

**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**  
BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA INFORMAČNÍCH TECHNOLOGIÍ**  
**ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ**

FACULTY OF INFORMATION TECHNOLOGY  
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA


**INTERAKTÍVNA SEGMENTÁCIA MEDICÍNSKÝCH**  
**OBRAZOVÝCH DÁT**

**DIPLOMOVÁ PRÁCE**  
MASTER'S THESIS


**AUTOR PRÁCE**  
AUTHOR

**Bc. MARTIN OLŠA**

BRNO 2011



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ  
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA INFORMAČNÍCH TECHNOLOGIÍ  
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ  
FACULTY OF INFORMATION TECHNOLOGY  
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

# INTERAKTIVNÍ SEGMENTACE MEDICÍNSKÝCH OBRAZOVÝCH DAT

INTERACTIVE MEDICAL IMAGE SEGMENTATION

DIPLOMOVÁ PRÁCE  
MASTER'S THESIS

AUTOR PRÁCE  
AUTHOR

Bc. MARTIN OLŠA

VEDOUCÍ PRÁCE  
SUPERVISOR

Ing. MICHAL ŠPANĚL, Ph.D.

BRNO 2011

## **Abstrakt**

Tato práce se zabývá segmentací anatomických struktur v medicínských objemových datech pomocí metody fast level-set. Zvolená metoda reprezentuje uzavřený 3D povrch postupující v čase z počáteční pozice. Hlavním zaměřením této práce je implementace metody level-set a vytvoření interaktivního nástroje určeného na segmentaci 3D medicínských objemových dat využitím této metody. Nástroj je schopný interaktivně měnit parametry vývoje povrchu během samotného procesu segmentace. Díky povaze metody level-set, může být proces vývoje povrchu pozastaven v jakémkoli momentě, nebo sledovaný několik kroků vedoucích zpět a z této pozice může být restartován s úplně jinou konfigurací.

## **Abstract**

This work deals with a fast level-set approach for segmentation of anatomical structures in volumetric medical images. The fast level-set method evolves a closed 3D surface in time propagating the surface from an initial position. The major contribution of this work is the implementation of the level-set method and construction of an interactive tool for segmentation of 3D medical data using this method. The tool is able to interactively change parameters of the evolution during the segmentation process itself. Due to the nature of level-set method, the evolution process can be stopped at any time, or backtracked and restarted from any previous step with a different configuration.

## **Klíčová slova**

Medicínské zobrazování, segmentace obrazu, počítačové vidění, deformovatelné modely, level-sets, CT, MR

## **Keywords**

Medical imaging, image segmentation, computer vision, level set, CT, MR

## **Citace**

Bc. Martin Olša: Interaktivní segmentace medicínských obrazových dat, diplomová práce, Brno, FIT VUT v Brně, 2011

# Interaktivní segmentace medicínských obrazových dat

## Prohlášení

Prohlašuji, že jsem diplomovou práci vypracoval samostatně pod vedením Ing. Michala Španěla, Ph.D. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....  
Bc. Martin Olša  
24.5.2011

## Poděkování

Chcel by som poďakovať vedúcemu mojej práce Ing. Michalovi Španělovi, Ph.D. za jeho nesmiernu ochotu, čas, vecné pripomienky a hlavne za veľkú podporu a pomoc počas celej práce.

© Bc. Martin Olša, 2011

*Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě informačních technologií. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.*



# Obsah

1 Úvod.....	6
2 Segmentačné techniky medicínskych dát.....	7
2.1 Thresholding.....	9
2.2 Metódy založené na regiónoch.....	10
2.3 Metódy založené na detekcii hrán.....	11
2.4 Hough transform.....	12
2.5 Klasifikátory.....	13
2.6 Markov Random Fields.....	14
2.7 Neurónové siete (NN).....	14
2.8 Atlas-guided metódy.....	15
2.9 Deformable models (DM).....	16
3 Level Set method.....	18
3.1 Matematický základ.....	18
3.2 Formulácia rýchlosti F.....	19
3.3 Rekonštrukcia tvaru propagáciou frontu.....	20
3.4 Rôzne urýchlenia LS metód.....	20
3.5 Fast Method.....	23
3.6 Segmentácia deformovateľnými povrchmi.....	25
4 Existujúce nástroje segmentácie medicínskych dát.....	28
4.1 Potreba segmentácie medicínskych dát.....	28
4.2 Nástroje využívajúce LSM.....	29
5 Návrh riešenia.....	33
5.1 Rozbor použitej metódy Fast Level-Set.....	34
5.2 Riadenie a krokovanie procesu segmentácie.....	42
5.3 Segmentačný nástroj.....	44
5.4 Návrh nadstavby nástroja.....	45
6 Implementácia.....	49
6.1 Reprezentácia základných prvkov.....	49
6.2 Segmentačný nástroj.....	50
6.3 Kľúčové metódy vývoja povrchu.....	53
6.4 Výstup nástroja.....	56
6.5 Implementácia nadstavby segmentačného nástroja.....	56
7 Dosiahnuté výsledky.....	60
7.1 Experimentovanie.....	62

7.2 Možnost' budúceho vývoja.....	65
8 Záver.....	67

## Zoznam obrázkov

Obrázok 1: Segmentácia obrazu technikou thresholding: Originál (a) a segmentovaný obraz (b); Obrázok prevzatý z <a href="http://thirdybuno.blogspot.com/2009/09/activity-14-pattern-recognition.html">http://thirdybuno.blogspot.com/2009/09/activity-14-pattern-recognition.html</a> .....	9
Obrázok 2: výsledok segmentácie metódou Region growing; Obrázok prevzatý z <a href="http://www.medicimaging.com/images/products/3d_tools_2.png">http://www.medicimaging.com/images/products/3d_tools_2.png</a> .....	10
Obrázok 3: Výsledok segmentácie edge-based metódou; Obrázok prevzatý z <a href="http://www-sop.inria.fr/members/Gregoire.Malandain/segment/edges.html">http://www-sop.inria.fr/members/Gregoire.Malandain/segment/edges.html</a> .....	11
Obrázok 4: Houghova transformácia; a) zdrojové dáta; b) výrez; c) akumulčné pole; d) výsledok detekcie [8].....	12
Obrázok 5: Obecný klasifikátor; Obrázok prevzatý z <a href="http://www.applied-mathematics.net/classification/C45.html">http://www.applied-mathematics.net/classification/C45.html</a> .....	13
Obrázok 6: Segmentácia mozgu; a) originál; b) segmentácia metódou K-means; c) segmentácia metódou K-means v spojení s MRF [10].....	14
Obrázok 7: Výsledok plne automatickej segmentácie šedej a bielej kôry mozgovej pomocou GRBF neurónovej siete [14]. .....	15
Obrázok 8: 3 rezy ľudského mozgu preložené s warped-atlas [10].....	16
Obrázok 9: priebeh evolúcie metódy aktívne kontúry [31].....	16
Obrázok 10: Level set funkcia (červená) vykresluje vzdialenosť každého bodu (x,y) od frontu (modrá); Obrázok prevzatý z [18].....	19
Obrázok 11: Postup frontu silou F [18].....	20
Obrázok 12: Adaptive mesh refinement [16].....	21
Obrázok 13: Znázornenie Narrow Band [16].....	22
Obrázok 14: Vektor bodov určuje hraničné body NB [16].....	23
Obrázok 15: (a) Implicitná definícia krivky C v LS metóde. Definícia zoznamova ; (b) Popis pohybu krivky na základe výmeny bodov medzi[25].....	23
Obrázok 16: Klasifikácie jednotlivých pixelov obrazu podľa hodnoty vzdialenostnej funkcie $\Phi$ [26]. .....	25
Obrázok 17: (a) Deformovateľný model "balloon" vsadený do volumetrických dát deformovaný posľa hrán LV (b)Rekonštrukcia povrchu LV [28].....	26
Obrázok 18: Pravá koronárna artéria. Model výsledku evolúcie pomocou metódy level-set. Obrázok prevzatý z <a href="http://www.slicer.org/slicerWiki/images/8/8c/Vmtkafterevolution.png">http://www.slicer.org/slicerWiki/images/8/8c/Vmtkafterevolution.png</a> .....	29
Obrázok 19: Ukážka prostresia a segmentácie programu itk-SNAP;.....	31

Obrázok 20: Rozťahovanie povrchu v 2D. V označenom bode sa povrch roztiahne. (a) Pred roztiahnutím, (b) Roztiahnutie, (c) Zcelistenie povrchu.....	37
Obrázok 21: Zmršťovanie povrchu v 2D. V označenom bode sa povrch zmrští. (a) Pred zmrštením, (b) Zmrštenie, (c) Zcelistenie povrchu.....	37
Obrázok 22: Ukážka zmazania zbytočných bodov hranice. (a) Výsledok zmazania zbytočných bodov po fáze rozťahovania povrchu, (b) Výsledok zmazania zbytočných bodov po fáze zmršťovania povrchu.....	38
Obrázok 23: Náčrt GUI: Časť inicializácia.....	46
Obrázok 24: Náčrt GUI: Časť Evolúcia povrchu.....	46
Obrázok 25: Náčrt GUI: Časť zobrazovania výsledkov.....	47
Obrázok 26: Diagram tried nástroja.....	52
Obrázok 27: Diagram tried pluginu.....	57
Obrázok 28: Ukážka GUI: Fáza evolúcie povrchu.....	59
Obrázok 29: Ukážka segmentácie volumetrických dát pomocou implementovaného nástroja. Prostredie modulu v MDSTk.....	60
Obrázok 30: Ukážka segmentácie aorty pomocou nastavby nástroja. Prostredie 3DimViewer.....	61
Obrázok 31: Ukážka výstupu modulu Level Set v MDSTk toolkite:velocity field. Obrázok bol upravovaný pre potreby tlače.....	72
Obrázok 32: Ukážka výstupu nástroja 2D variantu v prostredí MDSTk. Dva štvorce v dátach reprezentujú počiatočné krivky modelu. Obrázok bol spracovaný pre potreby tlače.....	73
Obrázok 33: Ukážka výstupu segmentácie mozgu pomocou implementovaného nástroja. Obrázok bol pre potreby tlače farebne upravený.....	74
Obrázok 34: Ukážka rezu segmentácie mozgu. Obrázok znázorňuje postupný vývoj povrchu z počiatočnej plochy, zachytený každých 10 iterácií.....	75

# Použité skratky

**PDEs** Parciálne diferenciálne rovnice

**NB** Narrow band

**LS** Level-set

**LSM** Level-set method

**FLSM** Fast level-set method

**VF** Velocity field

# 1 Úvod

Diagnostika zobrazovacími technikami má v oblasti medicíny nevyčísliteľnú cenu. Zobrazovacie zariadenia ako magnetická rezonancia (MR), počítačová tomografia (CT), digitálna mamografia a pozitronová emisná tomografia už dlhú dobu poskytujú v oblasti medicíny nenahraditeľnú úlohu neinvazívnych zobrazovacích techník. Pomáhajú diagnostikovať pacienta, sledovať proces liečby, plánovať operácie, ožarovacie liečby a riešiť množstvo iných problémov v medicíne. Samozrejme, na úspešné prevedenie spomenutých úkonov je potrebné správne vyhodnotenie výsledku zobrazovacích zariadení. Výstupná informácia je vo forme obrazového materiálu. Aby bol obraz vyhodnotený správne, musí byť analyzovaný lekárom na základe jeho schopností a vedomostí. Správna interpretácia medicínskych dát je kľúčová pre určenie správnej diagnózy pacienta. V nadnesenom zmysle slova môžeme povedať, že život pacienta je do značnej miery závislý na interpretácii získaného vyšetrenia. Správnej interpretácii dát môže napomôcť segmentácia dát a následná vizualizácia výsledku. V súčasnosti existuje nepreberné množstvo techník segmentácie medicínskych obrazových dát v 2D aj 3D priestore. Často sa na segmentáciu využívajú tzv. deformovateľné povrchy, ktoré sa používajú napríklad na rekonštrukciu tvarov objektov záujmu z dát. Jednou z týchto metód je aj metóda level-set, ktorá sa vďaka svojim výnimočným vlastnostiam stala predmetom tejto diplomovej práce.

