

Môžeme vidieť, že ISODATA algoritmus nedosiahol lepšie výsledky ako predošlé algoritmy. Napriek tomu hneď nevylučujeme tento algoritmus, keďže aspoň čiastočne splnil úlohu funkcie homogenity, a to, že vnútro segmentovanej oblasti (lesa) je biele, čo znamená, že rýchlosť rastu



(a) Pôvodný obrázok

(b) Funkcia homogenity  $H(\mathbf{x})$ 

Obr. 3.4: ISODATA algoritmus

krivky je nenulová. V tomto prípade hranice nie sú tak jednoznačne viditeľné ako pri predošlých funkciách, a to najmä v pravom dolnom rohu lesa, kde les susedí s mierne tmavšími poľami, ktoré algoritmus považuje za les. Problém v tomto prípade pravdepodobne vznikol už pri zvolení samotného globálneho prahovacieho algoritmu, ktorý, ako bolo už spomenuté, vyberie jeden prah pre celý obrázok. Vhodnejšie by mohlo byť uvažovať o použití jedného z lokálnych prahovacích algoritmov.

## 3.4 Bernsenova metóda

Ako reprezentanta lokálnych prahovacích algoritmov sme zvolili Bernsenovu metódu [6], ktorá určí meniacu sa prahovú hodnotu Q(x,y) prislúchajúcu jednotlivým pixelom obrázka  $I^{\sigma_0}(x,y)$ . Lokálne adaptívne prahovacie algoritmy sú vhodné pre prípady, keď je na obrázku nejednotné osvetlenie, expozícia, alebo poškvrnené pozadie (v našom prípade môžeme za škvrny považovať jednotlivé polia).

Bernsenova metóda určí dynamický prah pre každý pixel na pozícii (x, y) vypočítaný

#### SvF STUBA

na základe minimálnej a maximálnej intenzity v jeho lokálnom okolí R(x,y). Tieto hodnoty môžeme vypočítať ako

$$I_{min}^{\sigma_0}(x,y) = \min_{\substack{(i,j) \in R(x,y) \\ (i,j) \in R(x,y)}} I^{\sigma_0}(i,j),$$

$$I_{max}^{\sigma_0}(x,y) = \max_{\substack{(i,j) \in R(x,y) \\ (i,j) \in R(x,y)}} I^{\sigma_0}(i,j),$$
(3.3)

pričom spomenuté lokálne okolie pixelu uvažujeme štvorcovú plochu rozmerov  $(2r+1) \times (2r+1)$ , ktorého stredom je pixel, pre ktorý je práve počítaný prah a r je polomer okolia.

Po nájdení minimálnej a maximálnej intenzity, prah vypočítame jednoducho ako aritmetický priemer týchto hodnôt

$$Q(x,y) = \frac{I_{min}^{\sigma_0}(x,y) + I_{max}^{\sigma_0}(x,y)}{2}.$$
(3.4)

Takáto vypočítaná prahová hodnota sa avšak použije iba v prípade, že lokálny kontrast c(x,y) je väčší ako preddefinovaná hodnota minimálneho kontrastu  $c_{min}$ . V prípade, že je lokálny kontrast menší ako minimálny kontrast, prahu sa priradí automatická prahová hodnota  $\tilde{q}$ , ktorej hodnota je rovná 0, ak sa jedná o obrázok so svetlým pozadím. Naopak, ak sa jedná o obrázok s tmavým pozadím (náš prípad), tak sa do  $\tilde{q}$  priradí maximálna intenzita obrázka.

Celá metóda je opäť zhrnutá pseudokódom v Algoritme 2, kd<br/>eKznačí maximálnu intenzitu v obrázku.

Po implementovaní algoritmu sme ho testovali na testovacích dátach s parametrami r = 10a  $c_{min} = 0.15$  (Obr. 3.5).

Tentokrát vidíme oveľa jasnejšie hranicu lesa s poľami v pravom dolnom rohu v porovnaní s globálnym ISODATA algoritmom (obr. 3.4). Dokonca pozorujeme aj niektoré vnútorné štruktúry v lese, ako rúbaniská alebo cesty v ľavej časti lesa. Takisto vnútro segmentovanej oblasti je stále bielej farby, čo je, podobne ako bolo spomenuté pri ISODATA algoritme, veľkým plusom. Keďže Bernsenova metóda spočíva z počítania prahovej hodnoty z minimálnej a maximálnej intenzity v okolí, prichádza otázka, či nedochádza k podobnej situácii, ktorá bola spomenutá pri porovnávaní funkcií homogenity závislých od strednej hodnoty a minima s maximom, keď stačila jedna extrémna hodnota a výsledky funkcie závislej od extrémov sa výrazne menili. V tomto prípade sa nám síce nezmení celý výsledok, ale iba okolie daného

#### Algoritmus 2 Bernsenova metóda

- 1: Vstup: obrázok  $I^{\sigma_0}$  rozmerov  $M \times N$ , minimálny kontrast  $c_{min}$ , typ pozadia a polomer okolia r2:  $\tilde{q} \leftarrow \begin{cases} K & \text{ak } tmavé pozadie \\ 0 & \text{ak } svetlé pozadie. \end{cases}$ 3: for all  $pixel(x, y) \in M \times N$  do 4:  $R \leftarrow vytvorOkolie(x, y, r)$ 5:  $I^{\sigma_0}_{min}(x, y) = \min_{(i,j) \in R(x,y)} I^{\sigma_0}(i, j)$ 6:  $I^{\sigma_0}_{max}(x, y) = \max_{(i,j) \in R(x,y)} I^{\sigma_0}(i, j)$ 7:  $c \leftarrow I^{\sigma_0}_{max} - I^{\sigma_0}_{min}$ 8:  $Q(x, y) \leftarrow \begin{cases} I^{\sigma_0}_{min}(x, y) + I^{\sigma_0}_{max}(x, y) \\ \tilde{q} & \text{inak.} \end{cases}$  ak  $c \ge c_{min}$   $\tilde{q} & \text{inak.} \end{cases}$ 9: end for 10: return Q
- 11:  $vytvorOkolie(x, y, r) : \{(i, j) \in \mathbb{Z}^2 | u i \le r \land v j \le r\}$



(a) Pôvodný obrázok

(b) Funkcia homogenity  $H(\mathbf{x})$ 

Obr. 3.5: Bernsenov algoritmus

extrémneho pixelu. Napriek tomu nemôžeme zanedbať možnosť výskytu takejto situácie a skúsime navrhnúť lepšiu alternatívu.

## 3.5 Upravená Bernsenova metóda

Ako bolo ukázané v úvode kapitoly, výpočtovo najefektívnejšou alternatívou zo spomenutých možností je vypočítanie prahu pomocou aritmetického priemeru. Pri identickej definícii okolia R ako v sekcii Bernsenova metóda môžeme nahradiť rovnice (3.3) a (3.4) nasledovne

$$Q(x,y) = \frac{\sum_{(i,j)\in R(x,y)} I^{\sigma_0}(i,j)}{(2r+1)^2}.$$
(3.5)

Po takejto úprave vypadne kontrola minimálneho kontrastu, keďže lokálny kontrast už nepoznáme a nahradíme ju kontrolou minimálnej intenzity  $i_{min}$ , ktorá funguje na rovnakom princípe. Tvar upraveného algoritmu môžeme vidieť v Algoritme 3.

Algoritmus bol aplikovaný na testovacie dáta a ako parametre boli použité hodnoty  $i_{min} = 0.25$  a r = 15.

#### Algoritmus 3 Upravená Bernsenova metóda

1: Vstup: obrázok  $I^{\sigma_0}$  rozmerov  $M \times N$ , typ pozadia, minimálna intenzita  $i_{min}$  a polomer okolia r

$$2: \quad \widetilde{q} \leftarrow \begin{cases} K \quad \text{ak tmavé pozadie} \\ 0 \quad \text{ak svetlé pozadie.} \end{cases}$$

$$3: \quad \mathbf{for \ all \ pixel(x,y) \in M \times N \ do}$$

$$4: \quad R \leftarrow vytvorOkolie(x,y,r)$$

$$5: \quad i_{mean}(x,y) \leftarrow \frac{\sum_{(i,j) \in R(x,y)} I^{\sigma_0}(i,j)}{(2r+1)^2}$$

$$6: \quad Q(x,y) \leftarrow \begin{cases} i_{mean} \quad \text{ak } i_{mean}(x,y) \ge i_{min} \\ \widetilde{q} \qquad \text{inak} \end{cases}$$

7: end for

. .

- 8: return Q
- 9: vytvorOkolie(x, y, r):  $\{(i, j) \in \mathbb{Z}^2 | u i \leq r \land v j \leq r\}$



(a) Pôvodný obrázok

(b) Funkcia homogenity  $H(\mathbf{x})$ 

Obr. 3.6: upravený Bernsenov algoritmus

Môžeme vidieť, že čo sa týka hraníc segmentovanej oblasti, naša úprava viditeľne pomohla a

je úplne zrejmé, kde sa nachádza hranica lesa po celom jeho obvode. Toto vylepšenie však prišlo na úkor citlivosti algoritmu na detegovanie vnútorných štruktúr lesa, keďže sa nám podarilo zachytiť menší počet rúbanísk. Každopádne hodnotíme aj neupravený Bernsenov algoritmus, aj náš modifikovaný algoritmus pozitívne, keďže výsledky boli uspokojivé a nedošlo k výrazným vizuálnym chybám.

## 3.6 Metóda založená na entropii matíc opakovaných výskytov

Ako sme mohli vidieť v predchádzajúcich sekciách, prahovacie algoritmy môžu dosahovať vizuálne dobré výsledky, ale v niektorých prípadoch majú potenciál výrazne sa vylepšiť. Jeden zo zrejmých prípadov je ISODATA algoritmus, kde nastal problém pri identifikovaní hranice objektu, keď bola jeho intenzita podobná intenzite okolia (viď obr. 3.4(b) vpravo dole). Táto metóda bola založená na predpoklade, že histogram segmentovaného obrázka je zložený kombináciou dvoch Gaussových distribúcií. Jej princíp spočíval v nájdení prahovej hodnoty, ktorá by rozdelila tieto distribúcie do dvoch skupín (popredie a pozadie). Nasledujúca metóda opisuje alternatívny prístup, ktorý narozdiel od transformácie histogramu (ISODATA, Bernsenova metóda...) využíva na určenie prahových hodnôt štatistické vlastnosti obrazovej informácie. Metóda obsahuje okrem samotných intenzít pixelov obrázka  $I^{\sigma_0}$ , aj určitú informáciu o ich vzájomnej priestorovej korelácii. Zakomponovanie informácie o polohe je uskutočnené pomocou matice opakovaných výskytov (angl. *Co-occurrence matrix*).

