



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

SEGMENTACE MÍŠNÍHO KANÁLU A MEZIOBRATLOVÝCH PLOTÉNEK V MRI DATECH

SEGMENTATION OF THE CORD CANAL AND INTERVERTEBRAL DISCS IN MRI DATA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Martin Koban

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Roman Jakubíček

BRNO 2018

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Martin Koban

ID: 185950

Ročník: 3

Akademický rok: 2017/18

NÁZEV TÉMATU:

Segmentace míšního kanálu a meziobratlových plotének v MRI datech

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou zpracování objemových MRI obrazů, zejména segmentačních technik. Prostudujte anatomii osového skeletu - páteře. 2) Zpracujte literární rešerši na danou problematiku. Vyhledejte volně dostupné databáze objemových MRI dat vhodné pro segmentaci intervertebrálních disků a míšního kanálu. 3) Navrhněte vhodné postupy pro segmentaci míšního kanálu a jednotlivých intervertebrálních disků. 4) Realizujte navrženou metodu segmentace ve vhodném programovém prostředí. 5) Otestujte navržený algoritmus na veřejně dostupné databázi a proveďte kvantitativní zhodnocení výsledků zakládající se na dostupnosti „ground truth“ segmentace. 6) Diskutujte dosažené výsledky a možnosti využití segmentačního algoritmu v CAD systémech.

DOPORUČENÁ LITERATURA:

[1] JAN, Jiří. Medical image processing, reconstruction and restoration: concepts and methods. Boca Raton: Taylor & Francis, 2006. Signal processing and communications, 24. ISBN 0-8247-5849-8.

[2] CHEN, Cheng, Daniel BELAVY, Weimin YU, Chengwen CHU, Gabriele ARMBRECHT, Martin BANSMANN, Dieter FELSEBERG a Guoyan ZHENG. Localization and Segmentation of 3D Intervertebral Discs in MR Images by Data Driven Estimation. IEEE Transactions on Medical Imaging [online]. 2015, 34(8), 1719-1729.

Termín zadání: 5.2.2018

Termín odevzdání: 25.5.2018

Vedoucí práce: Ing. Roman Jakubíček

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Práca sa venuje vývoju metódy pre segmentáciu spinálneho kanálu a intervertebrálnych diskov v objemových MRI dátach. Cieľom je čo najvyšší stupeň automatizácie postupu a presnosť umožňujúca spoľahlivé kvantitatívne hodnotenie výsledkov. Základ segmentačného algoritmu tvorí model náhodnej prechádzky v kombinácii so špecifickou metódou aktívnych kontúr formulovanou prostredníctvom konceptu level set. Navrhnutý postup je testovaný na databáze trojrozmerných T2-váhovaných MRI snímok, ktorej súčasťou je aj referenčná manuálna segmentácia intervertebrálnych diskov.

KLÚČOVÉ SLOVÁ

Segmentácia, spinálny kanál, intervertebrálne disky, MRI, náhodná prechádzka, aktívne kontúry, level set

ABSTRACT

The concern of this thesis is development of the method for the spinal canal and intervertebral discs segmentation in volume MRI data. The primary aim is to achieve the highest possible level of automation and accuracy allowing for reliable quantitative evaluation of the results. The algorithm is based on the random walk model in combination with a specific active contour method formulated through level set concept. The proposed approach is tested using a database of three-dimensional T2-weighted MR images, which also contains referential manual segmentation of intervertebral discs.

KEYWORDS

Segmentation, spinal canal, intervertebral discs, MRI, random walk, active contours, level set

KOBAN, Martin. *Segmentace míšního kanálu a meziobratlových plotének v MRI datech*. Brno, 2018, 57 s. Bakalárska práca. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedúci práce: Ing. Roman Jakubíček

VYHLÁSENIE

Vyhlasujem, že som svoju bakalársku prácu na tému „Segmentácia spinálneho kanálu a intervertebrálnych diskov v MRI dátach“ vypracoval samostatne pod vedením vedúceho bakalárskej práce, s využitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na jej konci.

Ako autor uvedenej bakalárskej práce ďalej vyhlasujem, že v súvislosti s jej vytvorením som neporušil autorské práva tretích osôb, najmä som nezasiahol nedovoleným spôsobom do cudzích autorských práv osobnostných a/alebo majetkových a som si plne vedomý následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona Českej republiky č. 121/2000 Sb., o práve autorskom, o právach súvisiacich s právom autorským a o zmene niektorých zákonov (autorský zákon), v znení neskorších predpisov, vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia časti druhej, hlavy VI. diel 4 Trestného zákoníka Českej republiky č. 40/2009 Sb.

Brno

.....

podpis autora

POĎAKOVANIE

Týmto by som rád vyjadril vďaku pánovi Ing. Romanovi Jakubíčkovi za odborné vedenie, podnetné návrhy a konštruktívne pripomienky k práci.

Brno

.....

podpis autora

OBSAH

Úvod	9
1 Teoretické východiská	11
1.1 Zobrazovanie magnetickou rezonanciou	11
1.2 Formáty medicínskych obrazových dát	12
1.2.1 DICOM	12
1.2.2 NIFTI	12
1.3 Zobrazovanie osového skeletu	13
1.3.1 Anatómia chrbtice	13
1.3.2 Špecifiká zobrazovania chrbtice metódou MRI	14
1.4 Segmentácia obrazu	14
1.4.1 Model náhodnej prechádzky pre segmentáciu obrazov	15
1.4.2 Metóda aktívnych kontúr bez hranovej funkcie	19
1.4.3 Metóda rozvodí	22
1.5 Morfologické operácie	22
1.5.1 Erózia	23
1.5.2 Dilatácia	24
1.5.3 Distančná mapa	24
2 Súvisiace práce	25
3 Programová realizácia	28
3.1 Segmentácia spinálneho kanálu	28
3.1.1 Predspracovanie	28
3.1.2 Stanovenie inicializačných semienok	29
3.1.3 Segmentácia v inicializačnom úseku	30
3.1.4 Propagácia segmentácie	33
3.1.5 Vyhladenie	34
3.2 Segmentácia intervertebrálnych diskov	35
3.2.1 Stanovenie inicializačných semienok	35
3.2.2 Aplikácia 3D segmentačného algoritmu	40
3.2.3 Odstránenie nedostatkov 3D segmentácie	40
3.2.4 Vyhladenie	42
4 Výsledky a diskusia	43
4.1 Segmentácia spinálneho kanálu	43
4.2 Segmentácia intervertebrálnych diskov	47

5 Záver	52
Literatúra	53
Zoznam symbolov, veličín a skratiek	57

ZOZNAM OBRÁZKOV

1.1	Analógia medzi elektrickými obvodmi a modelom náhodnej prechádzky	17
1.2	K objasneniu princípu metódy aktívnych kontúr bez hranovej funkcie	20
3.1	Základná štruktúra navrhnutého algoritmu.	28
3.2	Algoritmus pre segmentáciu spinálneho kanálu	29
3.3	Inicializačné semienka pre segmentáciu spinálneho kanálu	30
3.4	Binárna maska – výstup segmentačného algoritmu	32
3.5	Algoritmus pre segmentáciu IVD	36
3.6	Oblasť pre stanovenie inicializačných semienok IVD	36
3.7	K stanoveniu inicializačných semienok pre IVD 1	37
3.8	K stanoveniu inicializačných semienok pre IVD 2	39
3.9	Nedostatky 3D segmentácie IVD	41
4.1	Segmentácia spinálneho kanálu pri správnom umiestnení semienok . .	44
4.2	Segmentácia spinálneho kanálu pri nevhodnom umiestnení semienok .	44
4.3	K vplyvu metódy aktívnych kontúr bez hranovej funkcie na segmentáciu	45
4.4	Nedostatky segmentácie spinálneho kanálu 1	46
4.5	Segmentácia vychýleného spinálneho kanálu	46
4.6	Nedostatky segmentácie spinálneho kanálu 2	47
4.7	Nedostatky stanovenia inicializačných semienok pre IVD	48
4.8	Ukážka výsledku segmentácie IVD	48
4.9	K významu vyhladenia segmentovaných IVD	49
4.10	3D objekty ako výstup segmentácie IVD	50

ÚVOD

Jedným zo základných kameňov súčasnej medicíny sú nepochybne metódy anatomickeho a funkčného zobrazovania ľudského organizmu a príslušné zobrazovacie systémy využívané v klinickej praxi. Charakteristikou moderných diagnostických metód nie je len pokročilá technológia zberu dát, ale aj ich kvalitné spracovanie, ktoré je podkladom pre korektnú interpretáciu. Toto spracovanie je v súčasnosti z podstatnej časti zabezpečené prostredníctvom informačných technológií a v oblasti obrazových dát predstavuje širokú škálu metód zlepšujúcich informačnú výťažnosť obrazu či vykonávajúcich špecifické operácie, ktoré umožňujú automatizáciu rutinných manuálnych úkonov (napr. segmentáciu alebo detekciu anatomických útvarov) a získanie informácií pre kvalitatívne a kvantitatívne hodnotenia výsledkov. Významne sa rozšírili aj možnosti následnej analýzy dát, napr. v oblasti onkológie pre detekciu nádorov, sledovanie ich vývoja či odozvy na liečbu.

S príchodom tomografických zobrazovacích systémov do medicíny sa zmenili aj nároky na spracovanie medicínskych obrazových dát. Zjavne nastáva posun od dvojrozmerných výstupov klasických zobrazovacích modalít k trojrozmerným, t.j. objemovým dátam. Práca s týmito údajmi častokrát znamená použitie komplexnejších a výpočtovo náročnejších metód, rovnako však prináša veľké množstvo nových možností pre získanie cenných diagnostických informácií zo špecifických výstupov. Jednou z týchto možností je aj segmentácia, t.j. čo najpresnejšie vymedzenie požadovanej časti obrazu, ktorá má charakteristické vlastnosti. V kontexte medicíny je najčastejšie touto oblasťou určitá anatomická štruktúra. Výsledky objektívnej segmentácie je potom možné pri dostatočnej presnosti metódy hodnotiť aj kvantitatívne a s výhodou využiť v rámci diagnostických či terapeutických postupov.

Mimoriadne častou cieľovou oblasťou pri vyšetreniach pomocou zobrazovacích systémov je chrbtica. Indikáciami môžu byť degeneratívne ochorenia skeletu, úrazy, neurologické problémy atď. Súčasťou hodnotenia výsledkov zobrazovania chrbtice je neraz vymedzenie spinálneho kanálu a intervertebrálnych diskov (IVD), napr. z dôvodu identifikácie deformácií či posunutia stavcov, miechy alebo medzistavcových platničiek. Dôvodom pre čo najvyšší stupeň automatizácie tohto procesu je odstránenie nutnosti vykonávať často zdĺhavú segmentáciu manuálne lekárom alebo inými zdravotníckymi pracovníkmi a predovšetkým možnosť objektívneho kvantitatívneho hodnotenia výsledkov – jedná sa napr. o posúdenie odchýlky objemu jednotlivých anatomických štruktúr vo vzťahu k štandardným hodnotám alebo predchádzajúcim vyšetreniam daného pacienta.

Cieľom tejto práce je vývoj algoritmu pre segmentáciu spinálneho kanálu a IVD vo výstupoch zobrazovania chrbtice pomocou magnetickej rezonancie. Teoretické základy obsiahnuté v prvej kapitole sa stručne venujú popisu diagnostickej me-

tódy MRI (Magnetic Resonance Imaging – zobrazovanie magnetickou rezonanciou), ďalej štandardným formátom pre uchovávanie medicínskych obrazov, zobrazovaniu a anatómii osového skeletu s dôrazom na spinálny kanál a IVD a napokon popisu segmentačných a ďalších doplnkových metód spracovania obrazov využívaných v práci. Druhá kapitola obsahuje prehľad publikovaných materiálov týkajúcich sa vymedzenej problematiky, náplňou kapitoly 3 je podrobný popis samotnej programovej realizácie navrhutej metódy. Dosiahnuté výsledky sú prezentované a diskutované v štvrtej kapitole nasledovanej záverečným zhodnotením práce v kapitole 5.

1 TEORETICKÉ VÝCHODISKÁ

1.1 Zobrazovanie magnetickou rezonanciou

Procesom zobrazenia nazývame transformáciu scény do obrazového priestoru, konkrétne ide o prevod určitého primárneho fyzikálneho parametra (hustota prostredia, intenzita ionizujúceho žiarenia a pod.) na jasovú hodnotu v obraze. Konkrétna zobrazovacia metóda je potom charakterizovaná príslušným primárnym parametrom scény a spôsobom jeho transformácie. Tento proces úzko súvisí s technickým riešením systému, ktorý danú metódu realizuje a jeho dôkladné objasnenie je nevyhnutným predpokladom pre získanie kvalitných dát.

Zobrazovanie pomocou magnetickej rezonancie je neinvasívna diagnostická metóda založená na jave nukleárnej magnetickej rezonancie (NMR). Tento fyzikálny proces bol popísaný a využívaný už desaťročia pred vznikom metódy MRI (najmä v oblasti analytickej chémie ako prostriedok pre identifikáciu zlúčenín), avšak až progres výpočtovej techniky umožnil jeho implementáciu v rámci zobrazovacích systémov [1].

Základným predpokladom pre vznik NMR je prítomnosť silného externého magnetického poľa s vysokou homogenitou, pričom dochádza k orientácii magnetických momentov jadier atómov do smeru paralelného, resp. antiparalelného so smerom pôsobenia tohto poľa. Za takých podmienok možno pomocou krátkych periodických pulzov magnetického poľa – hovoríme o rádiových vlnách – excitovať jadrá konkrétneho prvku (v praxi takmer výhradne vodíka). Po skončení pulzu sa jadrá vracajú do pôvodného stavu, pretože sa energia v nich nahromadená spontánnymi mechanizmami uvoľňuje. Ide o tzv. relaxačné procesy, pri ktorých sa charakteristicky menia magnetické momenty jadier a v dôsledku toho aj intenzita okolitého magnetického poľa. Tieto zmeny možno detegovať pomocou špeciálnych cievok a získať tak signál, ktorý je podkladom pre zobrazenie cieľového objemu.

Zobrazenie vytvorené pomocou MRI môže byť primárne modulované rôznymi vlastnosťami látky v závislosti na zvolených parametroch merania. Základné experimenty, ktoré sú obsiahnuté prakticky vo všetkých vyšetrovacích sekvenciách pre MRI, poskytujú tzv. T1-váňované, resp. T2-váňované obrazy. Označenia T1 a T2 sa vzťahujú k časovým konštantám, podľa ktorých dochádza k relaxácii magnetických momentov excitovaných jadier. Tieto veličiny sú dané charakterom látky a možno ich preto použiť na odlíšenie jednotlivých tkanív.

Výsadou metódy MRI je predovšetkým zobrazovanie mäkkých tkanív organizmu, ktoré obsahujú dostatočné množstvo vody a teda aj excitovaných jadier atómov vodíka. V tomto prípade poskytujú súčasné systémy výborné rozlíšenie (v porovnaní

napr. s počítačovou tomografiou) a navyše nedochádza k radiačnej záťaži pacienta. Nevýhodou je naopak zdĺhavosť vyšetrenia a jeho kontraindikácie vyplývajúce z prítomnosti silného magnetického poľa (napr. kardiostimulátor či kovové implantáty).

1.2 Formáty medicínskych obrazových dát

Globalizácia v dôsledku technologického pokroku vytvorila v medicíne okrem iného potrebu stanoviť všeobecné medzinárodné postupy pre uchovávanie a výmenu dát tak, aby mohli byť údaje jednoducho zdieľané medzi čo najväčším počtom zdravotníckych zariadení. V prípade obrazových dát sa jedná o špecifické štandardy popisujúce spôsob ich zobrazovania, distribúcie, zdieľania, archivácie, tlače atď. Súčasťou týchto štandardov sú definované dátové formáty výstupov zobrazovacích modalít.

1.2.1 DICOM

Označenie DICOM (Digital Imaging and Communications in Medicine) sa v širšom kontexte používa pre štandard špecifikujúci digitálny obrazový formát, protokol výmeny dát a štruktúru súborov pre biomedicínske obrazy a s nimi súvisiace informácie [2]. V ďalšom však budeme pod týmto pojmom rozumieť iba definovaný dátový formát.