Táto práca sa zaoberá implementovaním metódy *fast level-set* a následnou tvorbou nástroja využívajúceho túto metódu. Implementovaný nástroj slúži na segmentáciu medicínskych volumetrických dát. Zvolená metóda je revolučná a vďaka svojmu charakteru ponúka možnosť real-time spracovania objemových dát pomocou deformovateľného povrchu. Cieľom tejto práce je vlastná implementácia metódy *fast level-set* vychádzajúcej z teoretických podkladov [25,26], ktorá je obohatená o vlastné interaktívne prvky. V dobe písania práce je implementovaný nástroj jedinečný.

V kapitole 2 popisujem niektoré nízkoúrovňové techniky segmentácie medicínskych dát. Jedná sa skôr o prehľad techník ako o ich vyčerpávajúci zoznam. Ďalej v kapitole 3 sa nachádza teoretický rozbor a popis metódy level-set spolu s jej rôznymi modifikáciami vrátane metódy *fast level-set*, ktorá je kľúčovým prvkom tejto diplomovej práce. Nachádza sa tam tiež teoretický podklad a využitie segmentovania dát pomocou deformovateľných povrchov. Analýza oblasti segmentácie medicínskych dát, ich potreba, využitie a popis cesty od jednoduchých segmentačných metód až po vyšetrenú metódu sa nachádza v kapitole 4. Zároveň popisuje existujúce nástroje využívajúce základnú variantu metódy *level-set*. kapitola 5 obsahuje návrh segmentačného nástroja, jeho nadstavby a následná implementácia sa nachádza v kapitole 6. Dosiahnuté výsledky, experimenty a objasnenie ďalších krokov v budúcnosti popisuje kapitola 7.

## 2 Segmentačné techniky medicínskych dát

Diagnostika zobrazovaním je dnes v medicíne veľmi cenená a nenahraditeľná. Jedná sa o diagnostiku pomocou výstupu z niektorého zobrazovacieho zariadenia používaného v medicíne. Tieto technológie dnes dokážu rozlišovať zdravé a choré tkanivo pre medicínsky výskum a sú kľúčovým prvkom diagnózy a plánovania operácie. Už zo samotného obrazového výstupu týchto zariadení je možné odhaliť napríklad ochorenia mozgu, ktorých topológia je už známa [32]. Obzvlášť dôležité sú predovšetkým počítačové algoritmy, nazývané algoritmy segmentácie obrazu, ktoré hrajú podstatnú úlohu v množstve biomedicínskych aplikácií. Medzi aplikácie patrí napríklad diagnóza, plánovanie liečby, štúdium anatomických štruktúr, plánovanie ožarovania, zisťovanie objemu tkanív, lokalizácia nálezu, počítačom asistovaná operácia a mnohé iné [10].

Metódy segmentácie sa značne líšia v závislosti na špecifickej aplikácii, zobrazovanom tvare a použitej zobrazovacej technológii. Napríklad segmentácia mozgovej štruktúry má iné požiadavky ako segmentácia cievneho systému. Tu sa pridávajú známe artefakty samotného zobrazovania ako šum, pohyb pri snímaní a prítomnosť kovov, ktoré značne sťažujú proces samotného spracovania obrazu. Nedá sa povedať, že by existovala segmentačná metóda, ktorá by dávala uspokojivé výsledky pre každý možný obraz medicínskych dát. Avšak metódy, ktoré sa špecializujú na užšiu oblasť, dosahujú lepšie výsledky vďaka znalosti danej domény [13].

Segmentácia je jedným z najdôležitejších krokov vedúcich k pochopeniu obrazových dát. Cieľom je rozdeliť obraz na oblasti, ktoré korešpondujú s objektami v reálnom svete zachytenými v obraze. Na dosiahnutie úplnej segmentácie je možné, a často žiaduce, prepojiť jednoduchšie metódy so sofistikovanejšími metódami, ktoré majú k dispozícii špecifické znalosti. Existuje však veľké množstvo segmentačných problémov, ktoré sú úspešne riešiteľné pomocou jednoduchších metód [10]. V tomto prípade ide väčšinou o obraz pozostávajúci z kontrastných objektov na homogénnom pozadí, ako napríklad obraz obsahujúci krvinky (viď obrázok 1). V takom prípade je možné použiť niektorú z globálnych metód a segmentovaný obraz je ľahko získateľný. Cieľom je rozdelenie obrazu do homogénnych oblastí vzhľadom na dané kritérium ako sú farba, jas, textúra atď. Jedná sa teda o kontextovo nezávislú techniku, a teda nie je potrebné mať akúkoľvek znalosť o výsledku segmentácie.

Na druhej strane, ak sa pokúšame segmentovať zložitý obraz, potrebujeme mať isté znalosti o štruktúre dát a o tom ako by mal vyzerat' výsledok segmentácie. Typickým príkladom je obraz priečného rezu ľudského tela, ktorý obsahuje zložité štruktúry navzájom sa presahujúcich tkanív.

Veľkosť, posun a iné faktory snímaného obrazu sa líšia každým snímaním objektu. Už len samotný mozog má u každého človeka iný tvar a môže obsahovať aj rôzne nálezy, ložiská a deformácie. Segmentácia medicínskych dát je preto veľmi náročný proces, ktorý vyžaduje isté znalosti v danej doméne. Segmentačné techniky medicínskych dát [9, 10] pracujú na rôznych princípoch. Používa sa napr.:

- prahovanie,
- metódy založené na regiónoch,
- metódy založené na detekcii hrán,
- klasifikátory,
- markovove náhodné modely,
- neurónové siete,
- metódy využívajúce atlas,
- deformovateľné modely.

Väčšina spomenutých segmentačných techník môže byť postavená ako optimalizačný problém, kde požadovaná segmentácia minimalizuje energiu alebo ohodnocovaciu funkciu definovanú konkrétnou technikou. V pravdepodobnostných metódach je to ekvivalentné k maximalizovaniu pravdepodobnosti alebo *posteriórnej* pravdepodobnosti. Ak máme obraz  $y$ , požadujeme segmentáciu  $\check{x}$  takú, že

$$\check{x} = \arg \min_x \mathcal{E}(x, y), \quad (1)$$

kde  $\varepsilon$  je funkcia energie, ktorá závisí na obraze  $y$  a segmentačnom postupe  $x$ . Definovanie vhodnej funkcie  $\varepsilon$  je kvôli veľkej rôznorodosti vlastností obrazu obtiažna úloha [10].

Podľa dimenzie pracujú segmentačné techniky buď v doméne 2D alebo 3D priestoru. Tie techniky, ktoré závisia iba na intenzite obrazu, sú na dimenzii nezávislé. Avšak metódy ako *deformable models*, *Markov random fields* a *region growing* zohľadňujú aj geometrickú informáciu a teda pracujú v závislosti na dimenzii obrazu. Existujú aj modely, ktoré sú matematicky popísané a fungujú aj na doméne N-rozmerného priestoru. Funguje tak napríklad metóda *LS*, ktorá je podrobnejšie popísaná v kapitole 3.

Interaktivita segmentačného procesu je taktiež dôležitá. Niektoré metódy ju doslova vyžadujú. Manuálna segmentácia často prináša kvalitnejšie výsledky, práve vďaka znalosti výsledku segmentácie.

Typ interakcie v metódach sa značne líši. Ide napríklad o kompletne manuálne segmentovanie určovaním hraníc regiónov alebo o čiastočne manuálne umiestnenie semienka v metóde *region growing*. Aj zjavne automatické metódy však potrebujú určitý počiatok podmienky. Interaktivita môže byť žiaduca alebo nežiaduca v závislosti na type aplikácie.



## 2.1 Thresholding


*Thresholding* je najjednoduchšou segmentačnou technikou. Je výpočtovo nenáročná a rýchla, a zároveň patrí medzi najstaršie segmentačné metódy. Stále je hojne využívaná v mnohých aplikáciách, alebo slúži ako predspracovanie obrazu, ktoré je nasledované inou sofistikovanou metódou. Kompletnou segmentáciou obrazu  $I$  je konečný počet regiónov.

$$R = \bigvee_{i=1}^S R_i, \quad R_i \wedge R_j = *, \quad i \neq j. \quad (2)$$

Thresholding je transformácia vstupného obrazu  $I$  na výstupný binárny obraz  $g$  následovne:

$$g(i, j) = \begin{cases} 1 & \text{if } f(i, j) \geq T \\ 0 & \text{if } f(i, j) < T \end{cases}, \quad (3)$$

kde  $T$  je zvolený prah,  $g(i, j) = 1$  pre objekty v obraze a  $g(i, j) = 0$  pre elementy pozadia (alebo naopak). Pokiaľ sa objekty nedotýkajú a majú znateľne rozlíšiteľné intenzity od pozadia, potom thresholding je ideálna metóda. Najťažším krokom je výber správneho prahu. Výber prahu môže byť zvolený interaktívne, alebo je určený automaticky metódou na zistenie prahu. Väčšinou však jeden prah na úspešnú segmentáciu nestačí, pretože pre tie najjednoduchšie obrazy majú rôzne variácie ako v objektoch, tak aj v pozadí, napríklad kvôli nerovnomernému osvetleniu [2]. Výsledok segmentácie metódou thresholding ilustruje obrázok 1.



Obrázok 1: Segmentácia obrazu technikou thresholding: Originál (a) a segmentovaný obraz (b); Obrázok prevzatý z <http://thirdybuno.blogspot.com/2009/09/activity-14-pattern-recognition.html>.

Segmentácia metódou *adaptive thresholding* používa viacero rôznych prahov, ktorých hodnoty sa menia a sú určené na obraze funkciou lokálnej charakteristiky obrazu. Globálny prah je odvodený z celého obrazu a naopak lokálne prahy sú závislé na polohe bodu v obraze. Tu je princípom rozdelenie obrazu do častí, kde je prah definovaný a následuje prahovanie každej oblasti osobitne [9].