#### 3.6.1 Matica opakovaných výskytov

Matica opakovaných výskytov je matica, ktorá popisuje vzájomné vzťahy medzi intenzitami obrázka v preddefinovanej vzdialenosti a smere.

Majme prefiltrovaný obrázok  $I^{\sigma_0}$  rozmerov  $M \times N$ , ktorý je prevzorkovaný K rôznymi intenzitami  $V = \{0, 1, 2, ..., K-1\}$ . Tento obrázok môžeme definovať ako  $I_K = [f(x,y)]_{M \times N}$ , kde  $f(x,y) \in V$  je intenzita pixelu na pozícii (x,y). Matica opakovaných výskytov daného obrázka je  $K \times K$  rozmerná matica  $CM = [t_{i,j}]_{K \times K}$ , kde prvky  $t_{i,j}$ ,  $i, j \in V$  reprezentujú počet prechodov medzi dvoma intenzitami v obrázku. Matica opakovaných výskytov [7] je asymetrická matica, uvažujúca prechody medzi pixelmi horizontálne smerom vpravo a vertikálne smerom hore. V takomto prípade môžeme prvky matice opakovaných výskytov definovať ako

$$t_{i,j} = \sum_{l=1}^{M-1} \sum_{k=1}^{N-1} \delta(l,k), \qquad (3.6)$$

kde

$$\delta(l,k) = \begin{cases} 1 & \text{ak } (f(l,k) = i \land f(l+1,k) = j) \lor (f(l,k) = i \land f(l,k+1) = j), \\ 0 & \text{inak.} \end{cases}$$
(3.7)

V našom prípade použijeme definíciu matice opakovaných výskytov ktorá umožňuje skúmať priestorovú závislosť nielen v posune o 1 pixel, ale o *o* pixelov, kde  $o \in \{1, 2, ..., \lfloor \frac{\min(M, N) - 1}{2} \rfloor\}$ . Výslednú maticu opakovaných výskytov definujeme ako súčet matíc opakovaných výskytov v jednotlivých smeroch  $\theta \in \Theta$ , kde  $\Theta = \{0^{\circ}, 45^{\circ}, 90^{\circ}, 135^{\circ}\}$ , pričom tieto matice uvažujeme symetrické.

Prvky výslednej matice opakovaných výskytovCMzískame upravením rovníc(3.6)a(3.7)na tvar

$$t_{i,j} = \sum_{\theta \in \Theta} t_{i,j}^{\theta}, \tag{3.8}$$

kde

$$t_{i,j}^{\theta} = \sum_{l=1+o}^{M-o} \sum_{k=1+o}^{N-o} \delta_o^{\theta}(l,k)$$
(3.9)

а

$$\begin{split} \delta_{o}^{0^{\circ}}(l,k) &= \begin{cases} 1, & \text{ak } (f(l,k) = i \wedge f(l+o,k) = j) \lor (f(l,k) = i \wedge f(l-o,k) = j), \\ 0, & \text{inak}, \end{cases} \\ \delta_{o}^{45^{\circ}}(l,k) &= \begin{cases} 1, & \text{ak } (f(l,k) = i \wedge f(l+o,k+o) = j) \lor (f(l,k) = i \wedge f(l-o,k-o) = j), \\ 0, & \text{inak}, \end{cases} \\ \delta_{o}^{90^{\circ}}(l,k) &= \begin{cases} 1, & \text{ak } (f(l,k) = i \wedge f(l,k+o) = j) \lor (f(l,k) = i \wedge f(l,k-o) = j), \\ 0, & \text{inak}, \end{cases} \\ \delta_{o}^{135^{\circ}}(l,k) &= \begin{cases} 1, & \text{ak } (f(l,k) = i \wedge f(l-o,k+o) = j) \lor (f(l,k) = i \wedge f(l+o,k-o) = j), \\ 0, & \text{inak}, \end{cases} \\ \delta_{o}^{135^{\circ}}(l,k) &= \begin{cases} 1, & \text{ak } (f(l,k) = i \wedge f(l-o,k+o) = j) \lor (f(l,k) = i \wedge f(l+o,k-o) = j), \\ 0, & \text{inak}. \end{cases} \end{cases} \end{split}$$

Vizualizácia matice opakovaných výskytov CM vytvorenej z nášho testovacieho obrázka 3.1, pre ktorý platí M = N = 800, K = 256, o = 1 a  $\Theta = \{0^{\circ}, 45^{\circ}, 90^{\circ}, 135^{\circ}\}$  je zobrazená na obrázku 3.7. Z matice dokážeme aj bez pozretia na testovací obrázok povedať, že na ňom prevládajú tmavšie farby (najväčšie početnosti sú pri nízkych intenzitách), a že sa jedná o len mierne zašumený obrázok, tvorený najmä homogénnymi plochami, pretože najväčšie početnosti sú zoskupené pri hlavnej diagonále, t.j. na obrázku nie je príliš veľa veľkých skokov intenzít medzi porovnávanými pixelmi. Na obrázku 3.8 sú znázornené hodnoty zo stĺpcov 201 až 208 a riadkov 201 až 208. V tabuľke vidíme, že matica je symetrická a takisto vidíme, že najväčšie početnosti sa nachádzajú pri hlavnej diagonále a s rastom vzdialenosti od nej početnosti klesajú.

#### 3.6.2 Hľadanie prahovej hodnoty

Po vypočítaní matice opakovaných výskytov môžeme pokračovať v hľadaní prahovej hodnoty [7]. Prvým krokom je normalizovanie celkového počtu prechodov  $t_{i,j}$  v matici opakovaných výskytov s cieľom získania matice prechodových pravdepodobností, ktorá vyzerá nasledovne

$$p_{i,j} = \frac{t_{i,j}}{\sum_{l=0}^{K-1} \sum_{k=0}^{K-1} t_{k,l}}.$$
(3.11)

18

### DIPLOMOVÁ PRÁCA

#### SvF STUBA



Obr. 3.7: Matica opakovaných výskytov

ſ	·	÷	÷	:	÷	÷	÷	:	:	· · ·
		512	508	410	412	376	357	279	276	
		508	606	493	529	443	454	336	283	
		410	493	404	461	404	419	346	302	
		412	529	461	606	476	548	434	434	
		376	443	404	476	468	484	416	429	
		357	454	419	548	484	572	438	502	
		279	336	346	434	416	438	432	427	
		276	283	302	434	429	502	427	406	
	··	÷	÷	÷	÷	÷	÷	÷	÷	·



Uvažujme prahovú hodnotu  $q \in V$ . Matica opakovaných výskytov CM, definovaná rovnicami (3.8)-(3.10), je rozdelená na štyri kvadranty A, B, C a D (viď obr. 3.9).



Obr. 3.9: Kvadranty matice opakovaných výskytov

Tieto štyri kvadranty dokážeme rozdeliť na dva typy. Uvažujeme, že pixely s intenzitami väčšími ako je prahová hodnota q reprezentujú popredie a pixely s nižšími intenzitami ako q reprezentujú pozadie. Potom kvadranty A a C obsahujú lokálne prechody vrámci popredia resp. pozadia a kvadranty B a D označujú prechody medzi popredím a pozadím.

DIPLOMOVÁ PRÁCA

Dokážeme vypočítať sumy pravdepodobností v kvadrantoch vzťahmi

$$P_{A} = \sum_{i=0}^{q} \sum_{j=0}^{q} p_{i,j},$$

$$P_{B} = \sum_{i=0}^{q} \sum_{j=q+1}^{K-1} p_{i,j},$$

$$P_{C} = \sum_{i=q-1}^{K-1} \sum_{j=q-1}^{K-1} p_{i,j},$$

$$P_{D} = \sum_{i=q-1}^{K-1} \sum_{j=0}^{q} p_{i,j},$$
(3.12)

ktoré použijeme na vyjadrenie lokálnych prechodových pravdepodobností v rámci jednotlivých kvadrantov vo forme

$$p_{i,j}^{A} = \frac{p_{i,j}}{P_{A}},$$

$$p_{i,j}^{B} = \frac{p_{i,j}}{P_{B}},$$

$$p_{i,j}^{C} = \frac{p_{i,j}}{P_{C}},$$

$$p_{i,j}^{D} = \frac{p_{i,j}}{P_{D}}.$$
(3.13)

Na určenie prahovej hodnoty q použijeme entropiu kvadrantov B a D, ktoré popisujú prechody medzi popredím a pozadím. Definujme funkciu lokálnej entropie H prechodu z pozadia na popredie (kvadrant B) a z popredia na pozadie (kvadrant D) nasledovne

$$H_{B} = -\frac{1}{2} \sum_{i=0}^{q} \sum_{j=q+1}^{K-1} p_{i,j}^{B} \log p_{i,j}^{B}, \quad p_{i,j}^{B} \neq 0,$$

$$H_{D} = -\frac{1}{2} \sum_{i=q+1}^{K-1} \sum_{j=0}^{q} p_{i,j}^{D} \log p_{i,j}^{D}, \quad p_{i,j}^{D} \neq 0.$$
(3.14)

Výslednú entropiu môžeme definovať ako aritmetický priemer entropií kvadrantu Ba kvadrantu  $D\ [7]$ 

$$H = \frac{H_B + H_D}{2}.\tag{3.15}$$

Cieľom algoritmu je nájsť maximálnu entropiu pr<br/>e $o\in\{1,2,...,\lfloor\frac{\min(M,N)-1}{2}\rfloor\}$ a $q\in\{1,2,...,K-2\}.$ 

Metódu sme testovali na testovacom obrázku, pričom na výpočet matice opakovaných výskytov sme použili  $\Theta = \{0^{\circ}, 45^{\circ}, 90^{\circ}, 135^{\circ}\}$ . Pre urýchlenie výpočtu bol testovací obrázok prevzorkovaný do 32 intenzít, a preto K = 32.