Súbor formátu DICOM (s príponou .dcm) obsahuje okrem samotných obrazových dát hlavičku s doplňujúcimi informáciami (metadátami), ktoré sa týkajú parametrov danej snímky, pacienta, použitej modality, vyšetrenia atď. Niektoré položky hlavičky sú stanovené ako povinné a zvyčajne sú vyplnené automaticky pri vzniku súboru (identifikačné číslo snímky a pod.). Okrem toho sú v metadátach v základe obsiahnuté klinicky významné údaje (napr. meno a identifikátor pacienta) a napokon položky, ktoré si zvolí konkrétny užívateľ podľa potreby. Pokiaľ tieto údaje nie sú známe, môžu ostať príslušné polia nevyplnené [2]. DICOM umožňuje ukládanie dvojrozmerných aj trojrozmerných obrazov, avšak v prípade objemových dát sú obvyčajne jednotlivé 2D rezy umiestnené do samostatných súborov.

1.2.2 NIFTI

Formát NIFTI (Neuroimaging Informatics Technology Initiative, prípona .nii) vznikol pre potreby zobrazovania v neurovedách, avšak jeho použitie nie je limitované iba na túto oblasť. Ide o formát odvodený zo štandardu DICOM (v skutočnosti sa údaje zvyčajne získajú primárne vo formáte DICOM a následne sú prevedené do NIFTI), ktorý lepšie zodpovedá náležitostiam snímania priestorových dát – celý objem (všetky jeho rezy) sú zásadne súčasťou jedného súboru, čo zlepšuje prehľadnosť.

Okrem toho je odlišné aj spektrum údajov obsiahnutých v hlavičke súborov, narozdiel od formátu DICOM v nej nájdeme iba parametre priamo popisujúce obrazové dáta bez dodatočných informácií o pacientovi či vyšetrení.

1.3 Zobrazovanie osového skeletu

Stavba a zloženie anatomických štruktúr sa významne premieta do spôsobu ich zobrazenia a preto je nevyhnutné pri návrhu metód pre spracovanie medicínskych obrazov túto problematiku poznať. Pozornosť je rovnako nutné venovať aj osobitostiam zobrazovania konkrétnych útvarov pomocou rôznych modalít.

1.3.1 Anatómia chrbtice

Chrbtica tvorí základnú pevnú oporu ľudského organizmu, pozostáva z kostených stavcov – v smere kraniálno-kaudálnom ide postupne o 7 krčných stavcov – vertebrae cervicales ($C_1 - C_7$), 12 hrudných stavcov – vertebrae thoracicae ($Th_1 - Th_{12}$), 5 bedrových stavcov – vertebrae lumbales ($L_1 - L_5$), 5 stavcov krížových – vertebrae sacrales ($S_1 - S_5$), ktoré sekundárne zrastajú do krížovej kosti a 2 – 5 stavcov kostrčných – vertebrae coccygeae ($Co_1 - Co_5$), ktoré sekundárne zrastajú do kostrče [3]. V zátvorkách sú uvedené štandardné označenia, použité pre identifikáciu stavcov aj v ďalšom texte.

Každý stavec sa skladá z ventrálne uloženého tela, oblúka orientovaného dorzálne a stavcových výbežkov pre vzájomné spojenie stavcov, resp. pre ich spojenie s rebromi (v oblasti hrudníka). Telá a oblúky uzatvárajú stavcové otvory, ktoré spoločne tvoria spinálny kanál. V tomto kanáli je uložená miecha siahajúca u dospelého človeka k stavcu L_1 až L_2 [3] a obalená mozgovými blanami. Najvrchnejšia z týchto blán – dura mater – vymedzuje spoločne so stenami spinálneho kanála tzv. epidurálny priestor, ktorý je vyplnený hlavne tukovým tkanivom s lymfatickými a krvnými cievami. Dura mater je tesne spojená so strednou vrstvou – arachnoideou, subdurálny priestor medzi nimi je prítomný iba ako patologický, najčastejšie dôsledkom úrazu. Najvnútornejšou blanou je pia mater, ktorá tesne prilieha na povrch tkaniva centrálnej nervovej sústavy a spolu s arachnoideou ohraničuje subarachnoideálny priestor vyplnený cerebrospinálnou tekutinou. Tento priestor tvorí podstatnú časť kanálu, predovšetkým v jeho dolných partiách, kde už neprebíha miecha.

Telá stavcov sú vzájomne prepojené pomocou chrupavkovitých štruktúr – intervertebrálnych diskov. Ďalej je spojenie stavcov a stabilita chrbtice zabezpečená početnými väzmi, niektoré z nich tvoria vonkajšie steny spinálneho kanálu v miestach medzi stavcami.

1.3.2 Špecifická zobrazovania chrbtice metódou MRI

Výsledok zobrazenia pomocou MRI je značne závislý na použitej sekvencii, ktorá stanovuje primárny parameter pre rozlíšenie jednotlivých tkanív (kapitola 1.1). Rôzne protokoly môžu potlačovať či naopak zvýrazňovať určité štruktúry, kontrast medzi mäkkými tkanivami je však vo všeobecnosti oveľa vyšší ako na snímkach z iných modalít. To umožňuje dobré odlíšenie spinálneho kanálu a medzistavcových platničiek. Pokiaľ sa obmedzíme na základné vyšetrovacie sekvencie, tak v zásade platí, že solídne tkanivá sú zobrazované svetlejšie než tekutiny na T1-váhovaných obrazoch, ak je tekutina zobrazená svetlejšie ako pevné tkanivá, ide o T2-váhovaný obraz [1]. Obe sekvencie pritom zvýrazňujú tukové tkanivo. V prípade zobrazovania chrbtice to znamená, že cerebrospinálna tekutina sa bude javiť ako čierna na T1-váhovaných obrazoch (pričom je menej viditeľná miecha a dobre rozlíšiteľný epidurálny priestor s tukovým tkanivom) a naopak na T2-váhovaných snímkach bude zobrazená ako biela, čo zvýrazní tmavšiu miechu. Mierne rozdiely možno pozorovať aj pri zobrazení IVD, ktoré sú na T2-váhovaných obrazoch ohraničené tmavými okrajovými (kortikálnymi) časťami stavcov.

1.4 Segmentácia obrazu

Jedným zo základných krokov analýzy obrazu je segmentácia, ktorú možno definovať ako proces rozdelenia obrazu na neprekrývajúce sa oblasti charakterizované tým, že majú súvis s vecným obsahom scény – najčastejšie pôjde o vymedzenie určitých objektov v scéne. Výsledkom segmentácie je obraz rovnakého rozmeru ako originál, v ktorom sú vyznačené jednotlivé oblasti. Je možné označiť iba hranice týchto oblastí alebo celý ich obsah (resp. objem, pokiaľ ide o priestorové dáta), v takom prípade však strácame obrazovú informáciu v príslušných častiach obrazu. Pokiaľ je úlohou vymedziť jednu oblasť, výsledkom segmentácie môže byť binárny obraz, v ktorom hodnoty 0, resp. 1 označujú pozadie, resp. objekt, príp. naopak. Pri segmentácii na viac oblastí je nutné tieto označiť iným spôsobom – napr. indexovaním alebo farebne [4].

Existuje množstvo rôznych segmentačných metód, ktoré možno kategorizovať podľa principiálnych prístupov k tejto úlohe. Základné metódy (napr. jednoduché prahovanie) vychádzajú z myšlienky homogenity oblastí, to znamená každá oblasť by mala byť homogénna z hľadiska parametra, ktorým je charakterizovaná – v najjednoduchšom prípade je týmto parametrom intenzita obrazu. Iná skupina metód založená na koncepte regiónov – malých oblastí obrazu s rovnakými vlastnosťami – umožňuje utilizáciu a aplikáciu princípu homogenity na lokálnejšej úrovni (patrí sem napr. metóda narastania oblastí). Segmentačné metódy môžu s výhodou využívať

tiež hranovú reprezentáciu obrazu a vo výsledku poskytovať hranice jednotlivých segmentov (napr. Houghova transformácia), rozšírená je segmentácia na základe porovnávania s konkrétnymi vzormi či využitie tzv. aktívnych kontúr (t.j. definovaných flexibilných kriviek, ktoré sa iteratívne deformujú v závislosti na vlastnostiach obrazu až do dosiahnutia optimálneho stavu) [5].

Naznačené rozdelenie je iba prehľadové a nemôže v plnom rozsahu postihnúť široké spektrum a variabilitu metód pre segmentáciu obrazových dát. Napokon ani všetky postupy používané v tejto práci nie je možné spoľahlivo zaradiť do uvedených kategórií.

1.4.1 Model náhodnej prechádzky pre segmentáciu obrazov

Pojmom náhodná prechádzka (random walk) označujeme matematický model, ktorý možno použiť v rôznych vedeckých odvetviach pre popis určitých typov náhodných procesov. Ako vyplýva z názvu, ide o deje vyvíjajúce sa z počiatočného stavu postupnosťou náhodných krokov, pričom je zvyčajne predmetom záujmu konečný stav procesu, resp. pravdepodobnosť jeho nastania po danom počte krokov. Pri aplikácii modelu na konkrétnu situáciu je predovšetkým nutné zvážiť, či je popisovaný jav skutočne náhodný a v prípade potreby použiť parametre, ktoré budú vychyľovať vývoj algoritmu určitým smerom.

Koncept náhodnej prechádzky je možné použiť pre segmentáciu obrazov na ľubovoľný počet oblastí, predpokladom je však stanovenie počiatočných bodov v obraze (tzv. semienok) patriacich k jednotlivým segmentom – index každého semienka potom indikuje jeho príslušnosť k danej oblasti, pričom je nutné, aby každá oblasť bola označená aspoň jedným semienkom. Semienka zadá priamo užívateľ alebo ich možno získať automaticky pomocou iných metód obrazovej analýzy. Samotný algoritmus potom priraduje všetky neoznačené pixely (pojmom pixel budeme v ďalšom rozumieť najmenší obrazový element, aj keď všetky uvedené princípy možno vziať aj na trojrozmerné dáta zložené z voxelov) k definovaným segmentom na základe výpočtu pravdepodobnosti, s akou náhodná prechádzka vychádzajúca z uvažovaného pixelu dosiahne pozíciu jednotlivých semienok ako prvú. Ak uvažujeme K oblastí, potom každému pixelu prislúcha K -tica pravdepodobností a pixel patrí do tej oblasti, pre ktorej semienka bola vypočítaná najvyššia pravdepodobnosť (príp. možno použiť inú metódu pre zaradenie pixelov na základe stanovených pravdepodobností, napr. zhlukovú analýzu) [6].


Z pohľadu modelu náhodnej prechádzky je obraz vnímaný ako graf, v ktorom sú pixely reprezentované tzv. vrcholmi alebo uzlami. Graf $G = (V, E)$ pozostáva z dvojice množín V a E , kde $v \in V$ sú vrcholy (uzly) grafu a $e \in E \subseteq V \times V$ sú hrany grafu. Hrana spájajúca dva susedné vrcholy, v_i a v_j , je označená e_{ij} a možno

jej priradiť číselnú hodnotu – váhu w_{ij} . V tomto prípade hovoríme o váženom grafe, pričom nastavenie váh medzi jednotlivými vrcholmi – pixelmi bude výrazne ovplyvňovať chovanie modelu. Konkrétne je žiaduce, aby váhy vychádzali z určitého parametru, ktorý charakterizuje jednotlivé oblasti obrazu (v najzákladnejšom prípade pôjde o jasovú hodnotu) a aby tak vytvárali hranice, ktoré môžu byť pri náhodnej prechádzke prekročené s rozdielnym stupňom pravdepodobnosti. Taktiež predpokladáme, že graf je neorientovaný, t.j. $w_{ij} = w_{ji}$ [6].


Samotný výpočet požadovaných pravdepodobností je založený na analógii s elektrickými obvodmi. Ako je ukázané v [7], pravdepodobnosť, že pri náhodnej prechádzke z určitého bodu bude ako prvá dosiahnutá pozícia konkrétneho semienka je možné presne vypočítať riešením tzv. Dirichletovho problému s okrajovými podmienkami na pozíciách všetkých semienok, pričom uvažované semienka (t.j. tie, ktorých pravdepodobnosť dosiahnutia stanovujeme) budú mať jednotnú pevnú hodnotu a ostatné semienka budú nulové. Rovnaké riešenie dostaneme určením elektrického napätia v uzloch obvodu (zodpovedajúcich neoznačeným pixelom – vrcholom v grafe), kde váhy grafu sú reprezentované prevrátenou hodnotou odporu (teda vodivosťou) rezistorov medzi uzlami, uvažované semienka predstavujú napäťové zdroje s fixným jednotným napätím a všetky ostatné semienka reprezentujú uzemnenie (t.j. nulový potenciál). Tento koncept je ilustrovaný na obrázku 1.1, ktorý znázorňuje schémy elektrických sietí tvorených napäťovými zdrojmi, uzemnením a uzlami prepojenými cez rezistory. Uvedené obvody možno zároveň chápať ako grafy reprezentujúce obraz.

V tomto jednoduchom prípade sú definované tri rôzne semienka označené L_1 , L_2 a L_3 , pričom predpokladáme rovnaké hodnoty odporov všetkých rezistorov v schémach (čo zodpovedá jednotným váham v príslušnom grafe). Na obrázkoch 1.1b, 1.1c, resp. 1.1d sú pre jednotlivé uzly vypočítané hodnoty napätia za predpokladu, že semienko L_1 , L_2 , resp. L_3 predstavuje konštantný zdroj napätia (s veľkosťou 1) a ostatné semienka reprezentujú uzemnenie (nulové napätie). Tieto hodnoty sa zároveň rovnajú pravdepodobnostiam, že náhodná prechádzka vychádzajúca z daného bodu dosiahne ako prvé semienko L_1 , L_2 , resp. L_3 (je tomu tak preto, že sme zvolili jednotkovú veľkosť napätia zdroja, rovnaký výsledok by sme však dostali aj pre iné hodnoty po normalizácii). Na obrázku 1.1a je napokon naznačená segmentácia príslušného grafu – každý uzol je priradený k tomu semienku, pre ktoré bola vypočítaná pravdepodobnosť najvyššia.


Dôležitou vlastnosťou popísaného prístupu vzhľadom na segmentáciu obrazu je fakt, že všetky segmenty sú priamo spojené s príslušnými inicializačnými semienkami, t.j. v segmentovanom obraze sa nenachádzajú izolované oblasti, ktoré neobsahujú žiadne semienka. Súčet pravdepodobností v jednotlivých bodoch vzhľadom na všetky semienka je rovnaký (a rovný 1) a ich veľkosti sú váženým priemerom príslušných pravdepodobností pre susedné vrcholy grafu, pričom váhami sú hodnoty




(a) Segmentácia grafu s vyznačenými semienkami



(b) Pravdepodobnosti, že náhodná prechádzka vychádzajúca z jednotlivých uzlov dosiahne ako prvé semienko L_1



(c) Pravdepodobnosti, že náhodná prechádzka vychádzajúca z jednotlivých uzlov dosiahne ako prvé semienko L_2



(d) Pravdepodobnosti, že náhodná prechádzka vychádzajúca z jednotlivých uzlov dosiahne ako prvé semienko L_3

Obr. 1.1: K objasneniu analógie medzi elektrickými obvodmi a modelom náhodnej prechádzky. Prevzaté z [6].

priradené hranám grafu – tieto vlastnosti možno jednoducho overiť na ilustračnom príklade z obrázku 1.1 (prípadné nepresnosti sú dôsledkom zaokrúhlenia), ich teoretický výklad s dôkazmi je obsiahnutý v [6]. Významný je tiež poznatok, že pre zadaný problém existuje práve jedno unikátne riešenie.