## 2.2 Metódy založené na regiónoch

Tieto metódy priamo konštruujú regióny, pričom je vyžadovaná ich homogenita. Kritériom homogenity môže byť jas, textúra, farba, atď. Od regiónov sa vyžaduje, aby boli spojenými dvojdimenzionálnymi plochami. Ako budú regióny vo výsledku vyzerat' - či budú oddelené alebo spojené, alebo budú mať hladké okraje, závisí od použitej techniky (napr. narastanie oblastí) a na ciele aplikácie. Väčšinou sa požaduje aby výsledkom segmentácie bolo rozdelenie obrazu do disjunktných oblastí tak, že každý pixel obrazu patrí práve do jedného regiónu.

Primitívnejšie metódy využívajú iba súhrnné vlastnosti lokálnych skupín pixelov v obraze na určenie regiónu. Zložitejšie metódy pracujú na princípe spájania alebo rozdeľovania primitívnych regiónov. Ak je segmentovaný obraz jednoduchý (jednoduchý predmet na konštantnom pozadí), tak bude veľmi efektívna lokálna technika, ale na zložitejšie scény, ktoré sa vyskytujú častejšie, je treba použiť metódy globálne. Ani to často nestačí a techniky zamerané na regióny sú mnohokrát považované za metódy slúžiace na predspracovanie obrazu pre iné metódy.

### 2.2.1 Region growing

Region growing metódy (nazývané tiež *region merging*) sú veľmi vhodné na zašumené dáta, kde je ťažko odhaliť hranice objektov. Ako bolo spomenuté, metóda *region growing* hľadá oblasti s rovnakou homogenitou.




Obrázok 2: výsledok segmentácie metódou *Region growing*; Obrázok prevzatý z [http://www.medicimaging.com/images/products/3d\\_tools\\_2.png](http://www.medicimaging.com/images/products/3d_tools_2.png).

Začína s pixelom alebo skupinou pixelov nazývaných *seed*, ktoré patria do oblasti záujmu. Tieto počiatočné body môžu byť určené interaktívne alebo automaticky. Následne sú spracovávané okolné body, ktoré sú pridané do regiónu, ak spĺňajú kritérium homogenity. Tak to pokračuje až do momentu, kedy nie je možné pridať ďalšie pixely do regiónu (viď obrázok 2). Objekt je potom reprezentovaný množinou pixelov, ktoré boli počas procesu pridané. Výsledky metódy silne závisia na voľbe kritéria homogenity. Príkladom môže byť porovnanie intenzity pixelu a priemernej intenzity regiónu. Ak je rozdiel menší ako istá hranica, napr. dve smerodatné odchýlky intenzity celého regiónu, tak je pixel pridaný do regiónu [2].

## 2.3 Metódy založené na detekcii hrán

V prístupoch *edge-based* segmentácie je obraz popísaný hranami (hranicami) medzi jednotlivými regiónmi (viď obrázok 3). Na detekciu hrán existuje mnoho operátorov, ktoré sú poväčšine pomenované podľa ich vynálezcu. Medzi najznámejšie patria *Marr-Hildreth*, *Sobel*, *Prewitt* a *Canny* detektory hrán [5]. Aplikovanie hranových detektorov môže značne zmeniť množstvo dát určených na spracovanie. Odfiltruje teda menej podstatné informácie a dôležité naopak zvýrazní. V realite nie je možné získať iba ideálne hrany, ktoré by popisovali chcené objekty, zvlášť pri netriviálnych obrazových scénach.



Obrázok 3: Výsledok segmentácie *edge-based* metódou; Obrázok prevzatý z <http://www-sop.inria.fr/members/Gregoire.Malandain/segment/edges.html>.

Výstupom hranových detektorov je množina hrán obrazu, kde došlo k lokálnym zmenám jasů. Vytvárajú sa tak popri hranách, ktoré nás zaujímajú, aj tzv. falošné hrany alebo dokonca niektoré hrany v oblasti záujmu chýbajú [3].

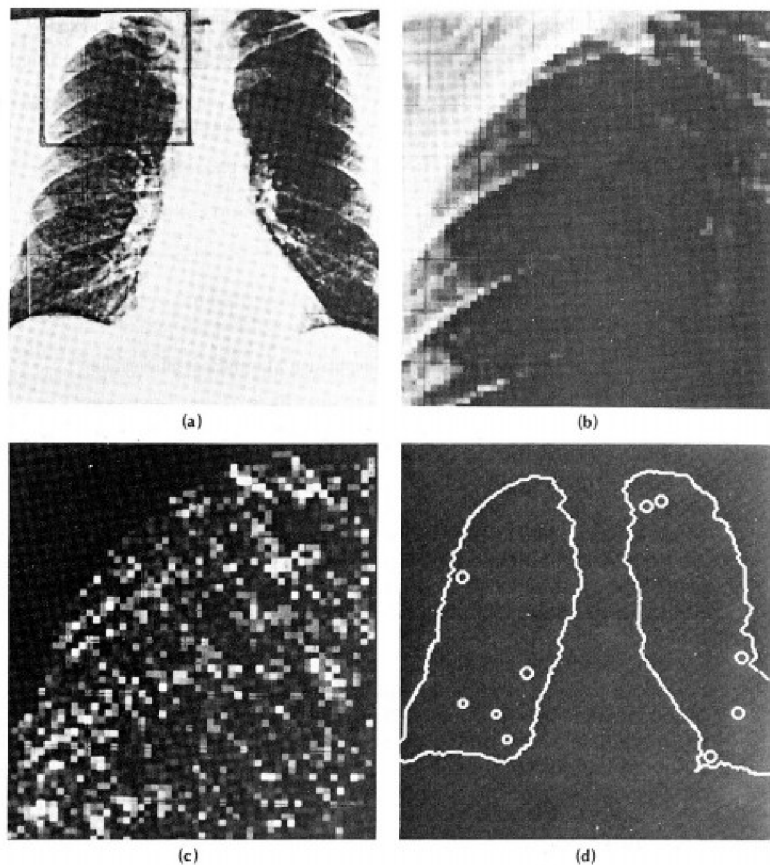
## 2.4 Hough transform

Houghova transformácia bola vyvinutá na detekciu rovných čiar v obrazových dátach [6].

Parametrické vyjadrenie priamky je:

$$d = c \cos(\theta) - r \sin(\theta), \quad (4)$$

kde  $d$  je vzdialenosť priamky od počiatku súradného systému a  $\theta$  je uhol vzhľadom na osu  $x$ . Houghova transformácia vyžaduje štruktúru o dimenzii rovnakej ako hľadané parametre danej rodiny kriviek. Pre priamku (podľa rovnice 4) sú potrebné dva parametre, a to  $d$  a  $\theta$ , ktoré následne ukladá do akumuláčného poľa pre ďalšie vyhodnotenie.




Obrázok 4: Houghova transformácia; a) zdrojové dáta; b) výrez; c) akumuláčné pole; d) výsledok detekcie [8].

Houghove transformácie sa veľmi často využívajú v segmentácii, pretože sú robustné a odolné voči neúplným dátam a šumu. Používajú sa obecné aj na detekciu kriviek, elíps alebo hraníc objektu [7]. Segmentáciu dát touto technikou ilustruje obrázok 4.

## 2.5 Klasifikátory

Metódy klasifikátorov sú technikami rozpoznávania vzorov, ktoré rozdeľujú priestor príznakov (angl. *feature space*) odvodených z obrazu. Feature space je priestor ľubovoľnej funkcie obrazu. Väčšinou sú príznakmi obrazu samotné intenzity pixelov. Príkladom takéhoto priestoru je napr. histogram obrazu, ktorý je príkladom 1D príznakového priestoru. 2D priestor príznakov obrazu je znázornený na obrázku 5. Všetky príznaky, ktoré sú červenou farbou, budú klasifikované do jednej triedy. Konkrétne príznaky môžu byť samozrejme zvolené aj inak. Obrázok interpretuje zaradenie obecných príznakov v obraze [10].



Obrázok 5: Obecný klasifikátor; Obrázok prevzatý z <http://www.applied-mathematics.net/classification/C45.html>.


Klasifikátory sú označované ako *supervised* metódy, pretože potrebujú na klasifikáciu testovacie dáta, ktoré boli manuálne segmentované a používajú ich ako referenčné dáta na zaradenie nových dát. Existuje viacero spôsobov ako budú trénovacie dáta použité klasifikačnou metódou. Najjednoduchším klasifikátorom je *nearest-neighbor*, ktorý nepotrebuje poznať východzie predpoklady o rozložení testovacích dát. Obsahuje trénovaciu množinu kladných aj negatívnych ohodnotení. Vzorka je klasifikovaná na základe vypočítania vzdialenosti k najbližšej trénovacej vzorke. K-nearest-neighbor (KNN) klasifikátor je zovšeobecnením spomenutého prístupu, kde rozhodnutie o klasifikácii závisí na  $k$  najbližších vzorkách. Bežne používaný parametrický klasifikátor je *maximum-likelihood* (ML) alebo inak *Bayesov* klasifikátor. Popisuje triedy vzoriek pomocou *Gaussian Mixture Models*. Každá trieda je popísaná gaussovým modelom pozostávajúcim z váhovaných Gaussových kriviek [10].

## 2.6 Markov Random Fields

Modelovanie pomocou Markovových náhodných modelov (angl. *Markov random field* - MRF) nie je segmentačná technika, ale štatistický model používaný v segmentačných technikách. MRF modeluje priestorové väzby medzi blízkymi pixelmi obrazu. Model predpokladá, že segment o veľkosti jedného pixelu má malú pravdepodobnosť výskytu v obraze [11].

MRF bývajú využívané metodami zhlukovej analýzy (*K-means*). Segmentáciu získame maximalizáciou posteriornej pravdepodobnosti  $p(C|X)$  pre všetky body obrazu použitím iteratívnych metód, ako napríklad simulované ochladzovanie [12].

Hlavnou nevýhodou MRF je obtiažne určenie parametrov kontrolujúcich silu geometrických väzieb. Ak sa parametre nenastavia správne, nastane situácia, kedy sú hranice medzi jednotlivými regiónmi príliš hladké a zapríčinia stratu dôležitých detailov. Aj napriek spomenutým nevýhodám a značnej výpočtovej zložitosti sa MRF často využívajú v praxi. Používajú sa napr. k modelovaniu nehomogenít v obraze, nerovnomerného osvetlenia, štruktúry a textúry segmentov obrazu. Pre podrobnejšie informácie viď [11]. Segmentáciu medicínskych dát pomocou MRF ilustruje obrázok 6.




Obrázok 6: Segmentácia mozgu; a) originál; b) segmentácia metódou *K-means*; c) segmentácia metódou *K-means* v spojení s MRF [10].

## 2.7 Neurónové siete (NN)

Neurónové siete sa stali predmetom skúmania po ich „znovuobjavení“ v osemdesiatych rokoch, ako nástroj na rozpoznávanie vzorov v obraze. Dá sa povedať, že NN sú pokusom o abstrakciu a napodobenie funkcie mozgu živých organizmov. Neurónovou sieťou nazývame takú štruktúru, ktorá slúži pre paralelné spracovanie informácií skladajúce sa z veľmi vysokého počtu výkonných prvkov (neurónov). Topológia neurónovej siete je určená jej grafom, kde uzly tvoria neuróny a hrany



grafu sú spoje medzi jednotlivými prvkami. Vzhľadom ku geometrickej štruktúre siete, môžeme niektoré prvky siete združovať podľa zhodných vlastností na úseky, ktoré potom tvoria základnú neurónovú sieť [13].