(a) Pôvodný obrázok

(b) Funkcia homogenity  $H(\mathbf{x})$ 

Obr. 3.10: Metóda založená na entropii matíc opakovaných výskytov

Maximálna entropia nastala pri odsadení o = 9 a prahu q = 10. Túto metódu môžeme považovať za vhodnú, keďže vnútro segmentovanej oblasti je biele a hranice sú dostatočne viditeľné dokonca aj v pravom dolnom rohu, kde mal ISODATA algoritmus problémy. Avšak môžeme si všimnúť potenciálne nedostatky danej metódy, konkrétne v hornej časti ľavého okraja lesa, kde algoritmus označuje jedno pole za les. Problém spočíva v tom, že poľnohospodárske plochy sú zväčša rozľahlé plochy homogénnych intenzít a majú veľký vplyv na maticu opakovaných výskytov, čím môžu značne ovplyvniť výsledok. Táto metóda by mala lepšie využitie v oblastiach s menším zastúpením antropogénneho reliéfu. Ďalšou potenciálnou nevýhodou tejto metódy je to, že je výpočtovo jednoznačne najnáročnejšia z dosiaľ nami testovaných metód. V našom prípade sme testovali pri prevzorkovaní na 32 intenzít, avšak reálne satelitné dáta môžu nadobúdať tisíce rôznych intenzít. Preto sme uvažovali nad inými metódami využívajúcimi matice opakovaných výskytov, ktoré by boli výpočtovo menej náročné.

## 3.7 Prahovanie diagonály matice opakovaných výskytov

Z definície matice opakovaných výskytov vieme, že prvky nachádzajúce sa na jej hlavnej diagonále popisujú pixely, ktorých susedia majú rovnakú intenzitu. To znamená, že čím je menší rozptyl mimodiagonálnych prvkov v smere kolmom na hlavnú diagonálu, tým majú v našom obrázku väčšie zastúpenie homogénne plochy.

#### 3.7.1 Premietanie matice opakovaných výskytov na diagonálu

Naším cieľom je dokázať rozdeliť tieto homogénne plochy reprezentujúce lesy a polia, preto má väčší zmysel zaoberať sa práve prvkami matice blízko hlavnej diagonály. Jednoduchým prístupom by bolo zanedbanie všetkých prvkov matice nenachádzajúcich sa na diagonále, avšak to nie je najvhodnejší prístup, pretože segmentovaná oblasť nie je takmer nikdy úplne homogénna a nachádzajú sa na nej štruktúry, v ktorých sa intenzity môžu mierne meniť. Z tohto dôvodu urobíme vážený priemet mimodiagonálnych prvkov matice opakovaných výskytov na jej diagonálu. Takto vytvorenú maticu si označíme ako CM'. Mimodiagonálny prvok  $t_{i,j}$ ,  $i \neq j$ premietame na súradnice {round $(\frac{i+j}{2})$ , round $(\frac{i+j}{2})$ }.

Ako bolo už spomenuté, zaujímajú nás hlavne prvky matice opakovaných výskytov, ktoré sú blízko diagonály. Preto si definujeme funkciu vzdialenosti od diagonály dist(i, j) = |i - j| [1]. Z tejto definície je zjavné, že ak sa prvok nachádza na diagonále, tak platí, že i = j a funkcia vzdialenosti je rovná nule (|i - j| = 0). Druhým extrémom sú súradnice matice i = K - 1, j = 0a i = 0, j = K - 1, kde funkcia vzdialenosti dosahuje maximálnu hodnotu K - 1. Túto funkciu však môžeme nahradiť aj euklidovskou vzdialenosťou súradníc prvkov od diagonály definovanou ako

$$dist(i,j) = \sqrt{\left(i - \frac{i+j}{2}\right)^2 + \left(j - \frac{i+j}{2}\right)^2}.$$
(3.16)

Na definovanie výslednej váhy pre priemet použijeme vzťah  $\frac{1}{l \cdot p}$ , kde l = dist(i, j) a p > 0 predstavuje penalizačný koeficient, ktorým budeme môcť meniť vplyv mimodiagonálnych prvkov na výslednú diagonálu matice opakovaných výskytov CM'. Celkový postup premietania na diagonálu je zhrnutý v Algoritme 4.

#### Algoritmus 4 Premietanie na diagonálu matice CM'

1: Vstup: matica opakovaných výskytov  $CM = [t_{i,j}]_{K \times K}$ a penalizačný koeficient p

2: for all  $t_{i,j} \in CM$  do 3:  $l \leftarrow dist(i,j)$ 4:  $index \leftarrow round(\frac{i+j}{2})$ 5:  $CM'(index, index) += \begin{cases} t_{i,j} & \text{ak } l = 0\\ \frac{t_{i,j}}{l \cdot p} & \text{inak} \end{cases}$ 6: end for 7: return CM'

8: 
$$dist(i,j): |i-j|$$
 alebo  $\sqrt{\left(i-\frac{i+j}{2}\right)^2 + \left(j-\frac{i+j}{2}\right)^2}$ 

Výsledok premietania matice opakovaných výskytov (obr. 3.7) na jej diagonálu, vytvorenej z testovacieho obrázka pri zadaných parametroch o = 1,  $\theta_{user} = \{0^{\circ}, 45^{\circ}, 90^{\circ}, 135^{\circ}\}, p = 10$  a využití euklidovskej vzdialenosti je zobrazený na obrázku 3.11 modrou farbou.



Obr. 3.11: Prvky diagonály matice CM'

### 3.7.2 Úprava diagonály premietnutej matice

Navrhnutý algoritmus je založený na sledovaní lokálnych extrémov na diagonále matice CM'. Keďže matica CM' má nenulové prvky iba na diagonále, definujeme si diskrétnu funkciu

d(x,t), pre ktorú platí, že  $d(x,0) = t_{x,x}$ , kde  $t_{x,x}, x = \{0, ..., K-1\}$  sú diagonálne prvky matice CM'. Funkcia d(x,t) môže obsahovať veľké množstvo malých lokálnych extrémov, pričom algoritmus je založený na sledovaní výraznejších extrémov. Z tohoto dôvodu použijeme jeden krok implicitnej numerickej schémy pre filtráciu lineárnou rovnicou vedenia tepla v 1D so zadaným časovým krokom  $\sigma_d$ .

Vo všeobecnosti vieme lineárnu difúziu funkci<br/>eu(x,t),kde $x\in[0,M],\ t\in[0,T]$ zapísať v tvare

$$\frac{\partial u(x,t)}{\partial t} = \Delta u(x,t). \tag{3.17}$$

Počiatočná podmienka je  $u^0(x) = u(x,0)$  a uplatňujeme Dirichletove okrajové podmienky  $u_{left} = u(0,0)$  a  $u_{right} = u(M,0)$ .

Na numerickú aproximáciu rovnice použijeme metódu konečných diferencií [11]. Na to, aby bola schéma bezpodmienečne stabilná, využijeme implicitnú časovú schému, ktorá na aproximáciu časovej derivácie používa spätnú diferenciu a na aproximáciu druhej derivácie centrálnu diferenciu. Rovnicu (3.17) vieme numericky vyjadriť v tvare

$$\frac{u_m^n - u_m^{n-1}}{\tau} = \frac{u_{m+1}^n - 2u_m^n + u_{m-1}^n}{h^2},\tag{3.18}$$

kde h = 1 je priestorový krok,  $\tau = t_n - t_{n-1}$  predstavuje časový krok a riešenie v *n*-tom časovom kroku v bode m = x označíme  $u_m^n$ .

Po dosadení a upravení rovnice (3.18) dostávame sústavu rovníc

$$u_0^n = u_{left}$$
  
$$-\tau u_{m-1}^n + (1+2\tau)u_m^n - \tau u_{m+1}^n = u_m^{n-1}, \qquad m = 1, \dots, M-1, \qquad (3.19)$$
  
$$u_M^n = u_{right}$$

alebo v maticovom zápise  $A\mathbf{x} = \mathbf{b}$ , kde je matica koeficientov A

$$A = \begin{bmatrix} 1 & 0 & 0 & 0 & \dots & 0 & 0 & 0 & 0 \\ -\tau & (1+2\tau) & -\tau & 0 & \dots & 0 & 0 & 0 & 0 \\ 0 & -\tau & (1+2\tau) & -\tau & \dots & 0 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \dots & -\tau & (1+2\tau) & -\tau & 0 \\ 0 & 0 & 0 & 0 & \dots & 0 & -\tau & (1+2\tau) & -\tau \\ 0 & 0 & 0 & 0 & \dots & 0 & 0 & 1 \end{bmatrix},$$
(3.20)

24

vektor neznámych  $\mathbf{x}$  je

$$\mathbf{x} = \begin{bmatrix} u_0^n \\ u_1^n \\ u_2^n \\ \vdots \\ u_{M-2}^n \\ u_{M-1}^n \\ u_M^n \end{bmatrix},$$
(3.21)  
$$\mathbf{b} = \begin{bmatrix} u_{left} \\ u_1^{n-1} \\ u_2^{n-1} \\ \vdots \\ u_{M-2}^{n-1} \\ \vdots \\ u_{M-1}^{n-1} \\ u_{M-1}^{n-1} \\ u_{M-1} \end{bmatrix}.$$
(3.22)

a známa pravá strana

Odvodenú numerickú schému použijeme na prefiltrovanie funkcie  $d(x,t), x \in [0, K-1], t \in [0, \sigma_d]$ čím dostaneme prefiltrovanú funkciu  $d^{\sigma}(x)$ . Ako počiatočnú podmienku použijeme hodnoty funkcie d(x,0) a ako okrajové podmienky hodnoty d(0,0) a d(K-1,0).

#### 3.7.3 Thomasov algoritmus

Riešime teda sústavu K rovníc, pričom sa jedná o trojdiagonálny systém, ktorý nemusíme riešiť iteračnými metódami (Jacobiho, Gauss-Seidelova, SOR), ale dokážeme ho vyriešiť aj zjednodušenou formou Gaussovej eliminácie - Thomasovym algoritmom [16], ktorý dospeje ku výsledku v O(K) operáciách namiesto  $O(K^3)$  potrebných pre Gaussovu elimináciu.

Zavedieme si označenie hlavnej diagonály matice M = diag(A), hornej diagonály U, spodnej diagonály L a vektora pravej strany F. Potom môžeme postup algoritmu opísať v dvoch krokoch. Prvým je dopredné prechádzanie, ktorým sa eliminuje L a spočíva vo vypočítaní

### DIPLOMOVÁ PRÁCA

#### SvF STUBA

dvoch pomocných vektorov U' a F'

$$U'_{m} = \begin{cases} \frac{U_{m}}{M_{m}} & \text{ak } m = 0, \\ \frac{U_{m}}{M_{m} - L_{m}U'_{m-1}} & m = 1, 2, 3, ..., K - 2 \end{cases}$$
(3.23)

a

$$F'_{m} = \begin{cases} \frac{F_{m}}{M_{m}} & \text{ak } m = 0, \\ \frac{F_{m} - L_{m} F'_{m-1}}{M_{m} - L_{m} U'_{m-1}} & m = 1, 2, 3, ..., K - 1. \end{cases}$$
(3.24)

Výsledné riešenie sa vypočíta v druhom kroku spätnou substitúciou

$$d_{K-1}^{\sigma} = F_{K-1}',$$

$$d_{m}^{\sigma} = F_{m}' - U_{m}'F_{m+1} \quad \text{pre } m = K-2, K-3, ..., 0.$$
(3.25)

Na obrázku 3.12 je znázornená neprefiltrovaná funkcia  $d^0(x)$  spolu s riešeniami s časovými krokmi  $\sigma_d = 1, \sigma_d = 2.5$  a  $\sigma_d = 5$ .