Ako bolo naznačené, podstatnú úlohu pri zostavovaní algoritmu náhodnej prechádzky zohráva nastavenie váh v grafe. Váhová funkcia použitá v práci je zhodná s návrhom podľa [6] a má tvar

$$w_{ij} = e^{[-\beta(g_i - g_j)^2]}, \quad (1.1)$$

kde g_i , resp. g_j je intenzita i -tého, resp. j -tého pixelu obrazu a β je zvolená kladná

konštanta, ktorá predstavuje jediný voľný parameter algoritmu (ide vlastne o váhu rozdielu intenzít medzi susednými pixelmi – ak sa β zníži, tak tento rozdiel ovplyvní hodnotu výslednej váhy w_{ij} do menšej miery a naopak). Pred výpočtom váh podľa 1.1 navyše dochádza k normalizácii výrazu $(g_i - g_j)^2 \forall e_{ij} \in E$, ide však o voliteľnú modifikáciu. Z tvaru váhovej funkcie vidíme, že danej hrane bude priradená tým nižšia hodnota, čím vyšší je rozdiel intenzít pixelov, ktoré spája. Hodnotu váhy teda možno interpretovať ako pravdepodobnosť, že pri náhodnej prechádzke bude príslušná hrana prekročená – pre hranice objektov v obraze bude táto pravdepodobnosť nízka.

Podstatnou nezodpovedanou otázkou nakoniec ostáva, ako určiť požadované napätia – pravdepodobnosti na základe stanovených váhových hodnôt a počiatočných okrajových podmienok, t.j. semienok. Spomínaný Dirichletov problém je formulovaný ako nájdenie harmonickej funkcie u , ktorá spĺňa zadané okrajové podmienky (v požadovaných bodoch sa rovná konkrétnym hodnotám) – táto funkcia potom určuje hodnoty pravdepodobností pre nezaraďené pixely. Harmonická funkcia je pritom definovaná tým, že vyhovuje Laplaceovej rovnici

$$\nabla^2 u = 0. \quad (1.2)$$

Z tejto podmienky vyplýva zaujímavá vlastnosť harmonickej funkcie – hodnoty jej vnútorných bodov sú dané priemerom (príp. váženým) okolitých hodnôt, napr. pre dvojrozmernú spojitú funkciu harmonickú v určitej oblasti platí, že hodnota $u(x, y)$ sa rovná priemeru hodnôt z kruhového okolia bodu (x, y) ľubovoľného priemeru, ktoré leží v danej oblasti [7]. Rovnaká charakteristika pre diskretný prípad je popísaná vyššie v spojitosti s vlastnosťami aplikácie princípu náhodnej prechádzky na dvojrozmerný graf. Dirichletov problém a jeho riešenie boli pôvodne popísané pre spojité funkcie (najmä v súvislosti s fyzikálnymi úlohami) – hľadaná harmonická funkcia u spĺňajúca zadané okrajové podmienky ohraničujúce oblasť Ω minimalizuje Dirichletov integrál $D[u]$ v tvare

$$D[u] = \frac{1}{2} \int_{\Omega} |\nabla u|^2 d\Omega. \quad (1.3)$$

V prípade algoritmu náhodnej prechádzky však pracujeme s nespojitými hodnotami vo vrchoch grafu. Našťastie je možné úlohu hľadania harmonickej funkcie previesť do diskretnej podoby a na jej vyriešenie použiť čisto kombinačné operátory, ktoré nevyžadujú diskretizáciu a nezavádzajú tak žiadne chyby ani nejednoznačnosti – vo výsledku získavame presné hodnoty pravdepodobností pre všetky vrcholy grafu. Matematická formulácia celého problému a náležitosti numerického riešenia sú však nad rámec tohto teoretického úvodu, možno ich nájsť v [6].

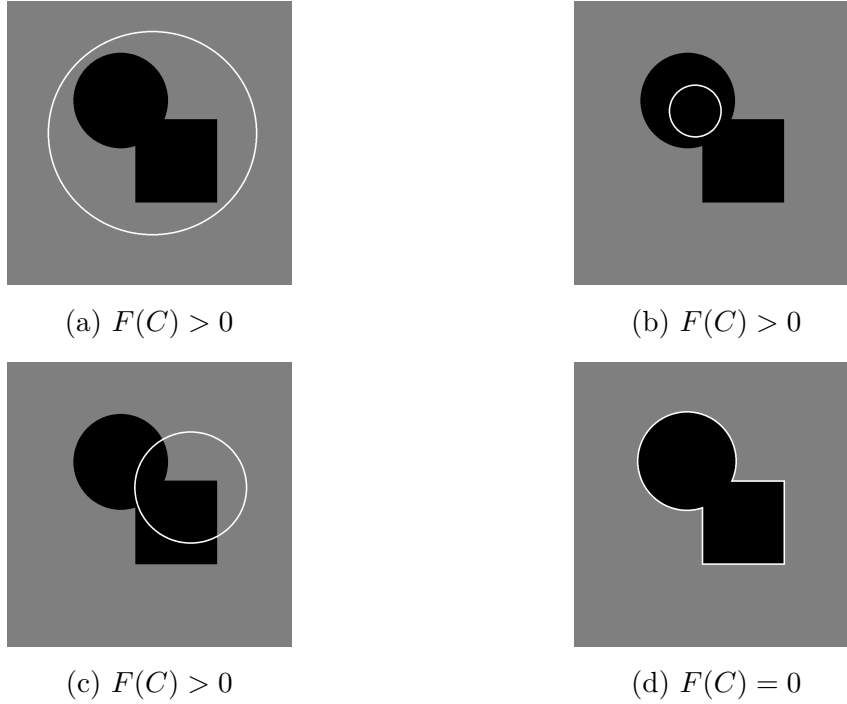
1.4.2 Metóda aktívnych kontúr bez hranovej funkcie

Aktívne kontúry sú veľmi rozšíreným modelom v oblasti segmentácie obrazových dát, ktorého princípom je evolúcia počiatočnej (napr. užívateľom zadanej) krivky na základe definovaných vzťahov tak, aby sa jej vývoj zastavil v optimálnom bode, t.j. na hraniciach objektov v obraze. Pod hľadáním optimálneho riešenia možno zvyčajne rozumieť minimalizáciu, príp. maximalizáciu určitej energetickej funkcie, ktorá často pozostáva z vonkajšej a vnútornej energie. Externá energia je určená príznakmi získanými z obrazu a priťahuje krivku k hraniciam jednotlivých oblastí, energia vnútorná slúži na kontrolu tvaru kontúry a jej výpočet je založený na parametroch samotnej krivky. Spoločným menovateľom veľkej časti metód z uvedenej kategórie je závislosť energetickej funkcie na gradiente jasových hodnôt obrazu, ktorý teda určuje podmienku pre zastavenie evolúcie krivky – možno hovoriť o segmentácii založenej na hranovej funkcii. Takýto prístup ale zlyháva v prípade, že hranice objektov nie sú dostatočne reprezentované zmenou intenzity v obraze, napr. po vyhladení silne zašumeného obrazu alebo v prípade neostrých hraníc oblastí. Metóda popísaná v tejto kapitole však predstavuje odlišný prístup, ktorý umožňuje vysporiadať sa s uvedenými problémami [8].

Matematický popis algoritmu vychádza z definovania vyvíjajúcej sa kontúry a regiónov, ktoré vymedzuje. Nech C je krivka na množine Ω ako hranica otvorenej množiny ω , ktorá je podmnožinou Ω (t.j. $\omega \subset \Omega$ a $C = \partial\omega$). Ďalej zavedieme označenie $C_{in} = \omega$ pre oblasť vnútri krivky a C_{ex} pre jej vonkajšiu oblasť, $C_{ex} = \Omega \setminus \bar{\omega}$ ($\bar{\omega}$ značí uzáver množiny ω). Základom segmentačnej metódy je minimalizácia výrazu

$$F(C) = F_1(C) + F_2(C) = \int_{C_{in}} |u_0(x, y) - c_1|^2 dx dy + \int_{C_{ex}} |u_0(x, y) - c_2|^2 dx dy, \quad (1.4)$$

kde c_1 , resp. c_2 sú priemerné intenzity obrazu u_0 v oblastiach C_{in} , resp. C_{ex} , integruje sa podľa priestorových súradníc obrazu x, y . Časti energetickej funkcie $F_1(C)$, resp. $F_2(C)$ sa teda vzťahujú k vnútornej, resp. vonkajšej oblasti krivky C . Pokiaľ uvážime obraz s dvoma oblasťami rozdielnej konštantnej intenzity (viď obrázok 1.2), tak je jednoduché ukázať, že uvedený výraz bude minimálny (nulový) v prípade, že kontúra leží na hranici medzi objektmi. Ak totiž bude krivka obkolesovať objekt (obrázok 1.2a), tak $F_1(C) > 0$ a $F_2(C) = 0$, pokiaľ bude celá vnútri objektu (obrázok 1.2b), tak naopak $F_1(C) = 0$ a $F_2(C) > 0$ a pokiaľ bude zasahovať do vnútra objektu aj mimo neho (obrázok 1.2c), tak $F_1(C) > 0$, $F_2(C) > 0$. Jedine pre $C = C_0$, kde C_0 predstavuje hranicu medzi oblasťami (obrázok 1.2d), platí $F_1(C) = F_2(C) = 0$. Z uvedeného vyplýva, že pre dosiahnutie požadovanej segmentácie budeme minimalizovať výraz 1.4, ktorý doplníme o parametre vzťahujúce sa



Obr. 1.2: K objasneniu princípu metódy aktívnych kontúr bez hranovej funkcie. Jednotlivé obrázky ukazujú rozličné polohy kontúry vzhľadom na segmentovaný objekt a vplyv tohto umiestnenia na veľkosť energetickej funkcie $F(C)$.

k tvaru kontúry nasledovne [8]:

$$F(c_1, c_2, C) = \mu \cdot D(C) + \nu \cdot S(C_{in}) + \lambda_1 \int_{C_{in}} |u_0(x, y) - c_1|^2 dx dy + \lambda_2 \int_{C_{ex}} |u_0(x, y) - c_2|^2 dx dy, \quad (1.5)$$

kde $D(C)$ je dĺžka vyvíjajúcej sa krivky, $S(C_{in})$ vyjadruje plochu ohraničenú krivkou a $\mu \geq 0$, $\nu \geq 0$, $\lambda_1, \lambda_2 > 0$ sú zvolené konštanty. Tento krok poskytuje možnosť lepšej kontroly vývoja krivky, príp. je možné dodatočné parametre vynechať (nastavením $\mu = 0$, $\nu = 0$) a kontúru prispôbovať iba na základe príznakov z obrazu.

Pre praktickú implementáciu popísaného modelu je výhodné definovať kontúru ako tzv. level set funkcie dvoch premenných, t.j. množinu všetkých bodov, v ktorých táto funkcia nadobúda stanovenú konštantnú hodnotu – možno tiež hovoriť o izolinii či vrstevnici danej funkcie. Ide o prístup často používaný pri práci s krivkami či povrchni, pretože umožňuje ich modelovanie v kartézskej sústave bez nutnosti parametrizácie. V tomto prípade je krivka určená ako nulový level set pomocnej

funkcie $\phi : \Omega \rightarrow \mathfrak{R}$, pre ktorú platí

$$\begin{cases} C = \partial\omega = \{(x, y) \in \Omega : \phi(x, y) = 0\} \\ C_{in} = \omega = \{(x, y) \in \Omega : \phi(x, y) > 0\} \\ C_{ex} = \Omega \setminus \bar{\omega} = \{(x, y) \in \Omega : \phi(x, y) < 0\}. \end{cases} \quad (1.6)$$

Vidíme, že funkcia ϕ nadobúda kladné hodnoty pre body vnútri krivky, v jej vonkajšej oblasti je záporná. S využitím tohto poznatku, Heavisideovej skokovej funkcie H a Diracovej miery δ_0 definovanými ako

$$H(z) = \begin{cases} 1 & \text{pre } z \geq 0 \\ 0 & \text{pre } z < 0, \end{cases} \quad (1.7)$$

$$\delta_0(z) = \frac{d}{dz}H(z) \quad (1.8)$$

je možné nahradiť neznámu premennú C v modeli aktívnej kontúry podľa 1.5 premennou ϕ a formulovať tak celý problém ako minimalizáciu energetickej funkcie $F(c_1, c_2, \phi)$ [8]:

$$\begin{aligned} F(c_1, c_2, \phi) &= \mu \int_{\Omega} \delta_0(\phi(x, y)) |\nabla \phi(x, y)| dx dy + \nu \int_{\Omega} H(\phi(x, y)) dx dy \\ &+ \lambda_1 \int_{\Omega} |u_0(x, y) - c_1|^2 H(\phi(x, y)) dx dy \\ &+ \lambda_2 \int_{\Omega} |u_0(x, y) - c_2|^2 (1 - H(\phi(x, y))) dx dy. \end{aligned} \quad (1.9)$$

Minimalizáciou $F(c_1, c_2, \phi)$ podľa ϕ pri konštantných c_1, c_2 možno odvodiť príslušnú Euler-Lagrangeovu rovnicu. Riešením tejto rovnice je vo všeobecnosti funkcia, pre ktorú je zadaný funkcionál stacionárny. V tomto prípade riešením Euler-Lagrangeovej rovnice získame neznámu funkciu ϕ , ktorá minimalizuje energiu podľa 1.9 a teda definuje hľadanú krivku ohraničujúcu jednotlivé oblasti v obraze. Formulácia rovnice spolu s podrobnosťami ohľadom numerického riešenia sú obsiahnuté v [8]. Na tomto mieste iba uvedme, že je nutná diskretizácia problému (keďže uvažujeme spracovanie digitálnych dát) a ku konečnému výsledku sa dospeje iteratívnou metódou, pričom je nutné zadanie počiatočnej kontúry ϕ_0 tak, ako bolo spomenuté na začiatku kapitoly.

Výhodou popísaného postupu a jeho formulácie s využitím konceptu level set je okrem spomínanej nezávislosti na gradiente obrazu (metóda neobsahuje hranovú funkciu) aj fakt, že z jedinej počiatočnej kontúry možno dosiahnuť segmentáciu vzájomne izolovaných oblastí, t.j. výsledkom môže byť niekoľko uzavretých kriviek

ohraničujúcich jednotlivé segmenty. Počiatočná kontúra pritom nemusí nevyhnutne obklopovať segmentované objekty a je možné ju umiestniť prakticky kdekoľvek v obraze (samozrejme s rozdielnym výsledkom po danom počte iterácií). Tieto vlastnosti predurčujú metódu pre použitie na silne zašumené obrazy bez nutnosti ich predchádzajúceho vyhladenia či pre segmentáciu objektov, ktorých hranice nie sú dobre charakterizované gradientom (napr. sú veľmi rozmazané) – v týchto prípadoch zvyčajne nie sú klasické metódy aktívnych kontúr aplikovateľné [8]. Je vhodné poznamenať, že postupy definované v tejto kapitole pracujú s dvojrozmernými obrazmi a ich výsledkom sú 2D kontúry, rovnaký prístup však možno zovšeobecniť aj na vyššie dimenzie – pri spracovaní objemových dát by výstup predstavoval povrch ohraničených 3D objektov.

1.4.3 Metóda rozvodí

Metóda rozvodí (známa najmä pod anglickým názvom watershed) je segmentačná technika, ktorej princíp je založený na analógii s reálnou povodňou. Obraz v tomto koncepte predstavuje členitý reliéf s vrchmi v miestach maximálnych jasových hodnôt a údoliami zodpovedajúcimi lokálnym minimám. Povodeň potom možno simulovať zaplavovaním reliéfu vodou, ktorá priteká z týchto miním a vytvára tak jednotlivé povodia – segmenty obrazu. V miestach, kde by malo dôjsť k spojeniu susedných povodí, sa začne vytvárať pomyselná priehrada (rozvodie) predstavujúca hranicu medzi oblasťami [4]. Týmto spôsobom dochádza k rozdeleniu obrazu na dopredu neurčený počet segmentov, ktoré spoločne so svojimi hranicami vytvárajú výstup algoritmu.

Metódu rozvodí je neefektívne používať na pôvodný jasový obraz, výhodnejšia je aplikácia na obraz parametrický. Používa sa najmä aproximácia prvej derivácie pomocou diferencií (t.j. gradientný obraz), alternatívne distančná mapa (kapitola 1.5.3) v prípade binárneho vstupu. Metóda sa vyznačuje veľkou robustnosťou voči šumu, nevýhodou je naopak sklon k vytvoreniu veľkého množstva segmentov nezodpovedajúcich vecnému obsahu scény (tzv. presegmentovanie). Pri praktickom použití je veľmi dôležité vytvorenie vhodného parametrického obrazu [4].