Obrázok 7: Výsledok plne automatickej segmentácie šedej a bielej kôry mozgovej pomocou GRBF neurónovej siete [14].

Výhody neurónových sietí spočívajú v spojení dvoch algoritmov pre tréning neurónovej siete, a to učenie s učiteľom a bez učiteľa. Nevýhodou je potreba manuálnej anotácie tréningových dát. Pre podrobný popis neurónových sietí vid' online zdroj<sup>1</sup> alebo [13]. Segmentáciu medicínskych dát pomocou neurónových sietí ilustruje obrázok 7.

## 2.8 Atlas-guided metódy

Atlas-guided (AG) prístupy predstavujú silný nástroj na segmentáciu medicínskych dát, ak je prítomný štandardný atlas alebo šablóna. Atlas [27] je generovaný zostavením informácií o anatomickej štruktúre, ktorá má byť segmentovaná. Tento atlas je potom použitý ako referenčné kritérium pri segmentácii nových dát. V princípe sa AG metódy podobajú klasifikátorom, ale sú definované na doméne geometrie a nie na doméne rysov obrazu [10].

---

<sup>1</sup> <http://www.particle.kth.se/~lindsey/nnwLinks.html>




Obrázok 8: 3 rezy ľudského mozgu preložené s warped-atlas [10].

Štandardný AG prístup je chápaný ako problém registrácie (angl. Registration) [13]. Hľadá sa transformácia 1:1, ktorá namapuje predsegmentovaný obraz atlasu na obraz, ktorý chceme segmentovať. Tento proces sa často nazýva *atlas-warping* [27].

AG boli aplikované hlavne na spracovanie obrazu z magnetickej rezonancie. Ich výhodou je, že so segmentáciou sa na obraz prenáša aj samotné označenie segmentovanej časti podľa atlasu. Na druhú stranu je ťažká presná segmentácia komplexných štruktúr, kvôli anatomickej variabilite. Situáciu znázorňuje obrázok 8, kde je vidno, že mozgová kôra nie je segmentovaná tak dobre ako na obrázku 6. Preto sú AG metódy vhodné na segmentáciu stabilných štruktúr [10].

## 2.9 Deformable models (DM)

Deformovateľné modely sú založené na fyzikálnom modeli určenom na vymedzenie hraníc regiónov. Využívajú pritom uzavreté parametrické krivky, alebo plochy, ktoré sa deformujú vplyvom externých a vnútorných síl.



Obrázok 9: priebeh evolúcie metódy aktívne kontúry [31].

Vnútorné sily sú vypočítané z danej krivky alebo plochy tak, aby bola zachovaná vlastnosť hladkosti povrchu počas procesu deformácie. Externé sily sú naopak vypočítané zo samotného



obrazu tak, aby výsledný model reprezentoval hranice objektu v obraze [10]. Príkladom sú aktívne kontúry v 3D priestore [1]. DM sa pohybuje na základe jeho dynamických rovníc a hľadá minimum funkcie energie [29].

Výhodou DM je práve vlastnosť priamo produkovať parametricky uzavreté krivky a plochy z obrazu a ich podmienka pravidelného a hladkého povrchu, ktorá robí metódu robustnou a odolnou voči šumu. Jednou z hlavných nevýhod metódy je ich problém s konkávnymi povrchmi a taktiež nedokážu meniť svoju topológiu (rozdelenie alebo spájanie modelu) počas deformácie. Vyčerpávajúci prehľad DM a ich vylepšení sa nachádza v [13, 28, 30]. Segmentáciu deformovateľnými povrchmi ilustruje obrázok 9 a obrázok 17.

## 3 Level Set method

LS je robustná metóda rodiny metód *shape reconstruction* a *deformable models*, ktorú pôvodne navrhli páni J. A. Sethian a S. Osher [16]. Myšlienku použitia LS na detekciu tvaru uviedol ako prvý R. Malladi [19]. Teória LS ďalej našla uplatnenie aj v iných oblastiach ,ako *crystal growth and dendritic solidification* [33].

Hlavný prínos metódy LS je v tom, že ide o od základu nový prístup rekonštrukcie tvaru, ktorý prekonáva obmedzenia dovtedy známych techník v danej oblasti. Vyvýjajúci sa povrch vie meniť svoju topológiu (rozdeliť sa, spájať sa), dokáže kopírovať rôzne komplexné geometrie tvarov a výsledok je menej závislý na inicializácii ako akákoľvek iná iteratívna metóda [15]. Tento prístup bol použitý už skôr v mnohých oblastiach počítačového videnia. Bolo navrhnutých viacero evolučných modelov, ale mnohé z nich vyžadujú zadanie viacerých parametrov ako iteračný krok, váhové parametre, propagáciu frontu a ďalšie, pričom nastavenie týchto parametrov je kľúčové pre úspech metódy. Metóda, ktorú navrhol R. Malladi, nepotrebuje pre vývoj v priestore takmer žiaden parameter. Využíva parametre závislé na obrazových dátach a na konkrétnom stave procesu segmentácie [19].

### 3.1 Matematický základ

Metóda LS je popísaná všeobecne pre  $N$ -rozmerný priestor, a teda je vhodná na riešenie v 2D a 3D priestore. Základnou myšlienkou LS je popísať pohyb *hypersurface* (nadplochy)  $\Gamma(t)$  v  $(N-1)$  dimenzionálnom priestore, ktorá sa šíri priestorom v ortogonálnom smere vzhľadom na povrch silou  $F$ . Sila  $F$  môže byť odvodená od parametrov ako krivosť povrchu, ortogonálny smer, vlastnosti média, na ktorom je definovaný model (obrazová informácia). Hlavnou myšlienkou LS je chápať tento vyvíjajúci sa povrch ako *nulový rez* viacdimenzionálnej funkcie  $\Phi$ . Definujme  $\Phi$  nasledovne. Nech funkcia  $\Phi(x, t=0)$ , kde  $x$  je bod patriaci do  $R^N$ , je definovaná ako:

$$\Phi(x, t=0) = \pm d, \quad (5)$$

kde  $d$  je vzdialenosť bodu  $x$  od povrchu  $\Gamma(t=0)$  a znamienko plus (mínus) je vybrané na základe toho, či je bod  $x$  mimo (vo vnútri) počiatkovej hyperplochy  $\Gamma(t=0)$ . Máme teda počiatkovú funkciu

$$\Phi(x, t=0): R^N \rightarrow R, \quad (6)$$


s vlastnosťou:

$$\Gamma(t=0) = [x \vee \Phi(x, t=0) = 0]. \quad (7)$$

Cieľom je rovnicou popísať vyvíjajúcu sa funkciu  $\Phi(x, t)$ , ktorá popisuje pohyb plochy  $\Gamma(t)$  ako level set  $\Phi = 0$  (situáciu ilustruje obrázok 10). Každý level funkcie  $\Phi$  je určený gradientným poľom s rýchlosťou  $F$ , čo vystihuje rovnica

$$\Phi_t + F |\nabla \Phi| = 0, \quad (8)$$

kde  $\nabla$  je gradient level setu. Pre konkrétnu funkciu rýchlosti  $F$  treba riešiť štandardné *Hamilton-Jacobi* rovnice [21]. Dôležité je, že propagujúci front môže zmeniť svoju topológiu (rozdelenie na viacero častí) a stále bude splnená rovnica 8. To je rovnica LS navrhnutá podľa zakladateľov Sethian a Osher [15].



Obrázok 10: Level set funkcia (červená) vykresluje vzdialenosť každého bodu  $(x, y)$  od frontu (modrá); Obrázok prevzatý z [18]

## 3.2 Formulácia rýchlosti $F$

Vo všeobecnosti sa dá sila  $F$  rozdeliť na dve časti:  $F = F_A + F_G$ , kde  $F_A$  je sila nezávislá na geometrii pohybujúceho sa frontu a určuje sa iba podľa znamienka, teda podľa toho, či bude front expandovať alebo sa zmršťovať. Sila  $F_G$  závisí na geometrii postupujúceho frontu, čo je napríklad krivosť povrchu [16]. Ak bod  $x \in R^2$ , tak krivosť je definovaná ako

$$K = \frac{(\Phi_{yy} \Phi_x^2 - 2 \Phi_x \Phi_y \Phi_{xy} + \Phi_{xx} \Phi_y^2)}{(\Phi_x^2 + \Phi_y^2)^{\frac{3}{2}}}. \quad (9)$$

Tento prístup je jednoducho rozšíriteľný do vyšších dimenzií [15].

### 3.3 Rekonštrukcia tvaru propagáciou frontu


Uvažujme prípad, kedy sa front vyvíja konštantnou rýchlosťou napr.  $F_A = F_G$  (viď obrázok 11). Ak chceme doceliť, aby sa rýchlosť šírenia frontu blížila k nule blízko hrán v obraze, definujeme negatívnu silu odvodenú z obrazu nasledovne:

$$F_I(x, y) = \frac{-F_A}{(M_1 - M_2)} \{ |\nabla G_\sigma * I(x, y)| - M_2 \}, \quad (10)$$

kde  $M_1$  a  $M_2$  sú maximálne a minimálne hodnoty intezity frontu. Výraz  $G_\sigma * I(x, y)$  hovorí, že obraz bol konvoluovaný Gaussovým vyhladzovacím filtrom. Výsledná rovnica pohybu s pridanou silou získanou z obrazu je

$$\Phi_t + (F_A + F_I) |\nabla \Phi| = 0. \quad (11)$$

Metóda LS je zložitý problém, ktorého popis je mimo rozsah tejto práce. Detailný matematický popis modelu LS ako aj rôznych vylepšení a modifikácií možno nájsť v bohatých zdrojoch špecializujúcich sa na tému LS [15, 16, 17, 18, 19, 20, 21].



Obrázok 11: Postup frontu silou  $F$  [18].

### 3.4 Rôzne urýchlenia LS metód


Prezentovaná metóda LS je priamočiara a pomerne ľahko naprogramovateľná. Hlavnou nevýhodou je ale to, že metóda je veľmi pomalá a nevyužíva optimálne výpočtové prostriedky. Existuje zopár sofistikovanejších metód, ktoré urýchľujú výpočet.

### 3.4.1 Paralelné spracovanie

Predstavený prístup riešenia LS rieši parciálne derivácie pre výpočet funkcie  $\Phi$  na celej doméne. Z podstaty problému vyplýva, že sa ponúka paralelizácia ako prostriedok na urýchlenie výpočtu. Konkrétny popis je možné nájsť v [23].

### 3.4.2 Adaptive mesh refinement


Vychádza z princípu, že v miestach kde majú levely funkcie  $\Phi$  veľkú krivosť, alebo v miestach kde sa rapídne mení hodnota funkcie  $\Phi$ , sa použije prispôsobiteľné zjemňovanie mriežky v tomto okolí. Tento prístup naznačuje obrázok 12, kde je vidno, že v oblastiach s väčšou krivosťou je delenie mriežky jemnejšie. Pre podrobné informácie ohľadom *adaptive mesh refinement* viď [24].