Obr. 3.12: Prvky prefiltrovanej diagonály matice CM'

### 3.7.4 Hľadanie prahových hodnôt

Po prefiltrovaní dostávame funkciu  $d^{\sigma}(x)$ , kde lokálne maximá reprezentujú rozľahlé homogénne plochy, ako sú polia a lesy. Za predpokladu, že okolité polia budú dostatočne

rozľahlé, môžeme predpokladať, že týmto spôsobom odhalíme aj mierne rozdiely intenzít. V závislosti od veľkosti zvoleného argumentu  $\sigma_d$  na vyhladenie diagonály, sa mení počet lokálnych extrémov. Túto hypotézu sme aj empiricky potvrdili na našom testovacom obrázku (obr. 3.12), kde sa na vizualizácii neprefiltrovanej funkcie  $d^0(x)$  vyskytuje 38 lokálnych miním a na funkcii vyhladenej parametrom  $\sigma_d = 1$ ,  $\sigma_d = 2.5$  a  $\sigma_d = 5$  sa nachádza 19, 10 a 7 lokálnych miním.

Pri racionálnej voľbe parametra  $\sigma_d$  teda dostávame viacero lokálnych extrémov, pričom lokálne minimá funkcie  $d^{\sigma}(x)$  môžeme považovať za prahy medzi homogénnymi oblasťami. Samotný algoritmus hľadania lokálnych miním spočíva v tom, že hodnotu  $d^{\sigma}(x)$  považujeme za lokálne minimum, ak platí, že  $d^{\sigma}(x-1) < d^{\sigma}(x) < d^{\sigma}(x+1)$ . Algoritmus vracajúci vektor prahov  $p_q$ , q = 1, ..., Q môžeme jednoducho popísať pseudokódom v Algoritme 5.

Algoritmus 5 Hľadanie lokálnych miním vo vektore

1: Vstup: vektor  $v = d^{\sigma}$  dĺžky K 2: for i = 1, 2, ..., K - 2 do 3: if  $(v_{i-1} > v_i)$  and  $(v_{i+1} > v_i)$  then 4: p.append(i)5: end if 6: end for 7: return p

Definujme si funkciu homogénnych oblastí  $w_{i,j} \in [0,1]$ , pre ktorú platí

$$w_{i,j} = \frac{1}{Q} \sum_{q=1}^{Q} r_q, \qquad \text{kde } r_q = \begin{cases} 0, & \text{ak } p_q < I_{i,j}^{\sigma_0}, \\ 1, & \text{inak.} \end{cases}$$
(3.26)

Takto definovaná funkcia priraďuje každému pixelu obrázka  $I^{\sigma_0}$  nachádzajúcemu sa v homogénnej oblasti, ktorá bola detegovaná v  $d^{\sigma}(x)$ , rovnakú hodnotu. Na obrázku 3.13 sú znázornené hodnoty funkcie homogénnych oblastí na vyhladenej funkcii  $d^{\sigma}$  časovým krokom  $\sigma_d = 5$ .

Na obrázku 3.14 môžeme vidieť vizualizáciu funkcie homogénnych oblastí. Ako argumenty pre maticu opakovaných výskytov boli použité hodnoty K = 256, o = 1 a na filtráciu funkcie

## DIPLOMOVÁ PRÁCA

#### SvF STUBA



Obr. 3.13: Funkcia homogénnych oblastí na funkci<br/>i $d^\sigma$ 

d(x) sme použili  $\sigma_d = 0.2$ . Na obrázku vidíme, že homogénnej oblasti reprezentujúcej les bola priradená vysoká hodnota  $w_{i,j}$  a okolitým poliam boli priradené nižšie hodnoty. Potvrdil sa náš predpoklad a algoritmus odhalil hranicu lesa dostatočne dobre či už v spodnej časti lesa, kde mali problém globálne prahovacie algoritmy, ale aj v ľavej časti, s ktorou mal problém predchádzajúci algoritmus. Taktiež môžeme vidieť, že algoritmus dokáže rozoznať aj jednotlivé polia, ktorých veľkosť je značne menšia ako veľkosť segmentovanej oblasti.



Obr. 3.14: Funkcia homogénnych oblastí

#### 3.7.5 Výsledná funkcia homogenity

Takto navrhnutý algoritmus môže slúžiť na segmentáciu viacerých rôznych typov homogénnych oblastí (les, lúka, pole, vodná plocha, rieka a iné). Možnosť výberu oblasti je daná voľbou pozície počiatočnej krivky. Následne si zaznamenávame všetky rôzne hodnoty z funkcie homogénnych oblastí, ktoré sa nachádzajú v počiatočnej krivke. Tieto hodnoty budú vo výslednej funkcii homogenity nadobúdať hodnotu 1 a všetky ostatné budú nadobúdať hodnotu 0. Postup hľadania hodnôt z funkcie homogénnych oblastí v počiatočnej krivke a vytvárania výslednej funkcie homogenity je opísaný v Algoritme 6.

Algoritmus 6 Vytvorenie výslednej prahovej funkcie

- 1: Vstup: Obrázok hodnôt funkcie homogénnych oblastí  $W = [w_{i,j}]_{M \times N}$ a počiatočná krivka C
- 2:  $tmp \leftarrow \{\}$
- 3: for all  $w_{i,j} \in C$  do
- 4: **if**  $w_{i,j} \notin tmp$  **then**
- 5:  $tmp.append(w_{i,j})$
- 6: end if
- 7: end for
- 8: for all  $w_{i,j} \in W$  do
- 9:  $H(i,j) \leftarrow \begin{cases} 1 & \text{ak } w_{i,j} \in tmp \\ 0 & \text{ak } w_{i,j} \notin tmp \end{cases}$
- 10: **end for**

```
11: return H
```

Po implementovaní algoritmu sme získali výslednú funkciu homogenity zobrazenú na obrázku 3.15(b).

Na obrázku vidíme, že sa nám podarilo eliminovať nedostatky pôvodne definovanej funkcie homogenity (Obr. 3.1(c)) a celá hranica segmentovanej oblasti je jednoznačne určená. Výhodou navrhnutej funkcie je aj to, že dokázala zachytiť podrobne aj vnútornú štruktúru lesa a to všetko pri výraznom znížení časovej náročnosti oproti metóde založenej na entropii matíc opakovaných výskytov. V navrhnutom algoritme je detekcia samotných homogénnych oblastí



(a) Pôvodný obrázok

(b) Funkcia homogenity  $H(\mathbf{x})$ 

Obr. 3.15: Prahovanie diagonály matice opakovaných výskytov

nezávislá na pozícii počiatočnej krivky, keďže jej pozícia určuje len výber homogénnej oblasti, ktorú chceme segmentovať.

Pri porovnaní s druhou, pôvodne definovanou, funkciou závislou od strednej hodnoty (Obr. 3.1(b)) nie sú rozdiely až tak zjavné. Rozdiel je viac viditeľný, keď zmeníme pozíciu počiatočnej krivky napríklad na pozíciu z obrázku 3.16(a). Tentokrát počiatočná krivka už neleží celou svojou plochou v ideálnej zalesnenej časti, ale zahŕňa aj časť lúky. V tomto prípade je užívateľ pri voľbe metódy závislej od strednej hodnoty prinútený vybrať si z dvoch možností. Buď zvolí väčšiu hodnotu parametra  $\epsilon$  (Obr. 3.16(b)), čím zväčší interval na úkor podobných chýb ako boli skôr spomenuté, čiže horšia detekcia hraníc a zahrnutie niektorých polí do lesa, alebo zvolí menšiu hodnotu parametra  $\epsilon$  (Obr. 3.16(c)), pričom bude mať výsledná funkcia homogenity zjavné nedostatky. Pri použití navrhnutej metódy (Obr. 3.16(d)) vidíme mierne zmeny, kde už tak isto nie celkom dokonale rozoznávame hranice lesa, avšak pri porovnaní dosahuje podstatne lepšie výsledky. Vidíme teda, že navrhnutá metóda je stabilnejšia pri zmene polohy počiatočnej krivky.



(a) Testovací obrázok s novou pozíciou počiatočne<br/>j $\,$ (b) Funkcia závislá od strednej hodnoty s parametrom

krivky

 $\epsilon=0.1$ 



(c) Funkcia závislá od strednej hodnoty s parametrom (d) Navrhnutá metóda s parametrami $\epsilon=0.05 \qquad \qquad K=256, \; o=1, \; {\rm a} \; \sigma_d=0.2$ 

Obr. 3.16: Porovnanie metód pri zmenenej pozícii počiatočnej krivky

## 4 Numerické experimenty

V predchádzajúcej kapitole sme uviedli niekoľko navrhnutých úprav pre funkciu homogenity. V praktickej časti diplomovej práce sa sústredíme hlavne na nami navrhnutú funkciu homogenity popísanú v sekcii 3.7 pre metódu automatickej segmentácie. Vybraná metóda dosahovala pri prvotných testoch vizuálne lepšie výsledky pri detegovaní homogénnych oblastí (Obr. 3.15).

Pri numerických experimentoch využívame navrhnutú metódu na segmentáciu satelitnej snímky získanej vďaka programu Copernicus [14] satelitom Sentinel-2. Sústredíme sa na segmentáciu dvoch konkrétnych biotopov zo súboru chránených oblastí Natura 2000, ktorých detailnejší popis je uvedený v nasledujúcej sekcii. Na získanie optimálnych parametrov pre modely sme implementovali algoritmus ladenia parametrov. Po nájdení optimálnych parametrov a na základe ich štatistík navrhujeme odporúčané parametre segmentačného modelu pre každý z vybraných biotopov. Na záver kapitoly uvádzame ukážky vysegmentovaných oblastí získaných použitím nájdených optimálnych parametrov modelu.