1.5 Morfológické operácie

Morfologické operácie predstavujú samostatnú sekciu metód pre spracovanie obrazov. Pôvodne boli vyvinuté pre prácu s binárnymi obrazmi, ktoré sú v ich kontexte vnímané ako množiny – jednotlivé metódy sú preto definované pomocou množinových operátorov. Morfológické operácie však môžu byť zovšeobecnené aj pre spracovanie šedotónových obrazov, ktoré je najskôr nutné previesť na súbor binárnych

obrazov (pomocou tzv. prahovej dekompozície) a následne sa aplikujú zovšeobecnené analógie množinových operátorov (prieniku zodpovedá operácia minimum, zjednoteniu zodpovedá maximum a pod.).

Morfologické operátory sú aplikované lokálne, pre danú operáciu je definovaný tzv. štruktúry element s referenčným bodom. Tento element obsahuje na svojich pozíciách hodnoty 1 (aktívne prvky) alebo 0 a pohybuje sa po obraze, pričom výsledok operácie sa do výstupného obrazu ukladá na pozícii referenčného bodu. Z uvedeného vyplýva, že výstup metódy bude závisieť na voľbe tvaru štruktúrneho elementu, rozmiestnení jeho aktívnych prvkov a referenčného bodu. Výhodou je skutočnosť, že štruktúrne elementy možno zostaviť aj vo viac ako dvoch dimenziách a spracúvať tak efektívne objemové dáta. Všetky morfologické operácie sú navyše nelineárne metódy, nemožno pre nich preto definovať impulznú či frekvenčnú charakteristiku ako u konvolučných operátorov [4]. V tejto kapitole sú priblížené základné binárne morfologické operácie, ktoré sú priamo využité v práci.

1.5.1 Erózia

Binárna erózia predstavuje operáciu, pri ktorej je do výstupného obrazu na pozícii referenčného bodu štruktúrneho elementu zapísaná hodnota 1, pokiaľ na pozíciách všetkých aktívnych prvkov tohto elementu vo vstupnom obraze je hodnota 1. V opačnom prípade je výstupom operácie v tomto bode hodnota 0. Tento proces možno matematicky vyjadriť rovnicou

$$Y = \mathbf{E}_H(X) = \{\mathbf{x} \mid H_{\mathbf{x}} \subseteq X\}, \quad (1.10)$$

kde X , resp. Y je vstupný, resp. výstupný obraz, \mathbf{x} označuje súradnice obrazu, na ktorých leží referenčný bod štruktúrneho elementu H a $H_{\mathbf{x}}$ predstavuje štruktúrny element posunutý na súradnice \mathbf{x} . Na pozíciu \mathbf{x} sa teda vo výstupnom obraze zapíše hodnota 1 jedine v prípade, že štruktúrny element posunutý do tohto bodu je podmnožinou vstupného obrazu [4].

Eróziu je možné definovať aj ako prienik súboru posunutých originálnych obrazov, ktorých posunutia sú dané vektorom \mathbf{h} posunutí medzi referenčným prvkom štruktúrneho elementu a všetkými jeho aktívnymi prvkami. Každá verzia originálneho obrazu sa pritom posúva opačným smerom, ako udáva príslušný vektor posunutia – prvok vektoru \mathbf{h} [4]. Táto definícia binárnej erózie je vyjadrená matematickým zápisom

$$Y = \mathbf{E}_H(X) = \bigcap_{\mathbf{h} \in H} X_{-\mathbf{h}} \quad (1.11)$$

a je výhodná predovšetkým z hľadiska praktickej implementácie metódy.

1.5.2 Dilatácia

Pri binárnej dilatácii vkladáme do výstupného obrazu na pozícii referenčného bodu štruktúrneho elementu hodnotu 1 v prípade, že aspoň na jednej z pozícií aktívnych prvkov tohto elementu vo vstupnom obraze je hodnota 1, inak je do výstupu zapísaná nula. Formálne

$$Y = \mathbf{D}_H(X) = \{\mathbf{x} \mid H_{\mathbf{x}} \cap X \neq \emptyset\}, \quad (1.12)$$

príčom význam symbolov je rovnaký ako v predchádzajúcej kapitole. Na pozíciu \mathbf{x} sa vo výstupnom obraze zapíše hodnota 1, pokiaľ prienik vstupného obrazu a aktívnych prvkov štruktúrneho elementu posunutého do bodu \mathbf{x} nie je prázdna množina [4]. Alternatívnou formuláciou je obdobne ako v prípade erózie vzťah 1.13 vyjadrujúci zjednotenie verzií originálneho obrazu posunutých podľa \mathbf{h} .

$$Y = \mathbf{D}_H(X) = \bigcup_{\mathbf{h} \in H} X_{-\mathbf{h}} \quad (1.13)$$

1.5.3 Distančná mapa

Medzi morfológické transformácie binárneho obrazu sa zaraďuje aj vytvorenie distančnej mapy založené na stanovení vzájomných vzdialeností medzi pixelmi. Každému pixelu objektu v obraze (označeného hodnotou 1) je totiž priradená hodnota vzdialenosti k najbližšiemu bodu pozadia. Distančná mapa $D(x)$ obrazu x je teda určená matematickým výrazom

$$D(x) |_{i,k} = \min_{m,n} [d((i,k), (m,n)), x_{m,n} = 0], \quad (1.14)$$

podľa ktorého je každému pixelu so súradnicami i, k v mape priradená minimálna hodnota spomedzi vzdialeností d tohto pixelu od pixelov (m, n) pozadia (majúcich hodnotu 0) [4]. Pre vlastnosti distančnej mapy je potom rozhodujúcim faktorom zvolená vzdialenostná metrika. V najbežnejšom prípade ide o manhattanskú, resp. euklidovskú vzdialenosť, ktorá sa pre pixely A a B n -rozmerného obrazu vypočíta podľa vzťahu 1.15, resp. 1.16, kde A_i, B_i sú zodpovedajúce si súradnice pixelov.

$$d_M(A, B) = \sum_{i=1}^n |A_i - B_i| \quad (1.15)$$

$$d_E(A, B) = \sqrt{\sum_{i=1}^n (A_i - B_i)^2} \quad (1.16)$$

2 SÚVISIACE PRÁCE

Rýchly rozvoj metód spracovania a analýzy obrazových dát v medicíne a vedecký záujem o danú problematiku je dokladovaný značným množstvom odborných materiálov z tejto oblasti, ktoré vznikli a boli publikované v posledných rokoch. Ide predovšetkým o algoritmy pre prácu so snímkami z modalít CT (Computed Tomography – počítačová tomografia) a MRI, pričom je často regiónom záujmu chrbtica. Pokiaľ sa zameriame konkrétne na segmentačné úlohy, veľa autorov sa venuje vymedzeniu spinálneho kanálu alebo IVD (segmentácia obidvoch štruktúr súčasne v rámci jednej metódy je menej častá) a všeobecnou snahou je čo najvyšší stupeň automatizácie postupu tak, aby sa znížila potreba vykonávania rutinných manuálnych úkonov zdravotníckymi pracovníkmi a bolo možné spoľahlivé kvantitatívne hodnotenie výsledkov bez vplyvu subjektívnych faktorov.

Iteratívna aplikácia modelu náhodnej prechádzky je využitá v [9] pre automatickú segmentáciu spinálneho kanálu v objemových CT dátach. Inicializačné semienka sú v tomto prípade získané pomocou extrakcie Haarových príznakov a metódy strojového učenia – je použitý klasifikátor trénovaný a testovaný na súbore manuálne anotovaných dát, ktorý určí množinu voxelov s vysokou pravdepodobnosťou príslušnosti k segmentovanému objektu (spinálnemu kanálu). Po každej aplikácii algoritmu náhodnej prechádzky sa následne odvodí topológia vymedzenej oblasti v podobe mediálnej línie, ktorá je doplnená a upravená podľa geometrického modelu spinálneho kanálu vychádzajúceho z jeho anatomických parametrov. Na základe tejto korigovanej topológie sú stanovené nové semienka vstupujúce do nasledujúcej iterácie náhodnej prechádzky a proces sa opakuje až do konvergenencie metódy, t.j. kým sa prestane topológia spinálneho kanálu meniť.

Narozdiel od CT umožňujú niektoré MRI sekvencie (napr. T2-váhovanie) rozlíšiť tkanivo miechy od cerebros spinálnej tekutiny. Potom je možné segmentovať osobitne spinálny kanál a miechu – tento prístup je uplatnený v [10], kde je segmentácia navyše doplnená o identifikáciu IVD a stavcov. To následne umožňuje vymedzený spinálny kanál rozdeliť na úrovne prislúchajúce jednotlivým stavcom a zaviesť súradnicový systém, ktorý slúži na objektívne porovnanie kvantitatívnych parametrov (napr. obsahu prierezu alebo objemu kanálu či miechy v určitej oblasti) medzi pacientmi, príp. medzi rôznymi vyšetreniami rovnakého pacienta. Samotný segmentačný algoritmus je založený na propagácii a následnej deformácii trojrozmernej tubulárnej mriežky. Počiatočná pozícia mriežky sa stanoví pomocou eliptickej Houghovej transformácie.

Deformovateľný priestorový model (alebo tiež model aktívneho povrchu) je možné použiť aj pre segmentáciu IVD v MRI obrazoch, ako dokumentuje [11]. Zavádza sa inicializačná trojrozmerná šablóna (povrch) tvaru elipsoidu, ktorej počiatočná po-

loha približne korešpondujúca s umiestnením disku sa určí na základe užívateľom definovaných bodov. Následne dochádza k automatickej deformácii tejto mriežky podľa síl vychádzajúcich z obrazového gradientu. V prípade nekvalitnej segmentácie je možná intervencia zo strany užívateľa, ktorý môže v problematických oblastiach definovať dodatočné body na hranici IVD. Tento postup je v [11] použitý pre vytvorenie referenčnej segmentácie (tzv. „ground truth“) a taktiež pre zlepšenie vymedzenia patológiou postihnutých – herniovaných diskov.

Odlišný prístup pre lokalizáciu a segmentáciu IVD v MRI objemových dátach prezentuje článok [12]. Autori používajú za účelom extrakcie štrukturálnych príznakov z obrazu banku dvojrozmerných Gaborových filtrov, ktoré sú schopné vo zvolenom okne identifikovať špecifický frekvenčný obsah obrazu v konkrétnom smere. Vhodnou voľbou parametrov filtra možno získať príznakovú mapu (GFI – Gabor Features Image) použiteľnú pre detekciu hraníc objektov v tomto smere. Najskôr sa na základe výpočtu GFI pre vertikálny smer určia hranice chrbtice a v tomto vymedzenom regióne sa nájdu približné pozície jednotlivých diskov, opäť pomocou vhodných GFI. Po korekcii lokalizácie diskov možno ešte presnejšie vymedziť oblasť záujmu, v ktorej napokon dochádza k aplikácii segmentačného algoritmu využívajúceho adaptívny prah.

Reprezentácia obrazu pomocou grafu (t.j. súboru vrcholov a hrán) je v oblasti segmentácie obrazov rozšíreným prístupom. Grafy sú základom modelu náhodnej prechádzky, ale taktiež pomerne širokej skupiny metód, ktoré pracujú s konceptom graph cut. Algoritmus z tejto kategórie a jeho využitie pre segmentáciu IVD v MRI obrazoch je popísané v [13]. Obraz je rozdelený do neprekrývajúcich sa blokov, ktoré sú klasifikované do skupín podľa príslušnosti k objektu (disku) alebo pozadiu na základe podobnosti s tréningovými obrazmi. Takto klasifikované pixely sú potom vstupom pre samotný graph cut algoritmus, ktorý vyhľadáva optimálny rez grafom – obrazom tak, aby bola minimalizovaná zadaná funkcia odvodená z parametrov obrazu.


Článok [14] prezentuje automatickú metódu lokalizácie a segmentácie IVD v trojrozmerných MRI obrazoch na základe tréningových, anotovaných dát. V prvom kroku sa lokalizujú centrálné body jednotlivých diskov pomocou náhodne zvolených vzoriek obrazu (3D oblastí o definovanej veľkosti), pre ktoré sa vypočítajú špeciálne navrhnuté príznaky súvisiace s tréningovými dátami a geometrickými obmedzeniami segmentácie. Stanovené príznaky sú súčasťou cieľovej funkcie, ktorá po optimalizácii poskytuje na výstupe vektor posunutia medzi náhodnou vzorkou obrazu a predpokladaným stredom disku. Kombináciou tejto informácie pre veľké množstvo vzoriek sa vytvára pravdepodobnostná mapa, na základe ktorej je určená poloha hľadaného centrálného bodu. Druhá časť metódy predstavuje samotnú segmentáciu diskov, pri ktorej sú voxely v okolí ich stredu klasifikované ako voxely pozadia alebo objektu.

Využíva sa obdobný princíp ako v prvej fáze metódy, pričom sú mierne pozmenené extrahované obrazové príznaky (s cieľom zabezpečiť lokálne vyhladenie segmentovaných objektov) a výsledkom optimalizácie cieľovej funkcie je pravdepodobnosť príslušnosti daného voxelu k IVD, resp. pozadiu. Výsledná pravdepodobnostná mapa je prahovaná pre získanie binárnej segmentácie.

Rozmach metód strojového učenia sa premietol aj do nových segmentačných techník. Možno povedať, že konvolučné neurónové siete (CNN – Convolutional Neural Networks) sú dnes už etablovanou oblasťou na poli spracovania obrazov. Použitie plne konvulčnej 3D neurónovej siete pre lokalizáciu a segmentáciu IVD v objemových dátach je predstavené v [15]. Benefitom metódy je skutočnosť, že sieť automaticky extrahuje obrazové príznaky vhodné pre účel segmentácie na základe tréningových dát. Autori navyše deklarujú kvalitnejšie výsledky v porovnaní s 2D CNN pri aplikácii na T2-váňované MRI snímky.

3 PROGRAMOVÁ REALIZÁCIA

Navrhnutý algoritmus je realizovaný v programovom prostredí MATLAB® R2015b a využíva niektoré jeho zabudované funkcie, ktoré sú súčasťou špecifických knižníc. Proces segmentácie prebieha v dvoch hlavných krokoch – najskôr je vymedzený spinálny kanál a následne sa pristupuje k segmentácii IVD tak, ako je uvedené v základnej schéme štruktúry programu na obrázku 3.1. Základom segmentačných algoritmov pre spinálny kanál aj IVD je aplikácia modelu náhodnej prechádzky (kapitola 1.4.1). Ide o koncept, ktorý bol v minulosti úspešne použitý pre segmentačné úlohy týkajúce sa trojrozmerných medicínskych obrazov (viď [9]) a jeho využitie v tejto práci vychádza z prieskumu publikácií a výsledkov dosiahnutých v uvedenej oblasti. Metóda náhodnej prechádzky vyžaduje stanovenie počiatočných bodov – semienok označujúcich objekt, resp. pozadie. V prípade spinálneho kanálu sú tieto body zadané užívateľom, semienka pre segmentáciu IVD sú odvodené automaticky z polohy kanálu získanej v prvej časti algoritmu.



Obr. 3.1: Základná štruktúra navrhnutého algoritmu.


Celý program je vytvorený vo forme funkcie, ktorej jediným povinným vstupným parametrom je cesta k súboru s obrazovými dátami. Dáta musia byť uložené vo formáte NIFTI.

3.1 Segmentácia spinálneho kanálu

Postup pri segmentácii spinálneho kanálu je uvedený na obrázku 3.2. Jednotlivé časti algoritmu na seba priamo naväzujú a sú bližšie popísané v nasledujúcich kapitolách.