Obrázok 12: Adaptive mesh refinement [16].

### 3.4.3 Narrow band (NB)


Dôvodom zavedenia urýchlenia klasickej LS metódy je myšlienka prevádzania výpočtu iba v blízkosti *zero level setu*. Nerieši sa teda výpočet na doméne celej LS funkcie, ale iba na nulovej hladine. Tento prístup sa nazýva *narrow band*. Zložitosť výpočtu klesla z  $O(N^3)$  na  $O(kN^2)$  pre 3D prípad.



Obrázok 13: Znáozornenie Narrow Band [16].

Princíp je značne priamočiary a dá sa demonštrovať na základe dvoch ilustrácií. Na obrázku 13 je znázornené umiestnenie NB okolo spomínaného frontu. Celá 2D mriežka je umiestnená vo štvorcovom poli. Na popis samotného NB potom využívame jednodimenzionálny objekt v tomto poli (čierne body na obrázku 14 popisujú NB okolo frontu s užívateľsky zadanou hrúbkou). Hodnoty  $\Phi$  sa potom rátať iba v úzkom pásom vymedzenom samotným NB a ostatné hodnoty mriežky sa nepočítajú, pretože sú zatiaľ mimo oblasť nášho záujmu. Akonáhle však pohybujúci sa front dosiahne hranicu vymedzenú úzkym pásom, výpočty sa pozastavia a je nutné určiť obdobným spôsobom nový pás NB, kde hranica samotného frontu bude znovu v strede úzkeho pásu. Tento proces je známy ako *reinizializácia*. Pre podrobný popis procesu reinizializácie, určenia správnej šírky NB a iných detailov, viď [16,22].

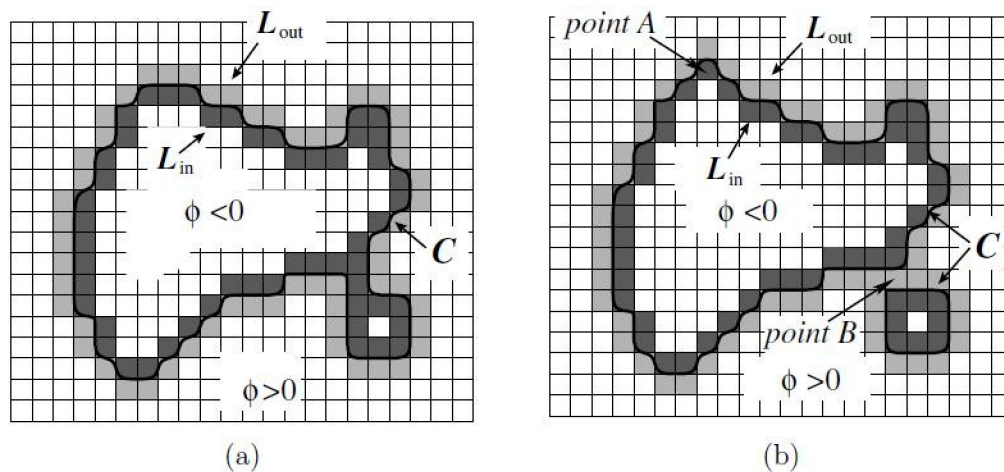




Obrázok 14: Vektor bodov určuje hraničné body NB [16].

### 3.5 Fast Method

Revolučná modifikácia metódy LS pre segmentáciu diskretných dát [25]. Doteraz spomenuté metódy a vylepšenia LS sa pokúšajú sledovať evolúciu *zero level set* funkcie s veľkou presnosťou riešením parciálne diferenciálnych rovníc (PDEs). Avšak táto presnosť nie je vôbec potrebná pre problémy počítačového videnia ako sú segmentácia a sledovanie objektov, kde je cieľom extrakcia tvaru



Obrázok 15: (a) Implicitná definícia krivky  $C$  v LS metóde. Definícia zoznamov  $L_{in}$  a  $L_{out}$ ; (b) Popis pohybu krivky na základe výmeny bodov medzi  $L_{in}$  a  $L_{out}$  [25].

objektov. V takom prípade nás viac zaujíma výsledok než samotný evolučný proces LS funkcie. Nová metóda nepotrebuje riešiť PDEs. Namiesto toho sú potrebné iba jednoduché operácie ako vkladanie a mazanie prvkov zo zoznamov obsahujúcich hraničné body frontu, potrebné na vývoj povrchu. V porovnaní s predchádzajúcimi optimalizovanými postupmi NB, je FLSM rýchlejšia až o

dva rády v 2D aj v 3D priestore. Vďaka tomu je možné implementovať real-time LS metódu, čo dovtedy nebolo možné kvôli veľmi vysokej výpočtovej náročnosti metódy LS [26].

### 3.5.1 Matematický aparát

V metóde LS je krivka  $C$  implicitne definovaná ako *zero level set* funkcie  $\Phi$ , ktorá je definovaná nad fixnou mriežkou znázornenou na obrázku 15 (a). Volíme  $\Phi$  pozitívnu vo vnútri krivky  $C$  a negatívnu mimo krivky  $C$ . Predpokladáme, že  $\Phi$  je definovaná na doméne  $D \subset R^K$  a je diskretizovaná do mriežky veľkosti  $M_1 \times M_2 \times \dots \times M_K$ . Ďalej predpokladáme, že mriežka je uniformne vzorkovaná intervalom 1. Súradnice bodu  $x$  mriežky označujeme ako  $x = (x_1, x_2, \dots, x_K)$ . Následne môžeme definovať krivku  $C$  ako dva zoznamy  $L_{in}$  a  $L_{out}$  susedných bodov v mriežke nasledovne:

$$\begin{aligned} L_{in} &= \{ x \mid \Phi(x) < 0 \text{ a } \exists y \in N(x) \text{ také že } \Phi(y) > 0 \} \\ L_{out} &= \{ x \mid \Phi(x) > 0 \text{ a } \exists y \in N(x) \text{ také že } \Phi(y) < 0 \} \end{aligned} \quad (12)$$

kde  $N(x)$  je okolie bodu  $x$  definované ako:

$$N(x) = \{ y \in D \mid \sum_{k=1}^K |y_k - x_k| = 1 \} \quad \forall x \in D, \quad (13)$$

kde  $|y_k - x_k|$  je Euklidovská vzdialenosť. Ako je vidno z obrázku 15(b),  $L_{in}$  je zoznam susediacich bodov vo vnútri krivky  $C$  a  $L_{out}$  je zoznam susediacich bodov mimo krivky  $C$ . Samotná krivka je reprezentovaná pomyselné ako krivka popisujúca rozhranie medzi vnútornými a vonkajšími bodmi.

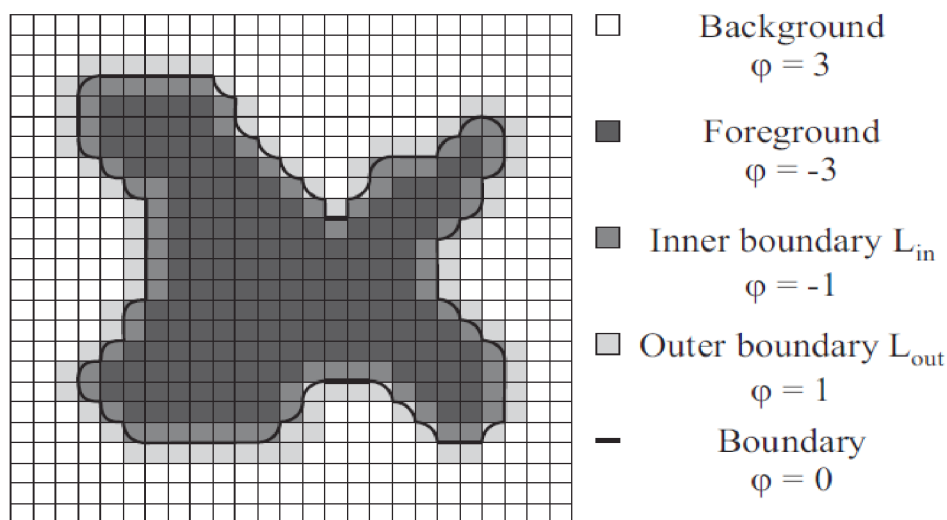
Pre evolučný algoritmus nie sú potrebné hodnoty funkcie  $\Phi$  vo vzdialených bodoch vzhľadom na hraničné body. Pre zjednodušenie je možné reprezentovať funkciu  $\Phi$  iba obmedzeným počtom hodnôt [25]. Blízko nulového rezu (zero level set), bude funkcia  $\Phi$  zhruba aproximovať funkciu vzdialenosti. Môžeme teda podľa [25] formálne definovať funkciu  $\Phi$  nasledovne:

$$\Phi(x) = \begin{cases} 3 & \text{ak sa } x \text{ nachádza mimo funkcie } \Phi \\ 1 & \text{ak } x \in L_{out} \\ -1 & \text{ak } x \in L_{in} \\ -3 & \text{ak sa } x \text{ nachádza vo vnútri funkcie } \Phi \end{cases} \quad (14)$$

Situáciu graficky znázorňuje obrázok 16. Evolúcia modelu prebieha aktualizovaním hraničných zoznamov bodov  $L_{in}$  a  $L_{out}$ . Daná hranica sa deformuje na základe skalárneho silového poľa VF. Toto pole má podľa [25] formu binárnej masky s hodnotami  $\{+1, -1\}$ . Tieto hodnoty určujú, či sa bude hranica v priestore rozťahovať alebo zmršťovať. Ďalej, model disponuje vnútornou silou, ktorá určuje elasticitu a hladkosť výsledného povrchu. Podrobnejší popis problematiky sa nachádza



v kapitole 5.1 na strane 34 alebo informácie o tejto metóde vrátane algoritmov môžu byť vyhľadane v príslušnej literatúre [25, 26, 36].

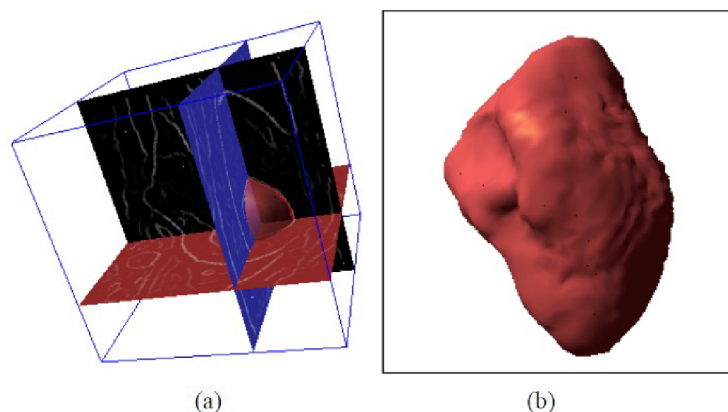


Obrázok 16: Klasifikácie jednotlivých pixelov obrazu podľa hodnoty vzdialenostnej funkcie  $\Phi$  [26].