## 4.1 Sentinel-2 a Natura 2000

Program Copernicus je program Európskej únie financovaný z verejných zdrojov, vďaka čomu je prevažná väčšina údajov a informácií voľne dostupná a prístupná občanom a organizáciám na celom svete. Jeho hlavným cieľom je monitorovanie Zeme a mnohých ekosystémov na nej, ako aj pripravenosť na prírodné a človekom spôsobené katastrofy v budúcnosti. Na monitorovanie slúži sústava osobitných satelitov známych ako skupina Sentinel [15], ktorých služba začala v roku 2014 vypustením satelitu Sentinel-1A a Európska únia sa zaviazala umiestniť na obežnú dráhu ďalších takmer 20 satelitov.

V našej práci budeme pracovať výhradne s dátami získanými satelitmi z misie Sentinel-2 [15]. Táto misia pozostáva z dvoch aktívnych satelitov Sentinel-2A a Sentinel-2B (obr. 4.1), ktoré boli postupne vypustené na obežnú dráhu 23. júna 2015 a 7. marca 2017, pričom ich



Obr. 4.1: Model satelitov Sentinel-2A a Sentinel-2B

fáza je posunutá o 180° (nachádzajú sa na navzájom opačnej strane planéty). Ich operačná životnosť je plánovaná na 7<sup>1</sup>/4 roku s možnosťou predĺženia na 12 rokov. Satelity obiehajú Zem po obežnej dráhe vo výške 786 km, so sklonom 98.5° a sú schopné zmonitorovať celú Zem raz za 5 dní, čo je užitočné v štúdiách sledujúcich rapídne zmeny na Zemskom povrchu.

Každý zo satelitov obsahuje multispektrálny senzor s 13 kanálmi zaznamenávajúcimi vlnové dĺžky viditeľného svetla, blízkeho infračerveného svetla a infračerveného svetla (Tabuľka 4.1). Najdôležitejšie kanály (červené, zelené, modré a blízke infračervené svetlo) majú rozlíšenie 10 metrov, čo znamená, že jeden pixel reprezentuje plochu  $10 \text{ m} \times 10 \text{ m}$ . Ostatné kanály majú rozlíšenie 20 metrov alebo 60 metrov.

Jednotlivé satelitné snímky sú distribuované ako oblasti rozmerov  $100 \ km \times 100 \ km$ . V našej práci sme sa zameriavali na oblasť s kódom 33UXP z 10.9.2018, v ktorej je zahrnutý región juhozápadného Slovenska, najmä južného Záhoria a horného toku Dunaja na území Slovenska, spolu so severozápadným Rakúskom (Obr. 4.2).

Vo vybranej oblasti bolo botanikmi z Botanického ústavu Slovenskej akadémie vied semiautomaticky [2] vysegmentovaných 23 lužných vŕbovo-topoľových a jelšových lesov (kód biotopu 91E0) a 23 lužných dubovo-brestovo-jaseňových lesov okolo nížinných riek (kód biotopu 91F0), ktoré sú bližšie popísané v tabuľke 4.2 [5]. Tieto segmentácie budú slúžiť ako referenčné krivky pre algoritmus ladenia parametrov.

## DIPLOMOVÁ PRÁCA

#### SvF STUBA

Kanál	Názov (význam)	Vlnová dĺžka	Šírka kanálu	Rozlíšenie
B1	Coastal aerosol (Pobrežný aerosól)	442 nm	21 nm	60 m
B2	Blue (Modré svetlo)	492 nm	66 nm	10 m
B3	Green (Zelené svetlo)	$559\mathrm{nm}$	36 nm	10 m
B4	Red (Červené svetlo)	$664 \mathrm{nm}$	31 nm	10 m
B5	Vegetation classification (Klasifikácia vegetácie)	$704 \mathrm{nm}$	$16~\mathrm{nm}$	20 m
B6	Vegetation classification (Klasifikácia vegetácie)	$740~\mathrm{nm}$	$15 \mathrm{nm}$	20 m
B7	Vegetation classification (Klasifikácia vegetácie)	$781 \mathrm{nm}$	20 nm	20 m
B8	Near infrared (Blízke infračervené svetlo)	833 nm	106 nm	10 m
B	Narrow near infrared	864 nm	21 nm	20 m
Doa	(Úzke pásmo blízkeho infračerveného svetla)	004 IIIII	21 1111	
B9	Water vapour (Vyparovanie vody)	$944~\mathrm{nm}$	$20 \ \mathrm{nm}$	60 m
B10	Short wave infrared - Cloud map (Pokrytie oblačnosťou)	$1375 \mathrm{nm}$	30  mm	60 m
B11	Short wave infrared (Pokrytie snehom a ladom)	$1612 \mathrm{nm}$	$92 \mathrm{nm}$	20 m
B12	Short wave infrared (Pokrytie snehom a ladom)	2197 nm	180 nm	20 m

Tabuľka 4.1: Spektrálne kanály satelitov Sentinel-2

Kód biotopu	91E0	91F0
Názov biotopu	Lužné vŕbovo-topoľové a jelšové lesy	Lužné dubovo-brestovo-jaseňové lesy
		okolo nížinných riek
Označenie biotopu	Mäkký lužný les	Tvrdý lužný les
Charakteristika biotopu	Prirodzené lesy nachádzajúce sa bez-	Prirodzené lesy nachádzajúce sa na
	prostredne pri tokoch, charakterizo-	vyšších, relatívne suchších miestach
	vané pravidelnými záplavami povrcho-	neďaleko tokov charakterizované zried-
	vou vodou alebo zamokrením pod-	kavejšími a kratšími povrchovými zá-
	zemnou vodou. V podraste prevlá-	plavami. V podraste sú prítomné
	dajú druhy znášajúce trvalé alebo pre-	druhy s vysokými nárokmi na obsah
	chodné zamokrenie.	dusíka v pôde.



#### DIPLOMOVÁ PRÁCA

#### SvF STUBA



Obr. 4.2: Satelitná snímka skúmanej oblasti juhozápadného Slovenska z družice Sentinel-2 z dátumu 10.9.2018

## 4.2 Ladenie parametrov

Vďaka poskytnutým referenčným krivkám sme boli schopní ladiť segmentačný model na reálnych biotopoch. Cieľom ladenia bolo nájsť optimálne parametre a rozpoznať ich spoločné vlastnosti pre skúmané typy biotopov. Takýmto postupom chceme určiť sadu odporúčaných parametrov, ktoré môžeme užívateľovi aplikácie NaturaSat nastaviť ako predvolené parametre pre automatickú segmentáciu vybraných biotopov.

Ladenie prebiehalo na optickom kanáli s kódom B3 (Zelené svetlo) kvôli najväčšej výpovednej hodnote o vegetácii a vysokému rozlíšeniu (10 m). Pre každú z dostupných kriviek bola vybraná pozícia v jej približnom strede, kde sme ako počiatočnú krivku použili kružnicu s polomerom 30 m a ako výpočtovú oblasť sme uvažovali štvorcovú oblasť rozmerov  $5 \text{ km} \times 5 \text{ km} (500 \times 500 \text{ px})$  centrovanú na stred počiatočnej krivky. Postup ladenia spočíval v prechádzaní priestorom parametrov a vyberaní množiny najlepších parametrov každej krivky určených pomocou Hausdorffových vzdialeností. Počet časových krokov vývoja bol pre každú krivku iný v závislosti od veľkosti segmentovanej oblasti. Vo väčšine prípadov bol ukladaný každý 50. časový krok, v prípade väčších oblastí bol ukladaný každý 100. časový krok (veľkosť jedného časového kroku numerickej schémy pre model automatickej segmentácie bol nastavený na hodnotu 1).

Za priestor parametrov bol zvolený priestor  $P: P^{K_1} \times P^{\sigma_0} \times P^o \times P^{\sigma_d} \times P^{\delta}$ , kde  $P^{K_1} = \{500, 1000, 2000, 4000, 8000, 16000, 32000, 64000\}$ ,  $P^{\sigma_0} = \{0, 0.5, 1, 1.5, 2, 2.5, 3, 3.5, 4, 4.5, 5\}$ ,  $P^o = \{1, 2, 3, 4, 5, 6, 7, 8, 9\}$ ,  $P^{\sigma_d} = \{0, 0.5, 1, 2, 5, 10, 20, 40, 80\}$  a  $P^{\delta} = \{0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8\}$  pre biotopy 91F0, pričom pri biotopoch 91E0 boli  $P^{K_1}$  a  $P^{\sigma_d}$  upravené na  $P^{K_1} = \{500, 1000, 2000, 4000, 8000, 16000\}$  a  $P^{\sigma_d} = \{0, 0.5, 1, 2, 5, 10, 20\}$ .

## 4.3 Určovanie optimálnych parametrov

Po vypočítaní automatickej segmentácie pre všetky kombinácie z priestoru parametrov P bolo potrebné nájsť najvhodnejšie parametre porovnaním výsledných kriviek (pre každý ukladaný časový krok) s referenčnými krivkami. Výsledná krivka sa nemusí zastaviť na referenčnej krivke, keďže referenčné krivky nemusia vždy ohraničovať celú plochu lesa, ale iba tú časť, kde odborníci z Botanického ústavu vedia s určitosťou povedať, že sa jedná o skúmaný biotop. Preto je potrebné kontrolovať viacero časových krokov vyvíjajúcej sa krivky. Na kvantitatívne porovnanie dvoch kriviek boli použité Hausdorffove vzdialenosti, konkrétne všeobecná (maximová) Hausdorffova vzdialenosť  $d_H$  a takzvaná priemerná Hausdorffova vzdialenosť  $\overline{d}_H$  [2], ktoré definujeme nasledovne

$$d_H(A,B) = \max\left\{\sup_{a \in A} \inf_{b \in B} d(a,b), \sup_{b \in B} \inf_{a \in A} d(a,b)\right\}$$
(4.1)

a

$$\overline{\delta}_H(A,B) = \frac{1}{n} \sum_{i=1}^n \min_{b \in B} d(a_i,b), \ \overline{\delta}_H(B,A) = \frac{1}{m} \sum_{i=1}^m \min_{a \in A} d(a,b_i),$$

$$\overline{d}_H(A,B) = \frac{\overline{\delta}_H(A,B) + \overline{\delta}_H(B,A)}{2},$$
(4.2)

kde d(a,b) je euklidovská vzdialenosť bodov a a b z množiny bodov kriviek  $A = \{a_1, a_2, a_3, \dots, a_n\}$ a  $B = \{b_1, b_2, b_3, \dots, b_m\}.$ 

Následne sme zvlášť pre každú referenčnú krivku zoradili všetky kombinácie parametrov

Parameter Charakteristika	$K_1$	$\sigma_0$	0	$\sigma_d$	δ
Smerodajná odchýlka	3839	0.76	2.63	6.33	0.21
Stredná hodnota	3979	1.82	5.28	4.00	0.37
Minimálna hodnota (0. kvartil)	500	0	1	0	0.1
1. kvartil	2000	2	3	0.5	0.2
Medián (2. kvartil)	2000	2	6	1	0.3
3. kvartil	4000	2	7	2	0.5
Maximálna hodnota (4. kvartil)	16000	5	9	20	0.8
Modus	4000	2	6	2	0.2
Zastúpenie modusu	34.60%	69.98%	25.91%	22.82%	19.40%

Tabuľka 4.3: Štatistické charakteristiky biotopu 91E0

vzostupne podla príslušnej hodnoty priemernej Hausdorffovej vzdialenosti. Za parametre vhodné na ďalšie porovnávanie a štatistické spracovanie boli považované tie parametre, pri ktorých priemerná Hausdorffova vzdialenosť nebola väčšia ako 1.05 násobok najnižšej hodnoty priemernej Hausdorffovej vzdialenosti spomedzi všetkých kombinácií parametrov. Spojením takto vybraných parametrov pre všetky referenčné krivky z daného biotopu vznikla množina optimálnych parametrov, ktorú používame na výpočet vybraných štatistických charakteristík.