3.1.1 Predspracovanie

Jedinou formou predspracovania vstupných trojrozmerných dát je prevod na dátový typ „double“ (64-bitový dátový formát s pohyblivou desatinnou čiarkou) a následná




Obr. 3.2: Bloková schéma algoritmu pre segmentáciu spinálneho kanálu.

normalizácia jasových hodnôt obrazu. Z hľadiska úspory pamäte a výpočtovej náročnosti nie je prevod dát efektívny (pre väčšinu medicínskych obrazov postačuje kódovanie hodnôt ako 16-bitových nezáporných celých čísel – v MATLABe® sa jedná o dátový typ „uint16“), avšak funkcie aplikované v ďalšom postupe vyžadujú na vstupe dáta typu „double“. Jasové hodnoty voxelov obrazu sú prevedené do rozsahu 0 až 1, pričom normalizovaná hodnota n_i i -tého voxelu sa vypočíta z jeho pôvodnej hodnoty g_i podľa vzťahu

$$n_i = \frac{g_i - \min_i(g_i)}{\max_i(g_i) - \min_i(g_i)}. \quad (3.1)$$

3.1.2 Stanovenie inicializačných semienok

Na vstup segmentačného algoritmu je okrem cesty k dátovému súboru (vo forme znakového reťazca) možné zadať aj jeden voliteľný parameter – súradnicu sagitálneho rezu, v ktorom si užívateľ praje zvoliť inicializačné semienka pre segmentáciu spinálneho kanálu. Ak tento vstupný údaj chýba, použije sa automaticky prostredný sagitálny rez nasnímaného objemu (predpokladá sa teda práca s centrovanými dátami). Príslušný sagitálny rez sa po spustení algoritmu zobrazí spoločne s výzvou na označenie bodov prislúchajúcich spinálnemu kanálu, ktoré budú použité ako inicializačné semienka pre model náhodnej prechádzky. Užívateľ môže zvoliť jediný bod (kliknutím počítačovou myšou) alebo viac bodov (potiahnutím myšou a vyznačením línie v obraze), ako je ilustrované na obrázku 3.3. V druhom prípade je vyznačená línia v rozsahu medzi jej najvrchnejším a najspodnejším bodom interpolovaná kubickým splajnom tak, aby každý transverzálny rez obrazu v tomto rozsahu obsahoval práve jeden inicializačný bod. Využíva sa kubický splajn typu „not-a-knot“, pri ktorom je vyžadovaná spojitosť tretej derivácie splajnu v druhom a predposlednom uzlovom bode [16] (čo zároveň zaručuje totožnosť prvého a druhého, resp. posledného a predposledného polynómu splajnu). Pokiaľ užívateľ v konkrétnom transverzálnom reze



Obr. 3.3: Inicializačné semienka pre segmentáciu spinálneho kanálu. Užívateľ interaktívne zvolí jediný inicializačný bod alebo označí líniu v oblasti spinálneho kanálu tak, ako je znázornené na tomto obrázku. Línia je vyznačená modrou farbou.

označí viac bodov, pre potreby interpolácie a následnej segmentácie bude využitý iba jeden z nich.

3.1.3 Segmentácia v inicializačnom úseku

Časť 3D obrazu zodpovedajúcu vertikálnemu rozsahu interpolovanej línie (viď predchádzajúca kapitola) budeme nazývať inicializačným úsekom (ktorý je v prípade, že užívateľ označí jeden bod, tvorený jediným transverzálnym rezom obrazu). V tomto úseku je vykonaná prvotná segmentácia spinálneho kanálu pomocou iteratívnej aplikácie modelu náhodnej prechádzky a metódy aktívnych kontúr bez hranovej funkcie (kapitola 1.4.2).

Prvotná aplikácia modelu náhodnej prechádzky

Najskôr je v každom transverzálnom reze inicializačného úseku použitý algoritmus náhodnej prechádzky, ktorého praktická implementácia pre 2D obrazy vychádza z kódu pre MATLAB[®] poskytnutého autorom článku [6]. Konkrétne sa využíva modifikovaná funkcia `random_walker` v kombinácii s balíčkom Graph Analysis Toolbox, ktoré sú voľne prístupné online ¹. Jediným voliteľným parametrom pôvodného


¹Zdrojové kódy dostupné z: <<http://leogrady.net/software/>>

algoritmu je koeficient β (viď vzťah 1.1), pričom bolo ponechané základné nastavenie $\beta = 90$ (testovaním sa zistilo, že β ovplyvňuje pri dostatočne vysokej hodnote výsledok segmentácie iba minimálne). Na vstup funkcie sa okrem tejto konštanty privádza segmentovaný 2D obraz (príslušný transversálny rez 3D obrazu), súradnice semienok prislúchajúcich jednotlivým oblastiam (vo všeobecnosti možno obraz rozdeliť na ľubovoľné množstvo segmentov) a každé semienko je označené indexom danej oblasti. V originálnej verzii kódu sú následne pixely obrazu priradené tomu semienku, pre ktoré bola na základe modelu náhodnej prechádzky vypočítaná najvyššia pravdepodobnosť. Pre potreby tejto práce, kde obraz rozdelujeme iba na dva segmenty (t.j. objekt – spinálny kanál a pozadie), bol navyše zavedený nastaviteľný prah P ako dodatočný vstupný parameter funkcie `random_walker`. Pokiaľ je pravdepodobnosť príslušnosti pixelu k objektu menšia ako P , je tento pixel zaradený do pozadia. Takto možno pomocou modelu náhodnej prechádzky získať iba tie pixely, ktoré patria do spinálneho kanálu so zvolenou pravdepodobnosťou. V rámci celého programu je použitý jednotný, empiricky zistený prah $P = 0,6$.

Okrem semienok segmentovaného objektu (jeden bod z oblasti spinálneho kanálu v každom transversálnom reze inicializačného úseku) je potrebné ešte stanoviť semienka pozadia. Na základe uváženia anatomických parametrov kanálu sú za pozadie považované všetky pixely daného rezu, ktoré ležia mimo kružnice so zvoleným polomerom R (uvedeným v počte pixelov) a so stredom na pozícii semienka objektu. V navrhnutom algoritme $R = 8$, nastavenie tohto parametru však závisí predovšetkým na rozlíšení segmentovaného obrazu v transversálnej rovine. Výsledkom algoritmu náhodnej prechádzky je binárny obraz – maska (viď obrázok 3.4), ktorá každý pixel identifikuje ako bod spinálneho kanálu alebo pozadia.

Iteratívna segmentácia

Výstup prvotnej segmentácie vstupuje do iteratívneho procesu, v ktorom je model náhodnej prechádzky aplikovaný s rovnakými parametrami β a P , ako je uvedené vyššie. Za semienka objektu sú však v tomto prípade dosadené pixely, ktoré boli zaradené do objektu v predchádzajúcom kroku. Semienka pozadia sa určia ako všetky pixely mimo kružnice s polomerom R a stredom na pozícii centroidu spinálneho kanálu vymedzeného v danom reze pri predošlej iterácii. Tento proces by mal zabezpečiť postupné skvalitnenie segmentácie kanálu v inicializačnom úseku, ktorá je potom východiskom pre ďalšie kroky navrhnutej metódy. Celkovo je uskutočnených 5 iterácií s popísanou štruktúrou, tento počet bol zvolený s ohľadom na čas výpočtu a na fakt, že zvyšovaním počtu iterácií sa nedosiahlo výrazné zlepšenie segmentácie.



Obr. 3.4: Ukážka výstupu segmentačného algoritmu v podobe binárnej masky, v ktorej je každý voxel vysegmentovaného objektu biely (má hodnotu 1). Na obrázku a) je stredný sagitálny rez 3D obrazu prekrytý maskou, obrázok b) predstavuje transverzálny rez zodpovedajúci červenej línii v a).

Aplikácia metódy aktívnych kontúr a zavedenie obmedzenia

Výstup iteratívnej aplikácie modelu náhodnej prechádzky vo forme binárnej masky je potom priamo vstupom pre metódu aktívnych kontúr bez hranovej funkcie, ktorá je implementovaná pomocou funkcie `activecontour`. Táto funkcia je súčasťou knižnice Image Processing Toolbox pre MATLAB® a pri vhodnom nastavení realizuje metódu popísanú v [8]. Binárna maska vstupujúca do funkcie slúži na odvodenie počiatočnej kontúry, ktorá sa určí ako hranica objektu (objektov) masky. Kontúra sa potom vyvíja po zvolený počet iterácií N na základe príznakov zo vstupného obrazu, v tejto práci $N = 10$ (relatívne malý počet iterácií metódy si môžeme dovoliť vzhľadom na fakt, že počiatočná kontúra ako výsledok segmentácie algoritmom náhodnej prechádzky by mala byť málo odlišná od požadovaného stavu). Okrem toho sa nastavujú ešte dva parametre funkcie – „SmoothFactor“ (S) a „ContractionBias“ (C). Prvý parameter nadobúda kladné hodnoty (zvyčajne v rozsahu 0 až 1) a ovplyvňuje tvar výslednej kontúry (kontúr) tak, že jeho zvýšením získame hladšie krivky. Pri nízkej hodnote tohto faktoru je kontúra flexibilnejšia a lepšie sa prispôbí členeným hraniciam. Hodnota parametru C sa pohybuje v rozsahu -1 až 1 a udáva, či bude mať krivka tendenciu sa kontrahovať (pre $C > 0$) alebo expandovať (pre $C < 0$). Použité sú empiricky zistené hodnoty $S = 0,5$; $C = -0,6$. Výstupom funkcie `activecontour` je opäť binárna maska s vysegmentovaným objektom. Ako

je dokladované v kapitole 4.1, zretazenie algoritmov náhodnej prechádzky a aktívnych kontúr bez hranovej funkcie poskytuje mierne zlepšenie výsledkov segmentácie.

Poslednou časťou segmentácie v inicializačnom úseku je zavedenie jednoduchého obmedzenia s cieľom aspoň čiastočne eliminovať nežiaduci jav, pri ktorom sú do oblasti spinálneho kanálu zaradené aj okolité štruktúry podobnej intenzity. Vypočíta sa euklidovská vzdialenosť jednotlivých pixelov objektu novej masky získanej metódou aktívnych kontúr od centroidu objektu v pôvodnej maske, ktorá vstupovala do algoritmu. Následne sú z objektu vyradené všetky pixely, pre ktoré je táto vzdialenosť väčšia ako zvolený prah H . Ide vlastne o vyradenie pixelov mimo kruhového okolia centroidu s polomerom H , čím sa rešpektuje približne kruhový tvar spinálneho kanálu v transverzálnych rezoch. Testovaním bola určená hodnota prahu $H = h + 3$, kde h je medián euklidovských vzdialeností pixelov objektu v pôvodnej maske od centroidu tohto objektu.

3.1.4 Propagácia segmentácie

Po ukončení segmentácie v inicializačnom úseku je potrebné vykonať segmentáciu aj v ostatných transverzálnych rezoch, kde už nie sú definované počiatkové semienka. Vychádza sa preto z predpokladu kontinuity spinálneho kanálu – segmentačný algoritmus je postupne propagovaný smerom nadol, resp. nahor od inicializačného úseku, pričom počiatkové podmienky sú stanovené vždy na základe segmentácie v predchádzajúcom reze (využijú sa teda iba okrajové rezy inicializačného segmentu). V tejto časti sú segmentačné metódy aplikované jednorázovo s ohľadom na výpočtový čas. Okrem toho sa predpokladá, že iteratívna segmentácia v inicializačnom úseku poskytne dostatočne kvalitné východisko pre ďalšie kroky.

Súradnice semienok objektu pre algoritmus náhodnej prechádzky sa odvodí z binárnej masky prislúchajúcej k predchádzajúcemu rezu tak, že sa spinálny kanál v tejto maske zmenší odstránením pixelov ležiacich na jeho hranici. Ide prakticky o eróziu (kapitola 1.5.1) s kruhovým štruktúrnym elementom, ktorého polomer určuje hĺbku erózie (t.j. o koľko pixelov bude objekt v danom mieste zmenšený). Pre potreby tejto práce bola zvolená erózia o hĺbke dvoch pixelov, čo zabezpečí dostatočné zmenšenie objektu tak, aby boli rešpektované zmeny v pozícii a tvare spinálneho kanálu v susedných transverzálnych rezoch. Takto upravený objekt (posunutý v smere kraniálno-kaudálnom na pozíciu príslušného transverzálneho rezu) potom predstavuje inicializačné semienka spinálneho kanálu. Semienka pozadia sú stanovené obdobne ako v kapitole 3.1.3, stred kružnice s polomerom R leží na pozícii centroidu erodovaného objektu. Ostatné parametre algoritmu (β , P) sú zachované.

Výsledná segmentácia pre daný rez ja opäť získaná metódou aktívnych kontúr bez hranovej funkcie, ktorá pracuje s výstupom náhodnej prechádzky. Nastavenia funkcie

activecontour sú zvolené tak, ako je uvedené v kapitole 3.1.3. Rovnakým spôsobom je použité aj obmedzenie výslednej binárnej masky, ktoré je však v tomto prípade aplikované aj na výstup náhodnej prechádzky (ešte pred jeho použitím pre metódu aktívnych kontúr). Pritom sú všetky euklidovské vzdialenosti počítané vzhľadom na centroid počiatočného erodovaného objektu.

Ukončovacou podmienkou pre propagáciu segmentácie je situácia, kedy po niektorom z vyššie popísaných krokov (erózia, aplikácia modelu náhodnej prechádzky alebo metódy aktívnych kontúr) získame na výstupe prázdnu masku bez objektu – spinálneho kanálu. K tomuto javu dochádza prirodzene v kaudálnom smere, kde sa spinálny kanál postupne zužuje a zaniká. V kraniálnom smere však kanál aj miecha plynule prechádzajú do mozgu a v tomto prípade by zrejme takto postavená podmienka pre ukončenie zlyhala. Keďže sa predpokladá použitie metódy na snímky zobrazujúce iba časť pacienta zodpovedajúcu chrbtici (v klinickej praxi sa napokon hlava zvyčajne zobrazuje osobitne) a na takých snímkach prebiehalo aj testovanie algoritmu (viď kapitola 4), nebol tento problém riešený.

3.1.5 Vyhladenie

Poslednou fázou segmentácie spinálneho kanálu je vyhladenie, ktoré pozostáva zo striedavej aplikácie morfológických operátorov a metódy aktívnych kontúr bez hranej funkcie na trojrozmerný obraz.

Aplikácia morfológických operácií

Najskôr je objem spinálneho kanálu získaný po predchádzajúcich krokoch podrobený binárnej erózii pomocou 3D štruktúrneho elementu tvaru gule s polomerom 1 voxel. Rozdiel medzi pôvodným a erodovaným objektom potom tvorí povrch pôvodného objektu, t.j. spinálneho kanálu. Voxely tohto povrchu sú následne prahované – všetky voxely s intenzitou pod zvoleným prahom E sú zaradené do pozadia. Proces erózie a prahovania je opakovaný e -krát, v navrhnutom algoritme $e = 5$.

V ďalšom kroku je naopak na spinálny kanál aplikovaná binárna dilatácia s rovnakým štruktúrnym elementom ako v prípade erózie. Tým získame trojrozmerný „obal“ kanálu o hrúbke 1 voxelu, ktorý prahujeme pomocou prahu D – voxely s jasovou hodnotou vyššou ako D sú považované za body kanálu. Celý postup je opäť iteratívny, zvolený počet iterácií je $d = 10$. Hodnota prahu D je určená ako súčet priemernej intenzity voxelov pôvodného obrazu, ktoré boli priradené k spinálnemu kanálu (ešte pred vyhladením) a smerodajnej odchýlky intenzít týchto voxelov. Prah E sa získa obdobne ako D , smerodajná odchýlka sa však v tomto prípade od priemeru odčíta. Počty iterácií pre jednotlivé operácie boli stanovené experimentálne. Poznamenajme,

že tento postup je optimalizovaný pre testovacie T2-váhované MRI snímky. Predpokladom pre správnu funkciu prahovania je totiž vysoká intenzita voxelov spinálneho kanálu v porovnaní s okolitými tkanivami (v prípade T2-váhovaných MRI obrazov je to zabezpečené výrazným zobrazením cerebrospinálnej tekutiny).

Po aplikácii uvedených morfológických operácií nakoniec dochádza na úrovni jednotlivých transversálnych rezov k finálnym úpravám v podobe vyplnenia dier v segmentovanom objekte a vyhladenia jeho hraníc podľa jednoduchého pravidla – pokiaľ je pixel pozadia obklopený minimálne štyrmi pixelmi objektu (uvažuje sa osem okolitých pixelov), tak je zaradený do spinálneho kanálu. Testované sú pritom iba pixely v blízkom okolí kanálu, aby sa znížila náročnosť výpočtu. Uvedený postup by mal prispieť k dosiahnutiu kompaktnejšej segmentácie.