### 3.6 Segmentácia deformovateľnými povrchmi

Deformovateľné povrchy (DP) získali na popularite po tom, ako bolo navrhnuté ich použitie v oblasti počítačovej grafiky v osemdesiatych rokoch dvadsiateho storočia [33]. Čoskoro sa odhalil potenciál DP a ich využitie v rýchlo sa rozvíjajúcej oblasti analýzy medicínskych dát. Boli aplikované na obrazovú informáciu z rôznych medicínskych zobrazovacích zariadení ako sú CT, MRI, PET, RTG a ultrazvuk. Začali sa využívať ako 2D, tak aj 3D deformovateľné modely, a to hneď vo viacerých oblastiach ako segmentácia, vizualizácia a tracking. Jedná sa napríklad o segmentáciu mozgu, srdca, tváre, tepien, žíl, vnútorných orgánov, ďalej objektov ako mozgové nádory, ľudský plod a bunčné štruktúry ako neuróny a chromozómy. Ďalej sa deformovateľné modely využívali na sledovanie premenného pohybu srdca, rastúceho výbežku neurónu alebo pohyb erytrocytov. Použitie je skutočne rozmanité a obsiahne, čo dokazuje ich univerzálnosť a robustnosť.

Avšak deformovateľné modely trpia aj mnohými obmedzeniami a nedostatkami, ktoré bránia ich použitiu vo viacerých oblastiach. Jedná sa hlavne o syntézu tvaru objektov v dátach s veľkým podielom šumu. Ďalej nie sú schopné modelovať delenie ani zlučovanie povrchu, teda popisovať zmenu topológie vyvíjajúceho sa povrchu.



Obrázok 17: (a) Deformovateľný model “balloon” vsadený do volumetrických dát deformovaný podľa hrán LV (b) Rekonštrukcia povrchu LV [28].

V osemdesiatych rokoch dvadsiateho storočia bol navrhnutý matematický model LS popisujúci vyvíjajúci sa povrch [16]. V oblasti medicínskeho zobrazovania [15,24,28] hrajú techniky LS významnú rolu hlavne vďaka ich unikátnym vlastnostiam, ktoré prekonávajú hlavné obmedzenia deformovateľných povrchov [28]. Jedná sa hlavne o možnosť zmeny topológie, ako rozdelenie povrchu na viacero častí, alebo naopak ich zlúčenie do väčšieho celku počas evolúcie povrchu. Pre podrobnejší popis viď kapitola 3.

LSM disponuje veľkou výpočtovou silou a robustnosťou. Aplikácie využívajúce túto metódu sú však limitované v časovej oblasti povahou samotnej metódy level-set. Tá totiž k spomenutej evolúcii povrchu potrebuje vypočítavať zložité parciálne diferenciálne rovnice v každom kroku viacerokrát. Je teda žiaduce nejaké urýchlenie tejto metódy aby ju bolo možné interaktívne využívať v daných oblastiach. Jednou z možností je využitie stále rastúceho výkonu počítačových komponentov, ktoré sú schopné čoraz rýchlejšie riešiť jednotlivé kroky. Jednou zo sľubných oblastí urýchlenia výpočtu je implementácia problému na grafickom procesore, ktorý je mnohonásobne rýchlejší pri výpočtoch s pohyblivou desatinnou čiarkou. Ďalšou možnosťou sú rôzne modifikácie samotnej metódy (viď 3.4). Mnohé z urýchlení skutočne znižujú celkový výpočtový čas, ale stále využívajú PDEs, ktoré sú na celkovom výpočte najviac časovo náročné. Keď si prevedieme problém LS do oblasti segmentácie objemových medicínskych dát, nastáva ďalšia komplikácia. Tieto objemové dáta sú geometricky rozmerné a môžu obsahovať až stovky miliónov obrazových bodov. Ak potrebujeme segmentovať takto veľký objem, časová zložitosť tým rapídne narastá. Aj pri metóde NB, ktorá poskytuje urýchlenie LSM, treba pre každý bod priestoru, ktorým vyvíjajúci sa povrch prejde, minimálne raz počítať PDEs určujúce smer a rýchlosť ďalšieho pohybu z daného bodu. Pre potreby interaktívnej práce s vyvíjajúcim sa modelom a real-time zobrazenia povrchu, sú tieto možnosti nedostatočné.

V roku 2005 bola navrhnutá revolučná modifikácia LSM nazývaná Fast level-set method [25]. Je rozšírením klasickej LSM [16]. Odlišnosť tejto metódy spočíva vo vylúčení riešenia PDEs pre evolúciu povrchu modelu. Pre podrobnejší popis FLSM viď kapitola 3.5. Tento nový prístup disponuje všetkými výhodami pôvodnej metódy, a navyše obsahuje modifikácie, ktoré urýchľujú výpočtový čas vyvíjajúceho sa povrchu až o dva rády [26]. Jedná sa hlavne o diskretizovaný pohľad na problém. Popis tejto modifikácie je teda prispôsobený na diskrétna dáta. Nepoužívajú sa pri výpočtoch časovo náročné PDEs, a teda celkový čas výpočtu sa rapidne skrúti. V diskretných dátach nepotrebujeme sub-pixelovú presnosť, keďže nás až tak nezaujíma presný matematický popis evolúcie povrchu, ale jeho výsledný tvar. Keď zosumarizujeme pozitívne vlastnosti FLSM :

- rýchly výpočet,
- možnosť zmeny topológie
- reprezentácia v 2D aj 3D priestore,
- diskrétna doména,

tak zo všetkých spomenutých vylepšení LSM má najlepšie predpoklady na použitie v interaktívnej aplikácii.

## 4 Existujúce nástroje segmentácie medicínskych dát

V tejto kapitole popíšem potrebu segmentácie medicínskych dát ako jeden z možných nástrojov, ktoré môžu prispieť k skvalitneniu posudku nemocničných vyšetrení. Kapitola popisuje myšlienkové postupy, ktoré znázorňujú cestu od analyzovania použitia segmentácie cez využitie deformovateľných modelov až po záver v podobe potreby segmentácie pomocou FLSM. Taktiež sa tu nachádza prehľad dostupných nástrojov (v čase písania práce) určených na segmentáciu medicínskych dát, ktoré pracujú s metódou LSM.

### 4.1 Potreba segmentácie medicínskych dát

Segmentácia anatomických štruktúr, čo je rozdelenie pôvodnej množiny obrazových bodov do množín reprezentujúcich konkrétne štruktúry, je dôležitou prvou fázou v mnohých medicínskych úlohách ako registrácia, labeling a motion tracking. Tieto úlohy vyžadujú, aby anatomické štruktúry v originálnych dátach boli prevedené na analytickú reprezentáciu ich tvarov. Manuálna segmentácia vyžaduje veľké úsilie a je časovo náročná. Jedným z príkladov segmentačných úloh môže byť segmentácia srdca, konkrétne ľavej srdečnej komory (LV) na kardiologickom oddelení (viď obrázok 17). Segmentácia LV je predpokladom na získanie diagnostických informácií ako podiel vypudenej krvi z LV, objem srdcových dutín, výdaj srdca a analýza pohybu srdcovej steny [28].

Ešte dnes sa často uskutočňuje segmentácia spôsobom manuálnej úpravy jednotlivých rezov dát. V takom prípade skúsený špecialista využívajúc počítačovú myš manuálne obkresľuje oblasť záujmu na každom reze obrazových dát. Takáto segmentácia trpí mnohými nedostatkami. Patrí sem napríklad nemožnosť reprodukovateľnosti rovnakého výsledku, pracovná nepresnosť a únava, a hlavne spôsob merania tvaru a objemu 3D štruktúr na základe separátnej analýzy každého 2D snímku.

Je preto žiaduce, aby mali lekári pri vyhodnocovaní obrazových dát čo najviac podpory. Dnešné počítačové algoritmy na spracovanie obrazu dokážu extrahovať z obrazu mnoho informácií, ktoré môžu lekárom pomôcť pri posudzovaní za veľmi krátky čas. Dnešným paradoxom je, že máme k dispozícii veľké množstvo dát a nedokážeme ho poriadne interpretovať. V oblasti medicíny je problém podobný. Charakter objemových medicínskych dát poskytuje o danom pacientovi obrovské množstvo dát, ktoré je treba vhodne interpretovať. Avšak spôsob akým je stanovovaná diagnóza nevyužíva plný potenciál objemovej reprezentácie dát. Akýmsi nástrojom na lepšie porozumenie


a orientáciu v priestore ponúka vizualizácia anatomických štruktúr konkrétneho pacienta. Tu sa teda ponúka možnosť využívať metódy spracovania obrazu, ktoré sú objektovo (deformovateľné povrchy) zamerané, a ktorých výsledok je možné vizualizovať a poskytnúť tak dodatočnú informáciu k objemovým dátam. Tento spôsob vedie na použitie techniky, ktorá je orientovaná na objekt, teda na segmentáciu používa napríklad deformovateľný povrch.

## 4.2 Nástroje využívajúce LSM

V dobe písania práce existuje niekoľko nástrojov využívajúcich LSM. Väčšina z nich používa klasickú LSM [16], ktorá využíva PDEs. Nástroje alebo privátne aplikácie ktoré využívajú FLSM sú hlavne predmetom výskumu a slúžia na súkromné účely. Jedná sa prevažne o vedecké práce popisujúce túto metódu [25, 26, 35].

### 4.2.1 3DSLICER

3D Slicer<sup>2</sup> je multi-platformový open source software určený na vizualizáciu a spracovanie medicínskych dát. V dobe písania tejto práce (2011) je vo verzii 3.6 a využíva okrem iného aj metódu LSM na účely spracovania a segmentácie dát.



*Obrázok 18: Pravá koronárna artéria. Model výsledku evolúcie pomocou metódy level-set. Obrázok prevzatý z <http://www.slicer.org/slicerWiki/images/8/8c/Vmtkafterevolution.png>.*

---

<sup>2</sup> <http://www.slicer.org/>

Súčasťou programu je aj modul zvaný *The Vascular Modeling Toolkit (VMTK)*<sup>3</sup>, ktorý slúži na 3D rekonštrukciu, geometrickú analýzu a generovanie povrchu pre účely modelovania ciev. Je teda vhodný napr. na segmentáciu mozgovej aneurizmy, extrakciu cievneho systému, alebo segmentáciu priedušiek. Na tento účel je možné využiť modul *VMTKLevelSetSegmentation*, alebo *VMTKEasyLevelSetSegmentation*. Avšak podľa dostupných informácií na oficiálnej stránke produktu 3D slicer, bolo na evolúciu výsledného modelu reprezentujúceho povrch pravej koronárnej artérie (viď obrázok 18) potrebných desať iterácií a výpočtový čas sa pohyboval okolo šiestich minút na počítači Quad Core 2.6GHz Xeon s 6GB RAM pamäte. Vzhľadom na celkovú veľkosť výsledného modelu, je výpočtový čas mnohonásobne väčší ako v prípade segmentácie objektov podobných rozmerov použitím metódy FLSM. Pre porovnanie viď kapitolu 7.1 alebo [26].