Týmto postupom sme dostali výsledných 2336 kombinácii parametrov pre biotop 91E0 a 5111 kombinácii parametrov pre biotop 91F0. Tieto parametre sme štatisticky popísali pomocou strednej hodnoty, mediánovej hodnoty a jednotlivých kvartilov vrátane minimálnej a maximálnej hodnoty, smerodajnej odchýlky, modusu a percentuálneho zastúpenia modusovej hodnoty. Jednotlivé hodnoty sú znázornené v tabuľkách 4.3 a 4.4.

Z tabuliek 4.3 a 4.4 je zrejmé, že na voľbe parametra posunu o (3.9-3.10) pri vytváraní matice opakovaných výskytov výrazne nezáleží, keďže kvartily sú relatívne rovnomerne rozdelené v priestore parametrov. Voľba vplyvu krivosti  $\delta$  (2.2) je silno previazaná s tvarom referenčnej krivky a preto sa nedá zovšeobecniť pre rôzne oblasti skúmaného biotopu.

Naopak, pri citlivosti hranového detektora  $K_1$  (2.4) a veľkosti časového kroku pri filtrácii

Parameter Charakteristika	$K_1$	$\sigma_0$	0	$\sigma_d$	δ
Smerodajná odchýlka	9989	0.88	2.57	28.28	0.23
Stredná hodnota	13670	0.84	4.92	48.33	0.45
Minimálna hodnota (0. kvartil)	500	0	1	1	0.1
1. kvartil	8000	0	3	20	0.2
Medián (2. kvartil)	16000	0.5	5	40	0.5
3. kvartil	16000	1.5	7	80	0.7
Maximálna hodnota (4. kvartil)	64000	5	9	80	0.8
Modus	16000	0	3	80	0.2
Zastúpenie modusu	32.72%	32.60%	12.74%	40.23%	13.44%

Tabuľka 4.4: Štatistické charakteristiky biotopu 91F0

obrázku  $\sigma_0$  (2.6), resp. pri filtrácii diagonály matice opakovaných výskytov  $\sigma_d$  (3.17) dokážeme vybrať odporúčané rozsahy parametrov pre biotopy 91E0 a 91F0.

Na obrázku 4.3 sú znázornené štatistiky z tabuliek pomocou škatuľových grafov. Na základe štatistík a tvaru škatuľových grafov vieme určiť odporúčané hodnoty pre parameter citlivosti hranového detektora  $K_1$  pre segmentáciu oblastí biotopu 91E0 na hodnoty v rozmedzí (2000 – 4000). Pre segmentáciu oblastí biotopu 91F0 odporúčame na základe výsledkov hodnoty z intervalu (8000 – 16000). Takisto môžeme vidieť, že jednoznačne najčastejšie vyskytujúcou sa hodnotou časového kroku pri filtrácii obrázku pre biotopy 91E0 je 2, pričom pre biotopy 91F0 sa ideálna hodnota parametru pohybuje v mierne nižších hodnotách v rozmedzí (0 – 1.5). Najvýraznejší rozdiel je vidieť pri parametri časového kroku pre vyhladenie diagonály matice opakovaných výskytov, ktorý je z intervalu (0.5 – 2) pre biotopy 91E0, zatiaľ čo pre biotopy 91F0 sa táto hodnota pohybuje rádovo v desiatkach. Tento značný rozdiel je pravdepodobne spôsobený väčšou členitosťou mäkkých lužných lesov, pri ktorých je dôležité zachovať menšie zmeny medzi druhmi stromov, zatiaľ čo väčšia homogénnosť tvrdých lužných lesov umožňuje filtrovať väčším časovým krokom.

#### SvF STUBA



Obr. 4.3: Škatuľové grafy vybraných kriviek

## 4.4 Ukážky výsledkov automatickej segmentácie

Na vizualizovanie výsledných segmentácií získaných automatickou segmentáciou s použitím navrhovanej funkcie homogenity 3.7 boli vybrané 3 výsledné segmentácie biotopov 91E0 a 3 výsledné segmentácie biotopov 91F0 s nízkou priemernou a maximovou Hausdorffovou vzdialenosťou voči referenčným krivkám. Na obrázkoch výsledných kriviek nie sú zobrazené vnútorné krivky, ktoré vznikli ohraničením vnútorných štruktúr.

#### 4.4.1 Mäkké lužné lesy

Prvým testovaným biotopom typu 91E0 boli Dunajské luhy juhozápadne od obce Bodíky v okrese Dunajská Streda. V tomto prípade sa ladením dospelo ku najvhodnejším parametrom  $K_1 = 2000, \sigma_0 = 0.5, o = 7, \sigma_d = 2, a \delta = 0.3$ , pričom výsledná priemerná Hausdorrfova vzdialenosť medzi výslednou krivkou a referenčnou krivkou v časovom kroku 1500 bola  $\overline{d}_H = 3.4$  m a maximová Hausdorffova vzdialenosť bola  $d_H = 15.3$  m. Obe krivky sú znázornené na obrázku 4.4 tyrkysovou (vyvinutá krivka) a červenou (referenčná krivka) farbou. Na ľavom obrázku sú znázornené spomenuté krivky spolu so zeleným kanálom satelitnej snímky a na pravom obrázku spolu s funkciou rýchlosti rozpínania krivky (2.8). Optimálne parametre v tomto prípade neboli parametre z odporučených intervalov. Z tohoto dôvodu bola evolúcia testovaná aj za využitia navrhovaných parametrov  $K_1 = 2000$ ,  $\sigma_0 = 2$ , o = 5,  $\sigma_d = 2$ , a  $\delta = 0.1$ , pričom boli dosiahnuté vzdialenosti  $\overline{d}_H = 4.8$  m a  $d_H = 27.9$  m v časovom kroku 1850, čo je vzhľadom na rozlíšenie vstupných dát stále vhodný výsledok s chybou menšou ako 1 px pre priemernú Hausdorffovu vzdialenosť (resp. 3 px, pre maximovú vzdialenosť).



Obr. 4.4: Dunajské luhy pri obci Bodíky - ostrov (červená - referenčná krivka, tyrkysová - výsledná krivka)

Druhou testovanou oblasťou biotopu 91E0 (Obr. 4.5) bol neďaleký les opäť patriaci pod Chránenú krajinnú oblasť Dunajské luhy, tentokrát priamo susediaci s obydliami, pričom môžeme vidieť, že táto skutočnosť neovplyvnila výslednú krivku, ktorá stále kopíruje hranice segmentovaného lesa. Optimálnymi parametrami v tomto prípade boli  $K_1 = 2000$ ,  $\sigma_0 = 1$ , o = 4,  $\sigma_d = 5$ , a  $\delta = 0.3$ , pričom vzdialenosti mali v časovom kroku 1500 hodnoty  $\overline{d}_H = 3.9$  m, resp.  $d_H = 20.2$  m. Pri využití odporúčaných parametrov  $K_1 = 2000$ ,  $\sigma_0 = 2$ , o = 6,  $\sigma_d = 2$ , a  $\delta = 0.3$  boli v časovom kroku 1650 dosiahnuté vzdialenosti  $\overline{d}_H = 4.4$  m a  $d_H = 26.9$  m, čo je podobne ako v predchádzajúcom prípade uspokojivý výsledok.



Obr. 4.5: Dunajské luhy pri obci Bodíky - biotop 2 (červená - referenčná krivka, tyrkysová - výsledná krivka)

Poslednou oblasťou testovaného biotopu 91E0 bola časť územia európskeho významu Bratislavské luhy, Slovanský ostrov pri mestskej časti Bratislava Devín (Obr. 4.6). Optimálnymi parametrami boli  $K_1 = 4000$ ,  $\sigma_0 = 2$ , o = 6,  $\sigma_d = 0$ , a  $\delta = 0.2$  so vzdialenosťami  $\overline{d}_H = 9.4$  m a  $d_H = 41.5$  m v časovom kroku 4950.



Obr. 4.6: Slovanský ostrov pri mestskej časti Bratislava Devín (červená - referenčná krivka, tyrkysová - výsledná krivka)

Vidíme, že vo všetkých prípadoch bola priemerná Hausdorrfova vzdialenosť medzi výslednými a referenčnými krivkami menšia ako rozlíšenie satelitov Sentinel-2 pre zelený kanál (10 m), čo môžeme hodnotiť ako veľmi pozitívny výsledok. Najväčšiu odchýlku môžeme nájsť v biotope Slovanský ostrov (Obr. 4.6) v severnej časti ostrova, či už na hranici susediacej s obydliami,

#### SvF STUBA

#### DIPLOMOVÁ PRÁCA

alebo s riekou. Po bližšom skúmaní snímky s väčším rozlíšením z približne rovnakého časového obdobia v softvéri Google Earth Pro [8] (Obr. 4.7) môžeme usúdiť, že táto odchýlka nie je nedostatkom navrhnutej metódy. Po porovnaní snímok je vidieť, že výsledná krivka kopíruje hranice biotopu presnejšie ako referenčná krivka, ktorá nezachytila miesta vtoku a výtoku ramena Dunaja cez oblasť biotopu.