Použitie metódy aktívnych kontúr

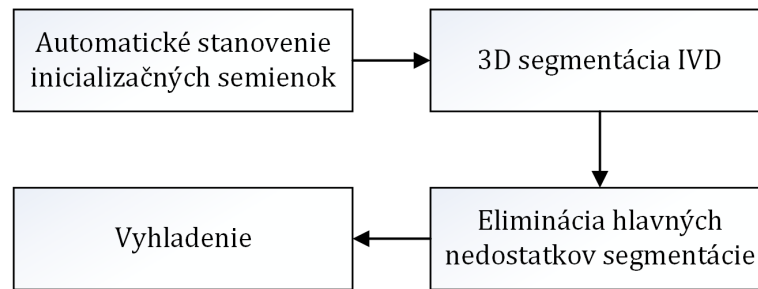
Pre zlepšenie segmentácie v problematických oblastiach je možné výsledok popisaneho vyhladenia opätovne podať na vstup metódy aktívnych kontúr bez hranovej funkcie. Metóda je aplikovaná na transversálne rezy, spinálny kanál (objekt) vysegmentovaný v jednotlivých rezoch slúži po zmenšení – 2D erózii (viď kapitola 3.1.4) pre odvodenie počiatočnej kontúry aj zavedenie obmedzenia výslednej segmentácie do kruhového okolia centroidu tohto objektu (viď kapitola 3.1.3). V navrhnutom algoritme je tento krok nasledovaný ešte jednou iteráciou vyhladenia pomocou morfológických operácií. Prakticky možno aplikovať striedavo metódu aktívnych kontúr a morfológické operátory s ľubovoľným počtom opakovaní, je však potrebné zohľadniť celkový čas výpočtu a samozrejme efekt takého prístupu na výsledok segmentácie.

3.2 Segmentácia intervertebrálnych diskov

Po vymedzení spinálneho kanálu sa započína segmentácia IVD, bloková schéma tejto časti algoritmu je na obrázku 3.5. Zásadnou zmenou oproti segmentácii spinálneho kanálu je automatické stanovenie inicializačných semienok pre model náhodnej prechádzky. Okrem toho je algoritmus prispôbený pre segmentáciu v troch dimenziách, narozdiel od 2D segmentácie v transversálnych rezoch počas prvej fázy.

3.2.1 Stanovenie inicializačných semienok


Súradnice semienok objektov – intervertebrálnych diskov sa odvodí na základe polohy vymedzeného spinálneho kanálu, pričom sa vychádza z anatomických vzťahov medzi týmito štruktúrami.



Obr. 3.5: Bloková schéma algoritmu pre segmentáciu IVD.

Vymedzenie oblasti pre stanovenie semienok


Prvým krokom je stanovenie prednej línie kanálu v strednom sagitálnom reze obrazu (resp. v reze, ktorý bol užívateľom zvolený pre stanovenie semienok kanálu) – táto línia pozostáva z prvých pixelov objektu v jednotlivých riadkoch obrazovej matice v horizontálnom smere. Následne dochádza k posunutiu línie o definovaný počet pixelov a vo ventrálnom smere a vymedzí sa „pás“ šírky b pixelov tak, že posunutá línia je mediálnou čiarou pásu. V tejto oblasti, ktorá svojím umiestnením zodpovedá chrbtici, sa budú hľadať semienka prislúchajúce IVD. Posunutie prednej línie spinálneho kanálu a šírka vymedzeného pásu sú závislé najmä na rozlíšení obrazu v sagitálnej rovine, pre testovacie dáta použité v tejto práci boli zvolené hodnoty $a = 16$, $b = 9$ pixelov. Ukážka segmentovaného kanálu a príslušného pásu pri použití týchto parametrov je na obrázku 3.6.



Obr. 3.6: Ukážka stanovenia oblasti (pásu) pre určenie inicializačných semienok patriacich k IVD. Bielou farbou je označený spinálny kanál, vymedzený pás je červený.

Prahovanie

Vo vymedzenej oblasti sa najskôr uplatní prahovanie za účelom odlíšenia IVD a stavcov. Využíva sa prítomnosť kortikálnej vrstvy stavcov, ktorá má na testovacích T2-váhovaných MRI snímkach nižšiu intenzitu ako okolité štruktúry. Hmota IVD je naopak zobrazená s mierne vyššou intenzitou ako kostené stavce. V oblasti záujmu tak nachádzame zvyčajne tri skupiny pixelov odlíšiteľné na základe jasovej hodnoty. Pre stanovenie prahu možno v tejto situácii s výhodou použiť Otsuovu metódu, ktorá je implementovaná v rámci knižnice Image Processing Toolbox pre MATLAB®. Príslušná funkcia umožňuje nastavenie počtu vypočítaných prahových hodnôt – v tomto prípade stanovíme dvojicu prahov a použijeme menší z nich. Pixely s podprahovou intenzitou zodpovedajúce kortikálnej časti stavcov budú z vymedzeného pásu odstránené (priradí sa im nulová hodnota) a tým sa pás rozdelí (v optimálnom prípade) na izolované oblasti diskov, resp. stavcov. Stanovenie dvoch prahov ošetrí prípad, kedy je intenzitný rozdiel medzi IVD a vnútornými časťami stavcov výraznejší ako rozdiel intenzity kortikálnych a vnútorných častí stavcov – v tejto situácii by sme stanovením jedinej hodnoty Otsuovou metódou získali nesprávny (vyšší) prah. Prahovaný pás sa nakoniec prevedie do binárnej podoby – nenulové hodnoty budú mať iba pixely prislúchajúce objektom (viď obrázok 3.7).



Obr. 3.7: Prahovaná oblasť pre stanovenie inicializačných semienok IVD v binárnej podobe. Jednotlivé izolované objekty zodpovedajú striedavo IVD, resp. telám stavcov.

Stanovenie semienok pre IVD


Na odlíšenie jednotlivých objektov vytvorených prahovaním je použitá metóda rozvodí (kapitola 1.4.3), opäť priamo dostupná v MATLABe® (Image Processing Tool-

box). Vstup algoritmu je odvodený z distančnej mapy pôvodného binárneho obrazu pri použití euklidovskej vzdialenostnej metriky (kapitola 1.5.3), na výstupe metóda poskytne jednotlivé objekty odlíšené pomocou označenia pixelov týchto objektov rozličnými indexmi. Algoritmus však často rozdelí na niekoľko oblastí aj celistvé objekty, čo je nežiaduce. Zavádza sa preto jednoduchá úprava, ktorá zlúči všetky dotýkajúce sa segmenty do jediného celku.

Za účelom zvýšenia spoľahlivosti boli do procesu stanovenia semienok pre IVD zaradené dva špecifické postupy. V prvom prípade sa jedná o ošetrovanie situácie, v ktorej dochádza pri prahovaní k úplnému odstráneniu oblastí prislúchajúcich k IVD zobrazeným s netypicky nízkou intenzitou, čo môže byť spôsobené ich odlišnou štruktúrou, napr. v dôsledku patologických procesov (viď obrázok 3.8a). Najskôr je pre každú dvojicu susedných objektov vypočítaná ich vzájomná vzdialenosť ako minimálna euklidovská vzdialenosť pixelov patriacich do týchto oblastí. Z takto získaných hodnôt zaokrúhlených na celé čísla je určený modus m . Následne sa medzi každé dve oblasti, ktorých vzdialenosť presahuje hodnotu prahu $M = m + 2$, umelo vloží objekt obdĺžnikového tvaru ako náhrada za chýbajúce semienka. Šírka vloženého objektu je odvodená z horizontálnych rozmerov príslušných susediacich oblastí a jeho výška sa stanoví tak, aby vzniknuté medzery medzi objektmi mali vo vertikálnom smere veľkosť 2 pixely (pokiaľ nie je možné túto podmienku splniť, k vytvoreniu nového objektu nedôjde).

Druhým častým problémom pri stanovení semienok je situácia ilustrovaná na obrázku 3.8b. V dôsledku prítomnosti nevýraznej či degradovanej kortikálnej časti stavca nedochádza pri prahovaní k rozdeleniu oblastí zodpovedajúcich stavcom a IVD, čo môže spôsobiť nesprávne určenie semienok aj pre ostatné disky (viď nasledujúci odsek). Preto bol zavedený jednoduchý postup, v rámci ktorého sa vytvára mediálna línia pôvodného prahovaného pásu posunutá v horizontálnom smere o 2 pixely doľava, resp. doprava. Ak sa aspoň v jednej z týchto línií nachádzajú pixely pozadia (označenú nulovou hodnotou) obklopené pixelmi rovnakého objektu, dochádza na pozíciách týchto pixelov k dodatočnému rozdeleniu danej oblasti vo vodorovnom smere. Vychádza sa z predpokladu, že na rozhraní medzi stavcom a IVD vzniká po prahovaní aspoň čiastočné oddelenie tak, ako ukazuje obrázok 3.8b. Aby sa predišlo rozdeleniu na nesprávnych pozíciách, je uvedený postup aplikovaný jedine v prípade, že v rámci oblasti pre stanovenie semienok bolo evidované narušenie pravidelného striedania menších a väčších objektov (porovnávajú sa plochy susedných oblastí). Táto požiadavka vyplýva z anatomických rozmerov diskov, ktoré majú v sagitálnej rovine výrazne menší obsah prierezu ako telá stavcov (z porovnávania sú vylúčené iba okrajové objekty, na ktoré sa v dôsledku orezania obrazu nemusí uvedený predpoklad vzťahovať).

Napokon je nutné stanoviť, ktoré z vytvorených objektov predstavujú IVD a ktoré



Obr. 3.8: Problémy pri stanovení inicializačných semienok pre IVD. Z dôvodu nízkej intenzity sú semienka diskov na označených pozíciách v obrázku a) odstránené pri prahovaní. Vyznačené miesto na obrázku b) ilustruje situáciu, v ktorej nedošlo k rozdeleniu oblasti stavca a IVD kvôli nevýraznej kortikálnej časti stavca v danom úseku. Semienka IVD, resp. pozadia sú reprezentované bielymi, resp. čiernymi pixelmi a v dôsledku uvedených nedostatkov sú identifikované chybné.

zodpovedajú stavcom. Využíva sa postup, pri ktorom najskôr identifikujeme objekt s minimálnym plošným obsahom a tento budeme považovať za oblasť IVD (opäť sa neuvažujú okrajové oblasti). Vzhľadom na polohu takto nájdeného objektu sa potom stanoví poradie ostatných objektov vo vertikálnom smere a každý druhý sa označí ako IVD. Predpokladom je v tomto prípade vzájomné striedanie stavcov a IVD v rámci chrbtice. Pixely priradené k IVD potom vstupujú do algoritmu náhodnej prechádzky ako semienka segmentovaného objektu, všetky ostatné pixely (z oblasti stavcov) sú považované za pixely pozadia. Keďže sa využíva 3D model náhodnej prechádzky, je výhodné pracovať s objemovými vstupnými dátami (čo môže výrazne urýchliť konvergenciu metódy k požadovanému riešeniu). Z tohto dôvodu je poslednou úpravou inicializačných semienok ich rozšírenie do n susedných sagitálnych rezov v oboch smeroch. Ide prakticky o „skopírovanie“ semienok do týchto rezov, čím sa vytvorí 3D objekty o dĺžke $(2n + 1)$ voxelov v transverzálnom smere, ktorých prierez v sagitálnej rovine bude zodpovedať príslušným 2D objektom. Hodnotu n je nutné zvoliť s ohľadom na transverzálne rozlíšenie, v tejto práci $n = 5$.

3.2.2 Aplikácia 3D segmentačného algoritmu


Použitie modelu náhodnej prechádzky modifikovaného pre trojrozmerný graf – obraz je základným kameňom segmentácie IVD. Realizácia algoritmu vychádza z rovnakého kódu, ktorý bol využitý pri segmentácii spinálneho kanálu. 3D verzia tejto dvojrozmernej implementácie je voľne prístupná online ². Aj v tomto prípade bola funkcia vykonávajúca výpočet pravdepodobností pre jednotlivé voxely a semienka upravená tak, že je možné na jej vstup podať prah P a do objektu budú zaradené iba voxely s nadprahovou pravdepodobnosťou príslušnosti k IVD. Ďalšími vstupmi sú koeficient β , segmentovaný 3D obraz a semienka stanovené v predchádzajúcom kroku označené indexmi pre objekt alebo pozadie. Rovnako ako pri segmentácii spinálneho kanálu $P = 0,6$; $\beta = 90$.

Jedinou ďalšou významnou zmenou oproti pôvodnému kódu je obmedzenie maximálneho počtu iterácií L metódy riešenia sústavy rovníc, ku ktorej vedie model náhodnej prechádzky (pre navrhnutý algoritmus $L_{max} = 600$). Výpočtové nároky sú totiž oveľa vyššie ako v prípade 2D segmentácie a pri použití maximálnej prípustnej chyby ako ukončovacej podmienky pre riešenie problému (čo je aplikované v pôvodnej verzii algoritmu) je čas výpočtu neúmerne dlhý, pretože je zvolená nízka hodnota odchýlky. Limitácia počtu iterácií môže samozrejme znížiť kvalitu segmentácie, predovšetkým vzniká nedostatok ilustrovaný na obrázku 3.9. Keďže výpočet pravdepodobností začína pre voxely v blízkosti inicializačných semienok, segmentácia v okrajových častiach obrazu je pri predčasnom ukončení algoritmu nedokončená. To sa prejavuje tak, že tieto oblasti sú nesprávne priradené k objektu. Z hľadiska vymedzenia IVD však táto skutočnosť nepredstavuje zásadnú prekážku a je možné sa s ňou vysporiadať jednoduchým spôsobom popísaným v kapitole 3.2.3. Druhý typ problému, ktorý vzniká pri 3D segmentácii, je vyznačený na obrázku 3.9 žltými šípkami. Ide o izolované skupiny nesprávne identifikovaných voxelov, spravidla oveľa menších rozmerov ako vysegmentované IVD. Postup riešenia tohto nedostatku je taktiež súčasťou nasledujúcej kapitoly.

3.2.3 Odstránenie nedostatkov 3D segmentácie

Za účelom správneho priradenia okrajových častí obrazu je možné využiť operáciu flood-fill, pretože tieto oblasti sú izolované od IVD voxelmi pozadia (viď obrázok 3.9). Algoritmus flood-fill začína na pozícii zadaných štartovacích bodov a dochádza k rozrastaniu oblasti postupným pridávaním voxelov, ktoré sú v kontakte s regiónom vymedzeným v predchádzajúcom kroku a majú rovnakú intenzitu ako inicializačný

²Zdrojové kódy dostupné z: <https://github.com/npathak/RW_segmentation>



Obr. 3.9: Nedostatky 3D segmentácie IVD. Červenou farbou sú označené pixely, ktoré boli na základe algoritmu náhodnej prechádzky priradené k IVD.

bod. Pritom je nutné špecifikovať tzv. konektivitu obrazovej matice – tento parameter stanovuje, ktoré voxely z okolia uvažovaného bodu sú s týmto bodom v kontakte a ktoré teda budú testované pre priradenie do vymedzovanej oblasti. Použitá je základná konektivita so šiestimi voxelmi, ktoré priamo susedia s uvažovaným voxelom v 3D obrazovej matici. Ako inicializačné body algoritmu sú stanovené 2 dvojice voxelov vo vzájomne protilahlých rohoch matice, okrem toho je na vstup funkcie realizujúcej operáciu flood-fill v MATLAB[®] (Image Processing Toolbox) privedená 3D binárna maska ako výsledok segmentácie metódou náhodnej prechádzky. Tieto nastavenia vo výsledku zabezpečia „vyplnenie“ okrajových oblastí, v ktorých budú voxely priradené k pozadiu.