## 4.2.2 ITK

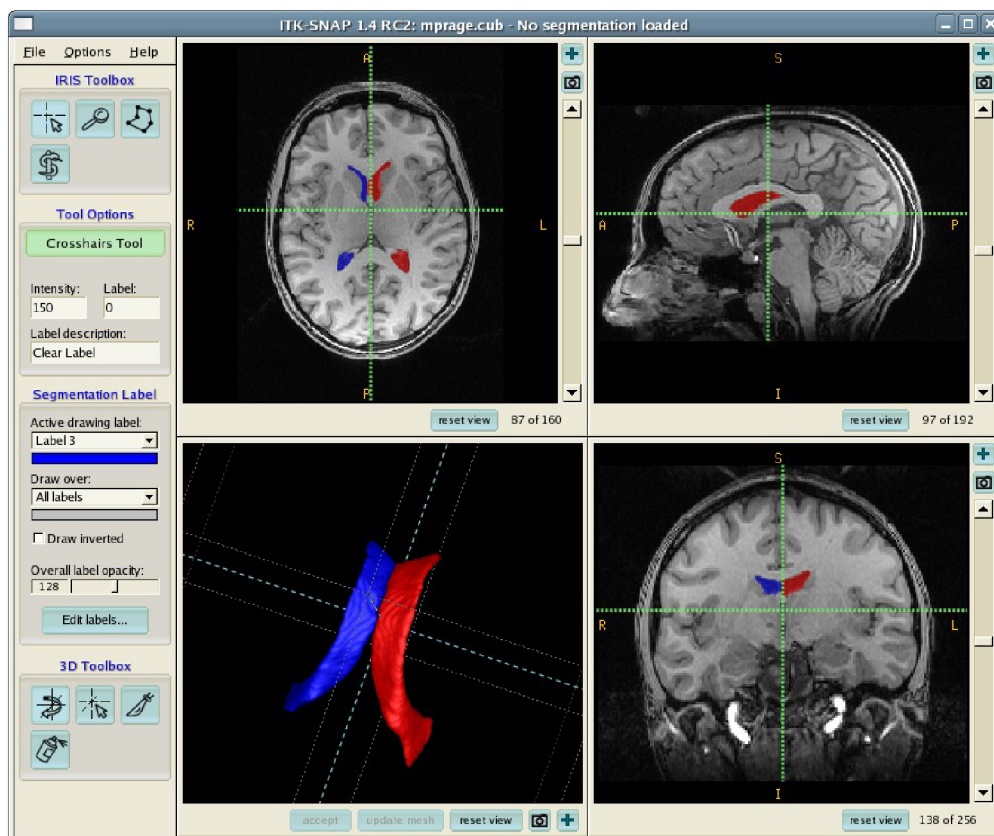
Insight Segmentation and Registration Toolkit<sup>4</sup> (ITK) je open-source, cross-platformový systém slúžiaci na analýzu obrazu. Obsahuje vysoko sofistikované algoritmy na spracovanie, segmentovanie a registrovanie multidimenzionálnych dát. ITK slúži hlavne na spracovanie medicínskych dát. Vznik projektu sa datuje do roku 1999, kedy *The US National Library of Medicine of the National Institutes of Health* podpísal kontrakt na vývoj open-source nástroja slúžiaceho na segmentáciu a registráciu. ITK obsahuje nepreberné množstvo algoritmov a nástrojov, ktoré tvoria základňu pre vývoj zložitejších nástrojov.

ITK nepochybne používa techniky LS či už k segmentácii, rekonštrukcii tvarov alebo ako obrazové filtre. Taktiež disponuje multidimenzionálnou reprezentáciou funkcie LS, avšak používa základnú metódu LS, alebo niektoré z jej vylepšení, ktoré ale stále počítajú spomínané PDEs uvedené v kapitole 3.4. Keďže ITK nepoužíva techniku FLSM, výpočty a segmentácia použitím LS je časovo omnoho náročnejšia ako výpočty na rovnakých dátach metódou FLSM. Pre demonštráciu porovnania viď [26].

---

3 [http://www.slicer.org/slicerWiki/index.php/Modules:VMTKEasyLevelSetSegmentation\\_AneurysmTutorial](http://www.slicer.org/slicerWiki/index.php/Modules:VMTKEasyLevelSetSegmentation_AneurysmTutorial)

4 <http://www.itk.org/>



Obrázok 19: Ukážka prostredia a segmentácie programu itk-SNAP;

Obrázok prevzatý z: <http://upload.wikimedia.org/wikipedia/en/9/9a/Itksnapshot.png>

Jedným z množstva nástrojov využívajúcich LS a ITK je segmentačný nástroj itk-SNAP (<http://www.itksnap.org/pmwiki/pmwiki.php>). Používa LS na rekonštrukciu tvarov v 3D priestore pomocou LSM. Ukážku prostredia a segmentácie ilustruje obrázok 19.

### 4.2.3 LSMLIB

The Level Set Method Library<sup>5</sup> (LSMLIB) je knižnica poskytujúca podporu pre sériovú a paralelnú simuláciu implicitných plôch a dynamiky kriviek v 2D aj 3D priestore. Zakladateľmi sú Kevin T. Chu (Serendipity Research) a Masa Prodanovic (Univ. of Texas at Austin). Jedná sa o open-source multiplatformovú knižnicu. Implementuje základné algoritmy metódy LS, ktoré sú teoreticky popísané v [16] a mnoho ďalších sofistikovaných vylepšení ktoré je možné vyhľadať v [20, 21, 22, 23, 24].

Podobne ako ostatné spomenuté nástroje, ani LSMLIB nevyužíva rýchlu metódu FLSM, ale ráta s subpixelovou presnosťou za pomoci PDEs. V konečnom výsledku je tento nástroj maximálne presný, ale za cenu veľkej časovej náročnosti.

5 <http://ktchu.serendipityresearch.org/software/lsmlib/index.html>



#### 4.2.4 LSSEG

The Level-Set Segmentation Library<sup>6</sup> (LSSEG) je knižnica vytvorená za účelom interného študijného projektu, ktorý sa zaoberá spracovaním obrazu pomocou PDEs. Súčasťou funkčnosti je aj segmentácia pomocou metódy LS. Pomocou LSSEG je možné riešiť segmentáciu ako v 2D tak aj v 3D priestore. Keďže rieši pri výpočtoch PDEs, radí sa k ostatným spomínaným nástrojom, ktoré využívajú metódu LS. Časová náročnosť výpočtu knižnice je oproti metóde FLSM omnoho vyššia.

#### 4.2.5 Ostatné implementácie

Existujú aj rôzne iné implementácie využívajúce metódu LS (viď príslušná literatúra v kapitole 3), ktoré sú často súčasťou výskumu a sú určené na súkromné a vedecké účely. Zatiaľ boli spomenuté nástroje ktoré využívajú základnú reprezentáciu metódy LS, poprípade ich rozšírenia. Existujú však aj implementácie využívajúce isté formy metódy FLSM. Jedná sa však práve o skupinu implementácií, ktoré sú súčasťou výskumu a privátnych projektov. Takéto implementácie je možné nájsť v zodpovedajúcej literatúre [25, 26, 35].

---

<sup>6</sup> <https://www.sintef.no/upload/IKT/9011/geometri/lsseg/doc/html/index.html>



## 5 Návrh riešenia

Segmentácia tradičnými nízkoúrovňovými technikami spracovania obrazu ako narastanie oblastí (region growing), detekcia hrán (edge detection) a matematicko-morfologické operácie vyžadujú značné množstvo profesionálneho riadenia. Okrem toho, automatizácia týchto metód je bez reprezentácie modelu značne obtiažna hlavne kvôli komplexnosti tvarov a veľkej variabilite medzi jedincami. Vo všeobecnosti obmedzuje povaha uvažovanej segmentácie efektivitu prístupov, ktoré berú ohľad len lokálnu informáciu. Rôzne obrazové artefakty tak môžu spôsobiť nesprávne rozdelenie do regiónov alebo nespojitosť hraníc objektov takto získanými prístupmi [28].

Segmentácia založená na schéme deformovateľných modelov v spojitosti s predspracovaním obrazu môže prekonať mnoho obmedzení manuálnej editácie jednotlivých rezov a tradičných techník spracovania obrazu. Tieto súvislé a spojité geometrické modely reprezentujú hranice objektu ako celok a môžu tak využiť *apriórnu* znalosť povrchu objektu pri segmentácii. Vlastná súvislosť a hladkosť modelov sa dokáže vysporiadať s obrazovým šumom, trhlinami a ďalšími nepravidelnosťami v povrchu hľadaného objektu. Parametrická reprezentácia modelu poskytuje kompaktný analytický popis povrchu objektov. Tieto vlastnosti vedú k elegantnému a robustnému spôsobu, ako z dát zaťažených šumom extrahovať koherentný model povrchu. Pre podrobnejší popis deformovateľných modelov vid' kapitola 2.9.

V tejto kapitole predstavím návrh implementácie metódy level-set podľa príslušnej literatúry [25, 26]. Motiváciou pre takýto krok je skutočnosť, že sa metóda level-set často využíva v oblasti spracovania obrazu a v neposlednom rade vďaka existencii jej modifikácie v podobe FLSM, ktorá výpočet mnohonásobne urýchľuje. Táto metóda patrí do rodiny metód deformovateľných povrchov a má všetky ich vlastnosti, ktoré sú obohatené o niekoľko ďalších vhodných vlastností (vid' kapitola 5.1). Výsledkom práce by mala byť implementácia tejto metódy podľa príslušného teoretického podkladu [25, 26, 35] v podobe nástroja určeného na segmentovanie medicínskych objemových dát.

Z celkového pohľadu by mal navrhnutý nástroj demonštrovať potenciál metódy. Určite by mal implementovať samotnú metódu a obsahovať rôzne experimenty s jej vlastnosťami, ktoré by sa dali efektívne využiť. Tieto vlastnosti a rozšírenia ponúkajú viacero príležitostí zvýšenia interaktivity segmentácie. Jednalo by sa o prvý segmentačný nástroj svojho druhu, práve vďaka využitiu tejto metódy.

Z predchádzajúcej kapitoly vyplýva, že vlastnosti metódy level-set sú pre interaktívnu segmentáciu medicínskych dát veľmi atraktívne. Bol uskutočnený aj prieskum dostupných nástrojov, ktoré implementujú metódu level-set (vid' kapitola 4.2). Žiaden z nich však neimplementuje urýchlenú variantu FLSM.

Priestor na experimentovanie sa ponúka v oblasti rôznych tzv. externých polí, ktoré určujú pohyb narastajúceho povrchu a v oblasti popisu povahy samotnej metódy, ktorá ponúka viacero možností. Jedná sa hlavne o možnosť krokovania procesu segmentácie, návratov v tomto procese alebo o zmenu konfigurácie v ktoromkoľvek momente segmentácie a následné pokračovanie s už zmenenými parametrami. Rozoberané budú aj možnosti rozšírenia, vyplývajúce zo znalosti konkrétnej segmentácie, ktoré budú užitočné v jednotlivých oblastiach a špeciálnych prípadoch. Tieto vlastnosti a ich možné využitie budú popísané a rozvedené podrobnejšie v tejto kapitole.