Obr. 4.7: Slovanský ostrov v softvéri Google Earth Pro (dátum snímky 7/2018)

#### 4.4.2 Tvrdé lužné lesy

Prvou testovanou oblasťou biotopu 91F0 je lokalita Ciglát v katastrálnom území obce Moravský Svätý Ján v okrese Senica znázornená na obrázkoch 4.8. Optimálne parametre boli v tomto prípade  $K_1 = 16000$ ,  $\sigma_0 = 0$ , o = 9,  $\sigma_d = 20$ , a  $\delta = 0.5$ , pričom vzdialenosti medzi kontrolnou krivkou (červená) a vyvinutou krivkou (tyrkysová) v časovom kroku 2900 boli  $\overline{d}_H = 6.6$  m a  $d_H = 47.3$  m. Vidíme, že až na mierne nedostatky v juhovýchodnom cípe lesa, kde je dosiahnutá maximálna odchýlka, krivka veľmi dobre kopíruje hranice biotopu.

Druhou oblasťou biotopu 91F0 bol Mokrý les pri obci Vysoká pri Morave v okrese Malacky (Obr. 4.9), kde sa pri najvhodnejších parametroch  $K_1 = 16000$ ,  $\sigma_0 = 1.5$ , o = 9,  $\sigma_d = 40$ , a  $\delta = 0.5$  v časovom kroku 6800 dosiahli odchýlky  $\overline{d}_H = 11.0$  m, resp.  $d_H = 97.3$  m. Okrem miernych nedostatkov v severnej časti lesa dávame opäť do pozoru citlivosť metódy na zmeny vo vnútornej štruktúre segmentovej oblasti, kde opäť za pomoci softvéru Google Earth Pro



Obr. 4.8: Lokalita Ciglát nedaľeko obce Moravský Svätý Ján (červená - referenčná krivka, tyrkysová - výsledná krivka)

[9] vidíme na obrázku 4.10, že výsledná krivka na rozdiel od referenčnej čiastočne zachytila aj odlesnenú časť biotopu.



Obr. 4.9: Mokrý les pri obci Vysoká pri Morave (červená - referečná krivka, tyrkysová - výsledná krivka)

Poslednou oblasťou biotopu kategórie 91F0 bol chránený areál Dedova jama neďaleko obce Červeník v okrese Hlohovec. Optimálnymi parametrami boli hodnoty  $K_1 = 32000$ ,  $\sigma_0 = 1$ , o = 5,  $\sigma_d = 80$ , a  $\delta = 0.3$ , pričom na obrázku 4.11 môžeme vidieť, že aj v tomto prípade sú dosiahnuté odchýlky od kontrolnej krivky v časovom kroku 3400 nízke s hodnotami  $\overline{d}_H = 6.4$  m a  $d_H = 21.0$  m.



Obr. 4.10: Mokrý les v softvéri Google Earth Pro (dátum snímky 6/2019)

## 4.5 Modifikácia modelu pre 3 kanály

Doterajší model [13] popisoval vývoj uzavretej Lagrangeovskej krivky na základe vstupného jednokanálového obrázku  $I^0: U \to [0,1]$ . Aj keď obrázok v odtieňoch šedi (angl. greyscale image) udáva základné informácie o vizualizovaných údajoch, nie vždy sú jednorozmerné dáta postačujúce. Z tohto dôvodu modifikujeme model spomenutý v kapitole 2 na prácu s tromi kanálmi, teda na základe obrázku  $I^0: U \to [0,1]^3$ .

Všeobecný zápis vývoja krivky a vektorového poľa ostáva nezmenený od rovníc $(2.1) {-} (2.2)$ v tvare

$$\frac{\partial \mathbf{x}}{\partial t} = \mathbf{V}(\mathbf{x}, t), \tag{4.3}$$

resp.

$$\mathbf{V}(\mathbf{x},t) = (1 - \lambda(t))g_2(\mathbf{x})\mathbf{N}(\mathbf{x},t) - \lambda(t)\nabla g_1(\mathbf{x}) - \delta(t)k(\mathbf{x},t)\mathbf{N}(\mathbf{x},t).$$
(4.4)

Modifikácie teda nastávajú vnútri funkcií  $g_1(\mathbf{x})$  a  $g_2(\mathbf{x})$ . Jedna zo zmien nastáva pri aplikovaní konvolúcie na obrázok, keďže pracujeme s trojkanálovým obrazom. Konvolúcia je aplikovaná na každý farebný kanál  $U_R, U_G, U_B$  ( $U = \{U_R, U_G, U_B\}$ , kde  $U_R, U_G, U_B \rightarrow [0, 1]$ ) zvlášť, pričom následne jednotlivé kanály skombinujeme a vytvoríme upravený trojkanálový obrázok.



Obr. 4.11: Chránený areál Dedova jama neďaleko obce Červeník (červená - referenčná krivka, tyrkysová - výsledná krivka)

Ďalšia zmena nastáva v hranovom detektore  $g_1(\mathbf{x})$  (2.3), kde modifikujeme funkciu (2.4) na tvar

$$g(s, K_1) = \frac{1}{1 + K_1\left(\sum_{i=1}^3 \frac{s_i^2}{3}\right)} \quad a \quad s(\mathbf{x}) = \left|\nabla\left(G_{\sigma_0} * I^0\right)\right|(\mathbf{x}).$$
(4.5)

Úprava nastáva kvôli tomu, že funkcia *s* je rôzna pre každý kanál, preto jednokanálovú verziu  $s^2$  nahrádzame  $\left(\sum_{i=1}^3 \frac{s_i^2}{3}\right)$ , kde majú na výsledný hranový detektor rovnaký, tretinový vplyv všetky kanály.

#### 4.5.1 Modifikácia funkcie homogenity

Posledná zmena v modeli nastáva vo funkcii rýchlosti rozpínania krivky  $g_2(x)$ , kde funkciu  $g_1(x)$  upravíme vyššie spomenutým spôsobom a prahovaciu funkciu  $H(\mathbf{x})$  upravíme na tvar využívajúci tri kanály. Keďže sa posledný testovaný model 3.7 javí ako najvhodnejší, ukážeme si modifikáciu len na ňom.

Podobne ako pri konvolúcii, aj tu spočiatku separujeme jednotlivé kanály a matice opakovaných výskytov počítame na každom kanáli zvlášť. Matice opäť zredukujeme na jednorozmerné pole premietaním na diagonálu, ktorú následne vyhladíme rovnicou vedenia tepla.

Diagonála každého kanálu má pri farebnom obrázku iný tvar, preto je pravdepodobné, že jednotlivé diagonály budú mať rôzny počet lokálnych miním/prahov. Dôsledkom toho je nutnosť upraviť Algoritmus 6 vytvárajúci výslednú prahovú funkciu  $H(\mathbf{x})$  na tvar v Algoritme 7.

Algoritmus 7 Vytvorenie výslednej prahovej funkcie pre tri kanály

1: Vstup: Obrázok hodnôt funkcie homogénnych oblastí  $W = [w_{i,j}]^3_{M \times N}$ a počiatočná krivka C2:  $tmp \leftarrow tuple(\{\},3)$ 3: for all  $w_{i,j} \in C$  do if  $\{w_{i,j}^R, w_{i,j}^G, w_{i,j}^B\} \notin tmp$  then 4:  $tmp.append(\{w_{i,j}^R, w_{i,j}^G, w_{i,j}^B\})$ 5:end if 6: 7: end for 8: for all  $w_{i,j} \in W$  do  $H(i,j) \leftarrow \begin{cases} 1 & \text{ak } \{w_{i,j}^R, w_{i,j}^G, w_{i,j}^B\} \in tmp \\ 0 & \text{ak } \{w_{i,j}^R, w_{i,j}^G, w_{i,j}^B\} \notin tmp \end{cases}$ 9: 10: **end for** 11: return H

Inými slovami, algoritmus upravíme tak, aby hľadal usporiadané trojice hodnôt  $\{p_{i,j}^R, p_{i,j}^G, p_{i,j}^B\}$ v počiatočnej krivke, ktorým následne priradí hodnotu 1 a všetkým ostatným trojiciam priradí hodnotu 0.

Upravený algoritmus bol testovaný na testovacom trojfarebnom obrázku 4.12(a) s parametrami $o=1,\,\sigma_0=0.5$  a  $\sigma_d=2.$ 



(c) Funkcia homogenity  $H(\mathbf{x})$ 

Obr. 4.12: Prahovanie diagonály matice opakovaných výskytov v troch kanáloch

#### 4.5.2Ukážky výsledkov automatickej segmentácie upraveného modelu

Na vizualizovanie výsledných segmentácií získaných automatickou segmentáciou s použitím upraveného evolučného modelu pre tri farebné kanály boli vybrané 2 biotopy, pričom jeden bol typu 91F0 (tvrdý lužný les) a jeden typu 91E0 (mäkký lužný les). Zvolené 3 optické kanály boli kanály B2, B3 a B4, teda modré, zelené a červené svetlo, ktorých kombináciou vznikne obraz vo viditeľnom spektre.

#### Tvrdý lužný les

Za reprezentanta tvrdých lužných lesov bolo vybrané územie európskeho významu Rozporec v katastrálnom území obce Vysoká pri Morave v okrese Malacky. Pri zadaných parametroch  $K_1=16000,\ \sigma_0=0.5,\ o=1,\ \sigma_d=20,$ a $\delta=0.6$ boli dosiahnuté odchýlky od referenčnej krivky v časovom kroku 4500 s hodnotami $\overline{d}_H=17.3~{\rm m}$  <br/>a $d_H=68.9~{\rm m}.$ Výsledky evolúcie krivky sú vizualizované na obrázku 4.13 vľavo na farebnom obrázku vytvorenom z použitých kanálov B2, B3 a B4 a vpravo na výslednej funkcii rýchlosti rozpínania krivky.



Obr. 4.13: Lokalita Rozporec neďaleko obce Vysoká pri Morave (červená - referenčná krivka, tyrkysová - výsledná krivka)

#### Mäkký lužný les

Testovaným biotopom typu 91E0, teda mäkkých lužných lesov boli Dunajské luhy neďaleko obce Bodíky v okrese Dunajská Streda. Uspokojivý výsledok, zobrazený na obrázku 4.14, bol dosiahnutý pri zadaných parametroch  $K_1 = 2000$ ,  $\sigma_0 = 1.5$ , o = 1,  $\sigma_d = 2$ , a  $\delta = 0.8$ , pričom boli dosiahnuté odchýlky s hodnotami  $\overline{d}_H = 13.0$  m a  $d_H = 61.3$  m v 3850. časovom kroku.