Pri eliminácii malých roztrúsených skupín voxelov nesprávne zaradených do oblasti IVD najskôr vychádzame zo vzájomnej anatomickej polohy spinálneho kanálu a diskov. Identifikované a následne preklasifikované sú všetky voxely priradené k IVD, ktoré ležia v akomkoľvek sagitálnom reze za prednou líniou spinálneho kanálu v dorzálnom smere a pod posledným bodom kanálu v smere kaudálnom. V týchto regiónoch totiž nie je prítomnosť IVD očakávaná. Nakoniec je aplikovaný algoritmus pre odstránenie malých objektov (t.j. skupín prepojených voxelov) z binárneho obrazu. Funkcia realizujúca metódu je súčasťou knižnice Image Processing Toolbox pre MATLAB[®] a na jej vstup je okrem 3D binárnej masky privedená prahová hodnota V . Všetky objekty zložené z menej ako V voxelov budú automaticky odstránené z obrazu, experimentálne stanovená hodnota použitá v práci je $V = 50$. Opäť je potrebné stanoviť konektivitu pre posúdenie prepojenia voxelov, v tomto

prípade každý voxel susedí s 26 voxelmi kocky s hranou dĺžky troch voxelov a so stredom na pozícii uvažovaného voxelu.

3.2.4 Vyhladenie

Poslednou fázou navrhnutého algoritmu je vyhladenie segmentovaných IVD. Účelom tohto kroku je zároveň vysegmentovanie kortikálnych častí stavcov, ktoré sú zahrnuté do manuálnej („ground truth“) segmentácie IVD dostupnej pre testovacie MRI snímky a ktoré nie sú vymedzené metódou náhodnej prechádzky z dôvodu odlišnej intenzity vzhľadom na IVD. Tento efekt sa dosiahne iteratívnou aplikáciou binárnej dilatácie s guľovým štruktúrnym elementom, získaním „obalu“ segmentovaných diskov a jeho následným prahovaním tak, ako je popísané v kapitole 3.1.5. Prahová hodnota je v tomto prípade totožná s prahom vypočítaným Otsuovou metódou pre potreby stanovenia inicializačných semienok IVD (viď kapitola 3.2.1). K objektu sú následne priradené všetky voxely 3D obalu diskov s podprahovou intenzitou, ktorá zodpovedá kortikálnym častiam stavcov. Rozdielny je ešte počet iterácii q , v ktorých sa aplikuje uvedený postup – v tejto práci $q = 5$.

Súčasťou každej iterácie je napokon vyplnenie dier v segmentovaných objektoch a vyhladenie na základe jednoduchého pravidla – pokiaľ je pixel pozadia obklopený viac ako štyrmi pixelmi objektu (uvažuje sa okolie ôsmich pixelov), je zaradený do oblasti IVD. Tieto operácie nie sú vykonávané v 3D, ale v jednotlivých dvojrozmerných rezoch obrazu, a to osobitne pre všetky transverzálne aj sagitálne rezy, v ktorých sú prítomné vysegmentované IVD.

4 VÝSLEDKY A DISKUSIA

Navrhnutý algoritmus bol testovaný na trojrozmerných MRI obrazoch z databázy, ktorú voľne poskytuje Prof. Dr. Guoyan Zheng (Institute for Surgical Technology and Biomechanics, University of Bern, Švajčiarsko) prostredníctvom portálu SpineWeb³. Dr. Zheng je spoluautorom publikácie [14], v ktorej je prezentovaná metóda pre lokalizáciu a segmentáciu IVD v 3D obrazoch (viď kapitola 2) a postup je testovaný okrem iného aj na týchto dátach. Databáza pozostáva z 3D T2-váhouvaných turbo spin echo MRI snímok 15 anonymných pacientov, pričom všetky obrazy obsahujú minimálne sedem IVD spodnej chrbtice v oblasti Th₁₁ až L₅. Každý pacient bol nasnímaný pomocou 1,5 T MRI skeneru od spoločnosti Siemens (Siemens Magnetom Sonata, Siemens Healthcare, Erlangen, Nemecko). Súčasťou databázy je manuálna segmentácia IVD vo forme binárnej masky pre jednotlivé snímky (pre každý subjekt je vysegmentovaných 7 diskov), ktorá slúži ako referencia („ground truth“). Všetky dáta sú uložené vo formáte NIFTI.

Testovanie algoritmu bolo vykonané na osobnom počítači s procesorom Intel® Core™ i7 2,50 GHz, pamäťou RAM veľkosti 8 GB a grafickou kartou NVIDIA GeForce GTX 860M. V testovacej databáze sa nachádzajú 3D obrazy dvoch odlišných rozmerov – pre snímky veľkosti 39 × 305 × 305 (3 627 975 voxelov) bola rýchlosť spracovania dát približne 2,75 min, segmentácia v objeme o rozmeroch 48 × 304 × 304 (4 435 968 voxelov) prebehla v priemere za cca 3,25 min.


4.1 Segmentácia spinálneho kanálu

Zásadným faktorom, ktorý ovplyvňuje výsledok segmentácie spinálneho kanálu, je interaktívne umiestnenie inicializačných semienok. Samozrejým predpokladom je, že užívateľ označí iba body prislúchajúce kanálu. Na T2-váhouvaných MRI snímkach však spinálny kanál pozostáva z dvoch regiónov, ktoré sa výrazne líšia svojou intenzitou – ide o miechu a cerebrospinálnu tekutinu (viď kapitola 1.3.2). Budeme preto navyše požadovať, aby boli inicializačné semienka umiestnené v oblasti mozgovomiešneho moku. Pri splnení tejto požiadavky potom výsledná segmentácia nie je výrazne závislá na polohe či počte semienok, ako je ukázané na obrázku 4.1.


Problematické je umiestnenie semienok do oblasti miechy s výrazne nižšou intenzitou ako okolitá tekutina. To zvyčajne spôsobí predčasné zastavenie propagácie segmentačného algoritmu, pretože počiatočná segmentácia metódou náhodnej prechádzky sa obmedzí na malú oblasť prislúchajúcu mieche a následná erózia pre získanie inicializačných semienok v ďalšom transverzálnom reze (kapitola 3.1.4) môže

³<http://spineweb.digitalimaginggroup.ca/spineweb/index.php?n=Main.HomePage>


viest k úplnému odstráneniu semienok a k ukončeniu segmentácie. Tento jav je ilustrovaný na obrázku 4.2.



Obr. 4.1: Segmentácia spinálneho kanálu v strednom sagitálnom reze pri správnom umiestnení počiatočných semienok do oblasti cerebrospinálnej tekutiny. Červenou farbou sú vyznačené zvolené semienka – segmentácia nie je výrazne odlišná pri označení jediného bodu (a)) a pri stanovení väčšieho počtu semienok (b)).



Obr. 4.2: Výsledok segmentácie spinálneho kanálu v strednom sagitálnom reze pri nevhodnom umiestnení inicializačných semienok do oblasti miechy. Segmentačný algoritmus bol v kaudálnom smere ukončený predčasne.



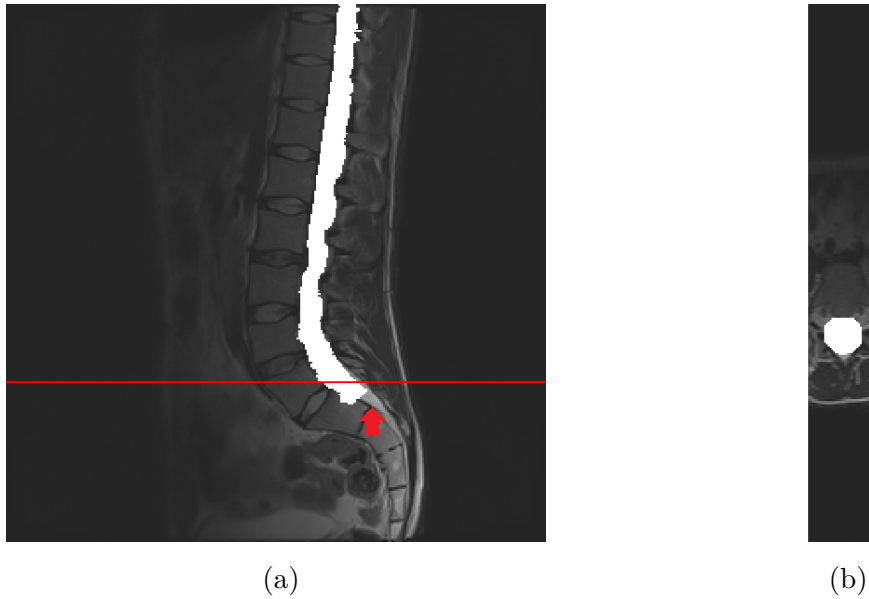
(a) Po prvej iterácii vyhladenia morfológickými operáciami

(b) Po aplikácii metódy aktívnych kontúr bez hranovej funkcie na obraz z a)


Obr. 4.3: K vplyvu metódy aktívnych kontúr bez hranovej funkcie na výsledok segmentačného algoritmu. Vo vyznačených oblastiach dochádza k miernemu zlepšeniu segmentácie.

Opodstatnenie zaradenia metódy aktívnych kontúr bez hranovej funkcie do navrhnutého algoritmu dokladuje obrázok 4.3. Tento krok dokáže v niektorých prípadoch vylepšiť výsledok segmentácie metódou náhodnej prechádzky a rovnako tak aj výstup vyhladenia segmentovaného objemu pomocou morfológických operácií (kapitola 3.1.5). Konkrétne sa dosahuje doplnenie segmentácie v niektorých špecifických miestach, ako napr. „výbežkoch“ spinálneho kanálu medzi telami stavcov, ktoré sú zreteľné predovšetkým v lumbálnej oblasti na sagitálnych rezoch obrazu.

Hlavné nedostatky navrhnutého algoritmu sa prejavujú pri segmentácii terminálnej časti kanálu. V tomto regióne má kanál najväčšie zakrivenie a postupne zaniká v oblasti krížovej kosti a kostrče. Ako ilustruje obrázok 4.4, problémy sú spojené predovšetkým s nedokončením segmentácie úzkej koncovej časti kanálu a s nekvalitnou segmentáciou v oblasti jeho najväčšieho zakrivenia. Tento jav sa neprejavuje tak výrazne v prípade menšieho zakrivenia kanálu (viď obrázok 4.1) a môže súvisieť s nízkou schopnosťou algoritmu prispôbiť sa pri propagácii zmene polohy a veľkosti kanálu v susedných transverzálnych rezoch. Na druhej strane je navrhnutá metóda schopná správne vymedziť kanál vychýlený od vertikály v mediolaterálnom smere, čo dokumentuje obrázok 4.5. Ide o vlastnosť, ktorá je dôležitá z hľadiska použitia algoritmu pre snímky skoliotických pacientov.



Obr. 4.4: Nedostatky segmentácie spinálneho kanálu. Na obrázku a) je šípkou vyznačená koncová časť kanálu s nedokončenou segmentáciou. Obrázok b) je transverzálny rez obrazu zodpovedajúci červenej línii v a), ktorý dokumentuje „vyliatie“ segmentácie v oblasti najväčšieho zakrivenia kanálu – do segmentovaného objemu sú nesprávne zaradené voxely mimo kanál s podobnou intenzitou.



Obr. 4.5: Segmentácia vychýleného spinálneho kanálu. Na obrázku a) je zobrazená projekcia výsledku segmentácie nedeformovaného kanálu do frontálnej roviny. Obrázok b) obsahuje rovnakú projekciu pre kanál v hornej časti vychýlený v mediolaterálnom smere a dokladuje schopnosť segmentačného algoritmu prispôbiť sa tejto deformácii.




Obr. 4.6: Nedostatky segmentácie spinálneho kanálu. Segmentácia nepokračuje do oblastí cerebrospinálnej tekutiny, ktoré sú izolované miechou od ostatnej časti kanálu s tekutinou.

Napokon uvedieme ešte jeden problematický aspekt segmentácie spinálneho kanálu, ktorý opäť súvisí s jeho dvojitou intenzitou v dôsledku vyššie spomínaného rozdielu medzi zobrazením miechy a cerebrospinálnej tekutiny na T2-váňovaných MRI snímkach. V niektorých prípadoch dochádza k tomu, že algoritmus v určitom úseku vysegmentuje iba časť kanálu zodpovedajúcu tekutine na jednej strane miechy. Táto situácia je zobrazená na obrázku 4.6 a nastáva najmä v prítomnosti mohutnej miechy a oblastí cerebrospinálnej tekutiny, ktoré sú miechou izolované od ostatnej časti kanálu s tekutinou (na obrázku 4.6 je taká oblasť vyznačená červeným krúžkom).


4.2 Segmentácia intervertebrálnych diskov

Výsledok segmentácie IVD sa odvíja od korektného vymedzenia spinálneho kanálu a následného automatického stanovenia inicializačných semienok pre 3D model náhodnej prechádzky. Určenie semienok je kompromitované najmä v prípade nekvalitnej segmentácie kanálu v strednom sagitálnom reze (resp. v reze, ktorý bol užívateľom zvolený pre stanovenie semienok kanálu). Ako je ilustrované na obrázku 4.7, môže táto skutočnosť viesť napr. k nežiaducej fragmentácii oblasti pre určenie semienok IVD v druhej fáze algoritmu.


Príklad výsledku segmentácie IVD v prípade, že stanovenie inicializačných semienok prebehne korektne, je znázornený na obrázku 4.8. Ide o finálnu segmentáciu



Obr. 4.7: Problémy pri stanovení inicializačných semienok pre IVD. V dôsledku nekvalitnej segmentácie spinálneho kanálu (obrázok a)) dochádza vo vyznačenej oblasti k vzniku fragmentovaných objektov (obrázok b)), ktoré nezodpovedajú usporiadaniu stavcov a IVD. Semienka IVD, resp. pozadia sú reprezentované bielymi, resp. čiernymi pixelmi.



Obr. 4.8: Ukážka výsledku segmentácie IVD. Na obrázku a) sú znázornené inicializačné semienka pre IVD, obrázok b) predstavuje finálnu segmentáciu IVD v strednom sagitálnom reze. Semienka IVD, resp. pozadia sú reprezentované bielymi, resp. čiernymi pixelmi.



(a) Pred vyhladením pomocou morfológických operácií

(b) Po finálnom vyhladení

Obr. 4.9: K významu vyhladenia segmentovaných IVD. Na vyznačených miestach je zjavné zlepšenie segmentácie kortikálnych častí stavcov. Na obrázkoch a), resp. b) je zobrazený totožný sagitálny rez 3D obrazu.

po odstránení jej hlavných nedostatkov (kapitola 3.2.3) a vyhladení (kapitola 3.2.4). Význam procesu vyhladenia, predovšetkým vzhľadom na vymedzenie kortikálnych častí stavcov, je potom ilustrovaný na obrázku 4.9.

Dostupnosť manuálnej segmentácie IVD vykonanej kvalifikovanými odborníkmi umožnila kvantitatívne zhodnotenie výsledkov segmentácie diskov porovnaním binárnej masky na výstupe navrhnutého algoritmu a referenčnej masky obsiahnutej v testovacej databáze pre každého pacienta. Trojrozmerná vizualizácia týchto masiek pre zvolený subjekt je na obrázku 4.10. Posudzovaná bola najskôr úspešnosť detekcie jednotlivých IVD, pre hodnotenie kvality segmentácie sa použili dva parametre – Diceov koeficient podobnosti (DC – Dice Coefficient) a priemerná absolútna povrchová vzdialenosť (MASD – Mean Absolute Surface Distance) vypočítané podľa [17] na základe vzťahov

$$DC = \frac{2 |V_r \cap V_s|}{|V_r| + |V_s|}, \quad (4.1)$$

$$MASD = \frac{1}{|S_s|} \sum_{i=1}^{|S_s|} d_i(S_s, S_r), \quad (4.2)$$

kde V_r , resp. V_s je referenčný, resp. vysegmentovaný objem, S_r je povrch referenčného objemu, S_s je povrch segmentovaného objemu a d_i je minimálna euklidovská vzdia-



Obr. 4.10: 3D vizualizácia výsledku segmentácie IVD vytvorená na základe binárnej masky ako výstupu navrhnutého algoritmu (obrázok a)) a príslušná referenčná manuálna segmentácia (obrázok b)).

lenosť i -tého bodu povrchu S_s od S_r . Súhrn výsledkov hodnotenia obsahuje tabuľka 4.1. Uvedené hodnoty DC a MASD sú priemerom cez všetky subjekty z testovacej databázy (\pm smerodajná odchýlka) a boli počítané v prípade správne detegovaných IVD, ku ktorým existuje referenčná segmentácia. Úspešnosť detekcie sa naopak posudzovala pre všetkých 131 IVD zobrazených v databáze bez ohľadu na dostupnosť manuálnej segmentácie, pričom prítomnosť disku v určitom mieste obrazu bola hodnotená vizuálne. Je nutné poznamenať, že výsledok segmentácie je výrazne závislý na voľbe inicializačných semienok – pre účely štatistického hodnotenia boli semienka umiestňované zásadne do oblasti cerebrospinálnej tekutiny spinálneho kanálu z dôvodov, ktoré sú popísané v kapitole 4.1. Odlišné umiestnenie semienok by prinieslo zmenu hodnôt parametrov z tabuľky 4.1.