Obr. 4.14: Dunajské luhy neďaleko obce Bodíky (červená - referenčná krivka, tyrkysová - výsledná krivka)

Lokalita	Typ biotopu	Kanály	Hodnoty parametrov	Hausdorffove vzdialenosti
Bozporec	91F0	B2 B3 B4	$K_1 = 16000, \ \sigma_0 = 0.5,$	$\overline{d}_H = 17.3 \mathrm{m}$
Itozporce	511.0	D2, D3, D4	$o = 1, \ \sigma_d = 20, \ \delta = 0.6$	$d_H = 68.9 \text{ m}$
Bogporoc	01F0	B3	$K_1 = 16000, \ \sigma_0 = 1,$	$\overline{d}_H = 18.3 \mathrm{m}$
Rozporec	9110	00	$o = 5, \ \sigma_d = 20, \ \delta = 0.4$	$d_H = 69.8 \text{ m}$
Dunniská luhy	01F0	B2 B3 B4	$K_1 = 2000, \ \sigma_0 = 1.5,$	$\overline{d}_H = 13.0 \text{ m}$
	91E0	$D_2, D_3, D_4$	$o=1,\ \sigma_d=2,\ \delta=0.8$	$d_H = 61.3 \text{ m}$
Dunajská luby	01F0	D3	$K_1 = 1000, \ \sigma_0 = 2,$	$\overline{d}_H = 20.1 \text{ m}$
	91E0	00	$o=2,\ \sigma_d=2,\ \delta=0.4$	$d_H = 151.5 \text{ m}$

Tabuľka 4.5: Porovnanie evolučných modelov na skúmaných biotopoch

#### Porovnanie s pôvodným modelom

Z obrázkov 4.13 a 4.14 vidíme, že upravený evolučný model pre 3 kanály je schopný pracovať dostatočne dobre. Otázkou je, či sú dosiahnuté výsledky porovnateľné alebo dokonca lepšie ako výsledky dosiahnuté evolúciou pôvodným modelom. Z tohoto dôvodu boli na dvoch skúmaných biotopoch vyladené parametre pre kanál B3 (Zelené svetlo) a ich výsledky boli porovnané pomocou Hausdorffových vzdialeností (4.1)-(4.2).

V tabuľke 4.5 vidíme, že nájdené vyladené optimálne parametre pre jednokanálový evolučný model neboli príliš odlišné od ručne nájdených parametrov pre trojkanálový model. To môže znamenať, že optimálne parametre sa výrazne nemenia bez ohľadu na výber optického kanálu, alebo kombinácie optických kanálov. Ďalej môžeme vidieť, že pri skúmanom biotope 91F0 (tvrdý lužný les) nedošlo pri zakomponovaní dodatočných dvoch optických kanálov ku značnému zlepšeniu, pretože aj priemerná aj maximová Hausdorffova vzdialenosť sa zlepšila len o 1 meter, čo je výrazne menej ako rozlíšenie senzorov satelitov Sentinel-2 pre použité optické kanály (10 metrov). Pri skúmanom biotope mäkkých lužných lesov už bolo zlepšenie výraznejšie, kde sa priemerná Hausdorffova vzdialenosť znížila o 35% a maximová vzdialenosť o viac ako polovicu.

Rozdiely medzi porovnávanými modelmi na skúmaných biotopoch sú vizualizované na obrázku 4.15, kde sú výsledné vyvinuté krivky pôvodného (zelená krivka) a upraveného modelu

#### SvF STUBA

#### DIPLOMOVÁ PRÁCA

(tyrkysová krivka) zobrazené spolu s referenčnými krivkami (červená krivka). Na pravom obrázku je znázornený použitý biotop 91F0, kde sa nám potvrdili výsledky Hausdorffových vzdialeností, pretože žiaden z evolučných modelov nedosahuje výrazne lepšie výsledky. Na ľavom obrázku sú znázornené výsledné krivky získané evolučnými modelmi na biotope typu 91E0. V tomto prípade je zlepšenie zjavné najmä v pravej časti biotopu, kde bol pôvodný model zastavený na mierne svetlejšej časti lesa, zatiaľ čo upravený model túto medzeru prekonal a zastavil sa až na hranici biotopu.



Obr. 4.15: Porovnanie upraveného modelu s pôvodným (červená - referenčná krivka, tyrkysová - výsledná krivka upraveného trojkanálového modelu, zelená - výsledná krivka pôvodného modelu)

## 5 Záver

V diplomovej práci sme sa zaoberali najmä návrhom nových metód automatickej segmentácie satelitných snímok, konkrétne návrhom alternatívnych definícií funkcie homogenity z článku [13]. Od jednoduchých návrhov založených na štatistických charakteristikách získaných z intenzít segmentovaných dát z vnútra počiatočnej krivky, postupujeme k návrhom funkcie homogenity založených na lokálnych a globálnych prahovacích metódach. Získané znalosti využívame na definíciu vlastnej funkcie homogenity, ktorá je založená na prahovaní diagonály matice opakovaných výskytov.

Využitím matice opakovaných výskytov aplikovanej na segmentované dáta sa nám podarilo úpravou jej diagonály identifikovať rozdielne homogénne oblasti. Pomocou takto detegovaných oblastí a pozície počiatočnej krivky vieme definovať funkciu homogenity, ktorá v modeli automatickej segmentácie riadi expanziu segmentačnej krivky.

Navrhované modifikácie metódy boli implementované v jazyku C++ ako rozšírenie softvéru NaturaSat [2]. Navrhnutú metódu prahovania diagonály matice opakovaných výskytov sme v numerickom experimente za pomoci expertov z Botanického ústavu Slovenskej akadémie vied úspešne otestovali. Automatickou segmentáciou oblastí na satelitnej snímke sme pomocou algoritmu ladenia parametrov našli rozmedzie odporúčaných parametrov, ktoré môžu pomôcť užívateľovi pri segmentácií vybraného biotopu.

Druhou časťou diplomovej práce bol návrh modifikácie modelu automatickej segmentácie z článku [13] na prácu s tromi optickými kanálmi. Upravený model bol v numerickom experimente porovnaný s modelom z článku [13] pri využití navrhnutej metódy prahovania diagonály matice opakovaných výskytov.

Ďalším smerom výskumu môže byť návrh optimalizačného algoritmu pre parametre modelu (4.4), prípadne návrh prídavného umelého optického kanálu, ktorý môže pomôcť lepšiemu rozlíšeniu umelých monokultúr, ktoré nie sú súčasťou Natura 2000, od chránených prirodzených lesov.

## Zoznam použitej literatúry

- Narendra Ahuja a Azriel Rosenfeld. "A Note on the Use of Second-Order Gray-Level Statistics for Threshold Selection". In: *IEEE Transactions on Systems, Man, and Cybernetics* 8.12 (1978), s. 895–898. DOI: 10.1109/TSMC.1978.4309892.
- [2] Martin Ambroz, Michal Kollár a Karol Mikula. "Semi-implicit scheme for semi-automatic segmentation in NaturaSat software". In: *Proceedings of the Conference Algoritmy* (2020), s. 171-180. URL: http://www.iam.fmph.uniba.sk/amuc/ojs/index.php/algoritmy/article/view/1579.
- [3] Martin Ambroz et al. "Numerical modeling of wildland surface fire propagation by evolving surface curves". In: Advances in Computational Mathematics 45.2 (apr. 2019), s. 1067–1103. ISSN: 1572-9044. DOI: 10.1007/s10444-018-9650-4. URL: https://doi.org/10.1007/s10444-018-9650-4.
- [4] Martin Balažovjech et al. "Lagrangean method with topological changes for numerical modelling of forest fire propagation". In: sept. 2012.
- [5] Biotopy NATURA 2000. http://www.sopsr.sk/natura/index1.php?p=4&sec=13. Navštívené: 2021-01-22.
- [6] Wilhelm Burger a Mark J. Burge. Principles of Digital Image Processing. Undergraduate Topics in Computer Science. Springer-Verlag London, 2013. ISBN: 978-1-84882-918-3.
   DOI: 10.1007/978-1-84882-919-0.
- [7] Chein-I Chang et al. "A relative entropy-based approach to image thresholding". In: *Pattern Recognition* 27.9 (1994), s. 1275-1289. ISSN: 0031-3203. DOI: https://doi.org/ 10.1016/0031-3203(94)90011-6. URL: https://www.sciencedirect.com/science/ article/pii/0031320394900116.
- [8] Google Earth Pro V 7.3.3.7786. Slovanský ostrov, Bratislava, Slovenská republika. 48° 10' 13.54"N, 16° 59' 10.27"E, Výška pohľadu 626m, Dátum snímky 7/2018. Maxar Technologies. https://www.google.sk/intl/sk/earth/.

- [9] Google Earth Pro V 7.3.3.7786. Vysoká pri Morave, Slovenská republika. 48° 19' 53.97"N,
   16° 57' 32.94"E, Výška pohľadu 901m, Dátum snímky 6/2019. Maxar Technologies.
   https://www.google.sk/intl/sk/earth/.
- [10] Jan J. Koenderink. "The structure of images". In: *Biological Cybernetics* 50.5 (aug. 1984),
   s. 363-370. ISSN: 1432-0770. DOI: 10.1007/BF00336961. URL: https://doi.org/10.1007/BF00336961.
- [11] Randall J. LeVeque. Finite Difference Methods for Ordinary and Partial Differential Equations: Steady-Stade and Time-Dependent Problems. Philadelphia, PA : Society for Industrial a Applied Mathematics, 2007, s. 3–11. ISBN: 978-0-898716-29-0.
- [12] Karol Mikula a Daniel Ševčovič. "Evolution of Plane Curves Driven by a Nonlinear Function of Curvature and Anisotropy". In: SIAM Journal on Applied Mathematics 61.5 (2001), s. 1473–1501. ISSN: 00361399. URL: http://www.jstor.org/stable/3061840.
- [13] Karol Mikula et al. "An automated segmentation of NATURA 2000 habitats from Sentinel-2 optical data". In: Discrete & Continuous Dynamical Systems - S 14 (jan. 2018). DOI: 10.3934/dcdss.2020348.
- [14] The Copernicus programme. https://www.copernicus.eu/en/about-copernicus. Navštívené: 2021-03-06.
- [15] The Copernicus Sentinel-2 mission. https://sentinel.esa.int/web/sentinel/ missions/sentinel-2. Navštívené: 2021-02-11.
- [16] Llewellyn Hilleth Thomas. "Elliptic Problems in Linear Differential Equations over a Network". In: Watson Sci. Comput. Lab Report, Columbia University, New York (1949).