Tab. 4.1: Kvantitatívne hodnotenie výsledkov segmentácie IVD. DC – Dice Coefficient, MASD – Mean Absolute Surface Distance.

Úspešnosť detekcie	Počet pravdivo pozitívnych detekcií	120
	Počet falošne negatívnych detekcií	11
	Počet falošne pozitívnych detekcií	0
	Senzitivita [%]	91,60
Úspešnosť segmentácie	DC [%]	86,01 \pm 2,46
	MASD [mm]	0,92 \pm 0,20

Dosiahnuté výsledky je možné priamo porovnať s prácami iných autorov, ktorí pre validáciu svojho postupu použili rovnaké dáta. Jedná sa napr. o účastníkov výzvy týkajúcej sa automatickej lokalizácie a segmentácie IVD v 3D T2-váhovaných MRI dátach, ktorá bola vyhlásená v roku 2015 v rámci akcie 3rd MICCAI Workshop & Challenge on Computational Methods and Clinical Applications for Spine Imaging – MICCAI-CSI2015 ⁴. Pre účely hodnotenia kvality navrhnutých metód bola autorom poskytnutá rovnaká testovacia databáza, ako je použitá v tejto práci. V článku [18] sú prezentované porovnateľné hodnoty parametru DC ($84 \pm 1,5$ %), publikácie [19],[20],[21],[22],[23],[24] potom deklarujú výsledky v rozmedziach približne DC = 88–92 %, MASD = 0,6–1,4 mm.

⁴<https://csi2015.weebly.com/>

5 ZÁVER

Cielom tejto práce bol vývoj metódy pre segmentáciu spinálneho kanálu a IVD v objemových MRI dátach s dôrazom predovšetkým na spoľahlivosť, presnosť a automatizáciu algoritmu. Samotnému návrhu metódy predchádzalo oboznámenie sa s problematikou spracovania MRI obrazov (najmä v oblasti segmentačných techník), preštudovanie anatómie chrbtice a spracovanie literárnej rešerše zhromažďujúcej publikácie týkajúce sa vymedzenej tematiky. Taktiež bol získaný prístup k databáze 3D T2-váňovaných MRI snímok chrbtice vhodných pre testovanie algoritmu. Navrhnutý postup bol realizovaný v programovom prostredí MATLAB® R2015b, dosiahnuté výsledky následne hodnotené kvalitatívne (v prípade spinálneho kanálu aj IVD) a kvantitatívne (v prípade IVD) na základe dostupnosti referenčnej manuálnej segmentácie diskov (tzv. „ground truth“ segmentácie) obsiahnutej v testovacej databáze. Hlavným výstupom práce je programový kód, ktorý realizuje navrhnutú metódu a je súčasťou príloh k práci.

Prezentovaný algoritmus je v súčasnom stave použiteľný pre spracovanie T2-váňovaných 3D MRI snímok chrbtice. Porovnanie kvality výslednej segmentácie s aktuálnymi výsledkami iných autorov naznačuje, že sa metóda približuje vysokému štandardu nastavenému v tejto oblasti. Optimalizácia parametrov algoritmu môže priniesť ďalšie zvýšenie presnosti, čo v konečnom dôsledku vedie k možnosti použitia pre spoľahlivé kvantitatívne hodnotenia obrazových dát. Jedným z benefitov metódy je segmentácia spinálneho kanálu a súčasne IVD v rámci jedného algoritmu, čo v súčasnosti neponúka takmer žiadny z publikovaných postupov. Prijateľná rýchlosť spracovania dát a nutnosť minimálnej užívateľskej interakcie predurčujú prezentovanú metódu na využitie v klinických systémoch pre podporu diagnostiky. Ďalší vývoj môže byť následne zameraný na úplnú automatizáciu metódy či rozšírenie jej použiteľnosti na väčšie spektrum obrazových dát – od rozlične modulovaných MRI obrazov až po výstupy CT.

LITERATÚRA

- [1] VÁLEK, Vlastimil a Jan ŽIŽKA. *Moderní diagnostické metody: Magnetická rezonance (III. díl)*. Brno: Institut pro další vzdělávání pracovníků ve zdravotnictví, 1996. ISBN 80-7013-225-6.
- [2] BIDGOOD, W. Dean, Jr., Steven C. HORII, Fred W. PRIOR a Donald E. VAN SYCKLE. Understanding and Using DICOM, the Data Interchange Standard for Biomedical Imaging. *Journal of the American Medical Informatics Association* [online]. May-June 1997, 4(3), 199–212 [cit. 2017-11-13]. PMID PMC61235. Dostupné z: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC61235/>>
- [3] HOLIBKOVÁ, Alžběta a Stanislav LAICHMAN. *Přehled anatomie člověka*. 5. vyd. Olomouc: Univerzita Palackého v Olomouci, 2010. ISBN 978-80-244-2615-0.
- [4] WALEK, Petr, Martin LAMOŠ a Jiří JAN. *Analýza biomedicínských obrazů: Počítačová cvičení* [online]. Brno: Vysoké učení technické v Brně, 2013, [cit. 2017-11-14]. ISBN 978-80-214-4792-9. Dostupné z: <<http://www.dbme.feec.vutbr.cz/sites/default/files/news/fabo.pdf>>
- [5] JAN, Jiří. *Medical image processing, reconstruction, and restoration: concepts and methods*. Boca Raton, FL: Taylor & Francis, 2006. ISBN 0-8247-5849-8.
- [6] GRADY, L. Random Walks for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* [online]. IEEE, 2006, 28(11), 1768–1783 [cit. 2017-11-25]. DOI: 10.1109/TPAMI.2006.233. ISSN 0162-8828. Dostupné z: <<http://ieeexplore.ieee.org/document/1704833/>>
- [7] DOYLE, Peter G. a J. Laurie SNELL. *Random Walks and Electric Networks*. Washington, D.C.: Mathematical Association of America, 1984. Ser. Carus mathematical monographs, vol. 22. ISBN 978-1-61444-022-2.
- [8] CHAN, T.F. a L.A. VESE. Active contours without edges. *IEEE Transactions on Image Processing* [online]. IEEE, 2001, 10(2), 266–277 [cit. 2017-11-26]. DOI: 10.1109/83.902291. ISSN 1057-7149. Dostupné z: <<http://ieeexplore.ieee.org/document/902291/>>
- [9] WANG, Qian, Le LU, Dijia WU, Noha EL-ZEHIRY, Yefeng ZHENG, Dinggang SHEN a Kevin S. ZHOU. Automatic Segmentation of Spinal Canals in CT Images via Iterative Topology Refinement. *IEEE Transactions on Medical Imaging* [online]. 2015, 34(8), 1694–1704 [cit. 2017-12-05].

DOI: 10.1109/TMI.2015.2436693. ISSN 0278-0062. Dostupné z: <<http://ieeexplore.ieee.org/document/7112540/>>

- [10] DE LEENER, Benjamin, Julien COHEN-ADAD a Samuel KADOURY. Automatic Segmentation of the Spinal Cord and Spinal Canal Coupled With Vertebral Labeling. *IEEE Transactions on Medical Imaging* [online]. 2015, **34**(8), 1705–1718 [cit. 2017-12-06]. DOI: 10.1109/TMI.2015.2437192. ISSN 0278-0062. Dostupné z: <<http://ieeexplore.ieee.org/document/7112150/>>
- [11] HAQ, Rabia, Rifat ARAS, David A. BESACHIO, Roderick C. BORGIE a Michel A. AUDETTE. 3D lumbar spine intervertebral disc segmentation and compression simulation from MRI using shape-aware models. *International Journal of Computer Assisted Radiology and Surgery* [online]. 2015, **10**(1), 45–54 [cit. 2017-12-06]. DOI: 10.1007/s11548-014-1094-9. ISSN 1861-6410. Dostupné z: <<http://link.springer.com/10.1007/s11548-014-1094-9>>
- [12] ZHU, Xinjian, Xuan HE, Pin WANG, Qinghua HE, Dandan GAO, Jiwei CHENG a Baoming WU. A method of localization and segmentation of intervertebral discs in spine MRI based on Gabor filter bank. *BioMedical Engineering Online* [online]. 2016, **15**(1), článok č. 32 [cit. 2017-12-06]. DOI: 10.1186/s12938-016-0146-5. ISSN 1475-925x. Dostupné z: <<http://www.biomedical-engineering-online.com/content/15/1/32>>
- [13] NASIRI, Fatemeh a Hamid Soltanian ZADE. Automatic segmentation of intervertebral disk from MR images of the spine based on graph cut method. **In:** *2013 8th Iranian Conference on Machine Vision and Image Processing (MVIP)* [online]. IEEE, 2013, 300–303 [cit. 2017-12-06]. DOI: 10.1109/IranianMVIP.2013.6779999. ISBN 978-1-4673-6184-2. Dostupné z: <<http://ieeexplore.ieee.org/document/6779999/>>
- [14] CHEN, Cheng, Daniel BELAVY, Weimin YU, Chengwen CHU, Gabriele ARMBRECHT, Martin BANSMANN, Dieter FELSENBURG a Guoyan ZHENG. Localization and Segmentation of 3D Intervertebral Discs in MR Images by Data Driven Estimation. *IEEE Transactions on Medical Imaging* [online]. 2015, **34**(8), 1719–1729 [cit. 2017-12-11]. DOI: 10.1109/TMI.2015.2403285. ISSN 0278-0062. Dostupné z: <<http://ieeexplore.ieee.org/document/7041180/>>
- [15] CHEN, Hao, Qi DOU, Xi WANG, Jing QIN, Jack C. Y. CHENG a Pheng-Ann HENG. 3D Fully Convolutional Networks for Intervertebral Disc Localization and Segmentation. *Medical Imaging and Augmented Reality* [online]. Cham: Springer International Publishing, 2016, 375–382 [cit. 2017-12-06]. DOI:

- 10.1007/978-3-319-43775-0_34. ISBN 978-3-319-43774-3. Dostupné z: <http://link.springer.com/10.1007/978-3-319-43775-0_34>
- [16] HOSSEIN BEHFOROZ, G. A comparison of the E(3) and not-a-knot cubic splines. *Applied Mathematics and Computation* [online]. 1995, **72**(2-3), 219–223 [cit. 2017-12-07]. DOI: 10.1016/0096-3003(94)00185-7. ISSN 00963003. Dostupné z: <<http://linkinghub.elsevier.com/retrieve/pii/0096300394001857>>
- [17] YAO, Jianhua, Joseph E. BURNS, Daniel FORSBERG, et al. A multi-center milestone study of clinical vertebral CT segmentation. *Computerized Medical Imaging and Graphics* [online]. 2016, **49**, 16–28 [cit. 2018-05-11]. DOI: 10.1016/j.compmedimag.2015.12.006. ISSN 08956111. Dostupné z: <<http://linkinghub.elsevier.com/retrieve/pii/S0895611115001937>>
- [18] JAMALUDIN, Amir, Meelis LOOTUS, Timor KADIR a Andrew ZISSERMAN. Automatic Intervertebral Discs Localization and Segmentation: A Vertebral Approach. **In:** VRTOVEC, T. et al. *Computational Methods and Clinical Applications for Spine Imaging* [online]. Cham: Springer International Publishing, 2016, 97–103 [cit. 2018-05-13]. Lecture Notes in Computer Science. DOI: 10.1007/978-3-319-41827-8_9. ISBN 978-3-319-41826-1. Dostupné z: <http://link.springer.com/10.1007/978-3-319-41827-8_9>
- [19] WANG, Chunliang a Daniel FORSBERG. Segmentation of Intervertebral Discs in 3D MRI Data Using Multi-atlas Based Registration. **In:** VRTOVEC, T. et al. *Computational Methods and Clinical Applications for Spine Imaging* [online]. Cham: Springer International Publishing, 2016, 107–116 [cit. 2018-05-13]. Lecture Notes in Computer Science. DOI: 10.1007/978-3-319-41827-8_10. ISBN 978-3-319-41826-1. Dostupné z: <http://link.springer.com/10.1007/978-3-319-41827-8_10>
- [20] KOREZ, Robert, Bulat IBRAGIMOV, Boštjan LIKAR, Franjo PERNUŠ a Tomaž VRTOVEC. Deformable Model-Based Segmentation of Intervertebral Discs from MR Spine Images by Using the SSC Descriptor. **In:** VRTOVEC, T. et al. *Computational Methods and Clinical Applications for Spine Imaging* [online]. Cham: Springer International Publishing, 2016, 117–124 [cit. 2018-05-13]. Lecture Notes in Computer Science. DOI: 10.1007/978-3-319-41827-8_11. ISBN 978-3-319-41826-1. Dostupné z: <http://link.springer.com/10.1007/978-3-319-41827-8_11>
- [21] HUTT, Hugo, Richard EVERSON a Judith MEAKIN. 3D Intervertebral Disc Segmentation from MRI Using Supervoxel-Based CRFs. **In:** VRTOVEC,

- T. et al. *Computational Methods and Clinical Applications for Spine Imaging* [online]. Cham: Springer International Publishing, 2016, 125–129 [cit. 2018-05-13]. Lecture Notes in Computer Science. DOI: 10.1007/978-3-319-41827-8_12. ISBN 978-3-319-41826-1. Dostupné z: <http://link.springer.com/10.1007/978-3-319-41827-8_12>
- [22] URSCHLER, Martin, Kerstin HAMMERNIK, Thomas EBNER a Darko ŠTERN. Automatic Intervertebral Disc Localization and Segmentation in 3D MR Images Based on Regression Forests and Active Contours. **In:** VRTOVEC, T. et al. *Computational Methods and Clinical Applications for Spine Imaging* [online]. Cham: Springer International Publishing, 2016, 130–140 [cit. 2018-05-13]. Lecture Notes in Computer Science. DOI: 10.1007/978-3-319-41827-8_13. ISBN 978-3-319-41826-1. Dostupné z: <http://link.springer.com/10.1007/978-3-319-41827-8_13>
- [23] CHU, Chengwen, Weimin YU, Shuo LI a Guoyan ZHENG. Localization and Segmentation of 3D Intervertebral Discs from MR Images via a Learning Based Method: A Validation Framework. **In:** VRTOVEC, T. et al. *Computational Methods and Clinical Applications for Spine Imaging* [online]. Cham: Springer International Publishing, 2016, 141–149 [cit. 2018-05-13]. Lecture Notes in Computer Science. DOI: 10.1007/978-3-319-41827-8_14. ISBN 978-3-319-41826-1. Dostupné z: <http://link.springer.com/10.1007/978-3-319-41827-8_14>
- [24] NEUBERT, Aleš, Jurgen FRIPP, Shekhar S. CHANDRA, Craig ENGSTROM a Stuart CROZIER. Automated Intervertebral Disc Segmentation Using Probabilistic Shape Estimation and Active Shape Models. **In:** VRTOVEC, T. et al. *Computational Methods and Clinical Applications for Spine Imaging* [online]. Cham: Springer International Publishing, 2016, 150–158 [cit. 2018-05-13]. Lecture Notes in Computer Science. DOI: 10.1007/978-3-319-41827-8_15. ISBN 978-3-319-41826-1. Dostupné z: <http://link.springer.com/10.1007/978-3-319-41827-8_15>

ZOZNAM SYMBOLOV, VELIČÍN A SKRATIEK

IVD	intervertebrálne disky
MRI	zobrazovanie magnetickou rezonanciou – Magnetic Resonance Imaging
NMR	nukleárna magnetická rezonancia
DICOM	Digital Imaging and Communications in Medicine
NIFTI	Neuroimaging Informatics Technology Initiative
CT	počítačová tomografia – Computed Tomography
GFI	Gabor Features Images
CNN	Convolutional Neural Networks
DC	Dice Coefficient
MASD	Mean Absolute Surface Distance