Nad rozsah práce je navrhnutá nadstavba, ktorá by spomenutú implementáciu rozšírila. Jedná sa o voliteľnú časť, ktorá by rozšírila implementáciu o pokročilejšie grafické rozhranie, dovoľujúce zmenu a nastavovanie pokročilých parametrov, ako aj zaistenie väčšej a vizuálnej interaktivity so segmentačným procesom. Nadstavba by mala dovoľovať aj zaujímavé a žiadané rozšírenie v podobe interaktívneho zobrazovania 3D modelu reprezentujúceho povrch vznikajúceho deformovateľného povrchu.

Výsledkom tejto práce by mal teda byť istý nástroj na segmentáciu volumetrických medicínskych dát, ktorého súčasťou bude implementácia zvolenej metódy a experimentovanie s jej vlastnosťami. Prehľad základných vlastností nástroja:

- metóda fast level-set,
- história niekoľkých krokov segmentácie,
- ovplyvňovanie rozťahovania/zmršťovania povrchu,
- rôzne typy velocity field,
- rozšírenia:
  - nadstavba v podobe GUI,
  - vizualizácia povrchu.

## 5.1 Rozbor použitej metódy Fast Level-Set

Navrhnutý nástroj používa FLSM pôvodne navrhnutú v [25]. Metóda je veľmi rýchla, zatiaľ čo zachováva všetky vlastnosti pôvodnej metódy level-set. Základnou myšlienkou je reprezentácia nulového rezu funkcie level-set ako zoznam hraničných bodov a pohyb hranice povrchu na diskretnej mriežke, pričom netreba riešiť náročné PDEs. Riešime pritom iba to, kam sa pohnú body povrchu, ktoré sú ovládané externým poľom VF. Ďalším hlavným rozdielom oproti pôvodnej metóde [16] je, že VF určuje iba externú silu pôsobiacu na povrch a interná sila zodpovedajúca za hladkosť povrchu je určená samostatným krokom algoritmu v podobe vyhladzovania povrchu funkcie. Táto sekcia sa opiera o matematický základ metódy spomenutej v kapitole 3.5, kde sa nachádzajú podrobné informácie. Dodatočné detaily môžu byť vyhľadane v príslušnej literatúre [25].

### 5.1.1 Základná schéma výpočtu

Proces segmentácie danou metódou sa riadi podľa istého predpisu. Tento predpis charakterizuje postupnosť krokov nutných k správne mu prevedeniu a ich logickú náväznosť. Vo všeobecnosti sa jedná o deformovateľný model, ktorý podlieha, a je riadený istými silami. Sú nimi externá sila získaná z dát, ktorá riadi pohyb povrchu a vnútorná sila, ktorá je vlastnosťou daného povrchu a určuje jeho elasticitu. Vývoj modelu (povrchu) sa riadi podľa týchto síl a vychádza z určitej počiatocnej definície povrchu.

Prvým krokom celého procesu je teda inicializácia povrchu. Znamená to definovanie hraníc povrchu umiestneného priamo v dátach. Jediná podmienka počiatocného povrchu je, že musí byť uzavretý. Povrch ako celok je reprezentovaný jeho hranicou (tvorená hraničnými bodmi) a vzdialenostnou funkciou  $\Phi$  definujúcou povrch vo forme binárnej masky, teda množinou bodov. Vďaka explicitnej definícii povrchu je možné definovať aj viacero počiatocných povrchov, ktoré sa budú samostatne vyvíjať.

Ako bolo spomenuté, daný povrch podlieha externej sile. Preto je ďalším krokom vypočítanie externého silového poľa VF. Výpočet prebieha podľa zvolenej metódy a je určený práve počiatocnou inicializáciou povrchu a parametrami výpočtu daného VF. Ďalším krokom je určenie parametrov internej sily zodpovednej za elasticitu a hladkosť povrchu. Po zedefinovaní spomenutých úkonov prechádza proces do stavu, kedy sa môže povrch vyvíjať.

Fáza vývoja povrchu prebieha na základe energie pôsobiacej na povrch. Energia sa skladá práve z externej a vnútornej sily. Vnútorná sila je reprezentovaná fázou vyhladzovania funkcie  $\Phi$ . Vychádzajúc z vlastnosti, že je možné reprezentovať počiatocný povrch aj viacerými oddelenými povrchmi, zistíme že jednotlivé oddelené povrchy sa správajú rovnako a v čase sa vyvíjajú. Obrovský prínos tejto metódy je vlastnosť zmeny topológie povrchu. V tomto prípade to znamená, že oddelené povrchy sa vyvíjajú v čase a pri vzájomnom priblížení je možné povrchy spojiť do jedného, alebo naopak tieto povrchy ďalej deliť na menšie. Práve vďaka jednotnej reprezentácii oddelených povrchov pomocou funkcie  $\Phi$  tieto topologické zmeny povrchu prebiehajú automaticky a nie je potrebné zložitý vyšetrenie podmienok spájania, alebo rozdeľovania povrchov. Vývoj sa končí buď na základe užívateľského zásahu alebo splnenia kritéria konca evolúcie.

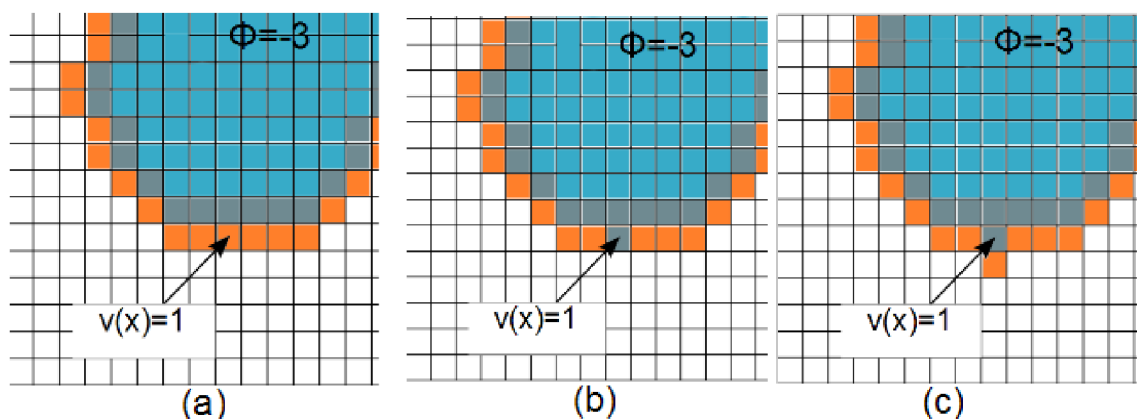
Algoritmy popisujúce prácu s metódou FLSM je možné nájsť v kapitole 6.2 (algoritmus 1, algoritmus 2, algoritmus 3).

## 5.1.2 Vývoj povrchu

Ako bolo prezentované, vyvíjajúci sa povrch je charakterizovaný zoznamom hraničných bodov na diskretnej mriežke a vzdialenostnou funkciou  $\Phi$  (viď rovnica (12)). Situáciu ilustruje obrázok 15. Pohyb hranice povrchu je určený skalárnym poľom  $v$  (VF). Reprezentuje externú silu pôsobiacu na povrch získanú z obrazovej informácie. Kladná hodnota poľa  $v$  znamená, že daný bod je vo vnútri objektu záujmu v obraze, a teda sa v tomto bode bude povrch rozťahovať. Naopak pre negatívnu hodnotu  $v$  platí, že daný bod je v oblasti pozadia, teda mimo objektu záujmu, a tak sa v tomto bode bude povrch modelu zmršťovať. Obe fázy prebiehajú separátne. Tieto dva spôsoby šírenia povrchu teraz podrobnejšie popíšem v nasledujúcich odsekoch.

### Rozťahovanie povrchu

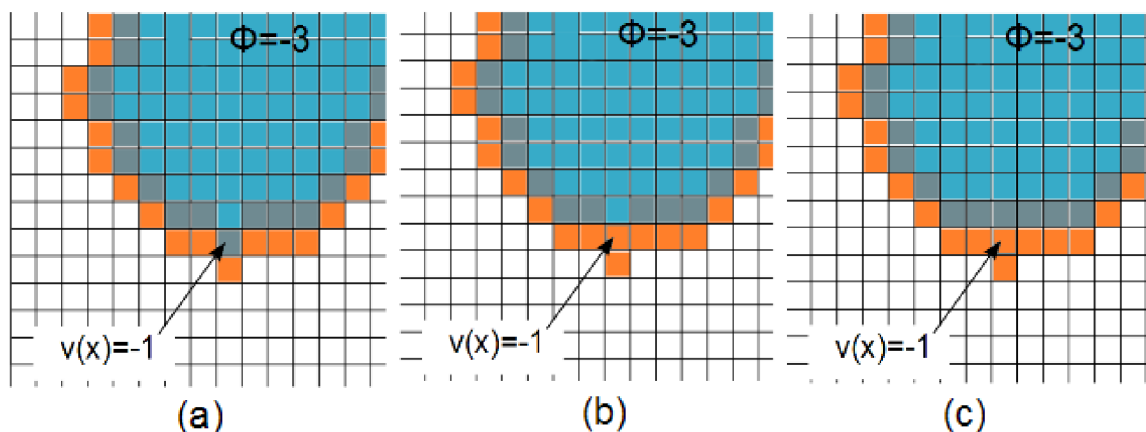
Keď hodnota VF  $v(x)$  v bode  $x$  patriacom do zoznamu  $L_{out}$  je kladná, potom sa povrch v tomto bode bude rozťahovať. Tento posun hranice povrchu sa uskutoční výmenou bodu medzi zoznamami. Bod  $x$  tak vymažeme zo zoznamu  $L_{out}$  a pridáme ho do zoznamu  $L_{in}$  a nastavíme hodnotu funkcie  $\Phi(x) = -1$  podľa predpisu (viď rovnica (14)). V takomto prípade je však narušený vonkajší zoznam povrchu  $L_{out}$ , čo spôsobuje jeho nekonzistentnosť. Aby sme to napravili, potrebujeme zaradiť všetky body  $y$  z okolia  $N(x)$  (viď rovnica (13)) bodu  $x$ , ktorých hodnota  $\Phi$  je rovná 3, do zoznamu  $L_{out}$  a nastaviť  $\Phi(y) = 1$ . To znamená, že všetky body, ktoré doteraz nepatrili do reprezentácie hranice a boli susedné s pridaným bodom, budú odteraz súčasťou hranice. Túto situáciu demonštruje obrázok 20, kde oranžová farba reprezentuje zoznam  $L_{out}$  a sivá farba zoznam  $L_{in}$ . Na obrázok 20 (c) je možné badať zbytočné body vo vnútornom obale, ktoré ale budú odstránené až vo fáze zmazania zbytočných bodov povrchu (viď obrázok 22 (a)).



Obrázok 20: Rozťahovanie povrchu v 2D. V označenom bode sa povrch rozťahne. (a) Pred rozťahnutím, (b) Rozťahnutie, (c) Zcelistvenie povrchu.

### Zmršťovanie povrchu

Zmršťovanie povrchu funguje na podobnom princípe ako rozťahovanie. Pre každý bod  $x \in L_{in}$ , kde  $v(x)$  je záporné, preradíme tento bod z  $L_{in}$  do  $L_{out}$  a nastavíme  $\Phi(x) = 1$ . Tu sa taktiež hranica povrchu



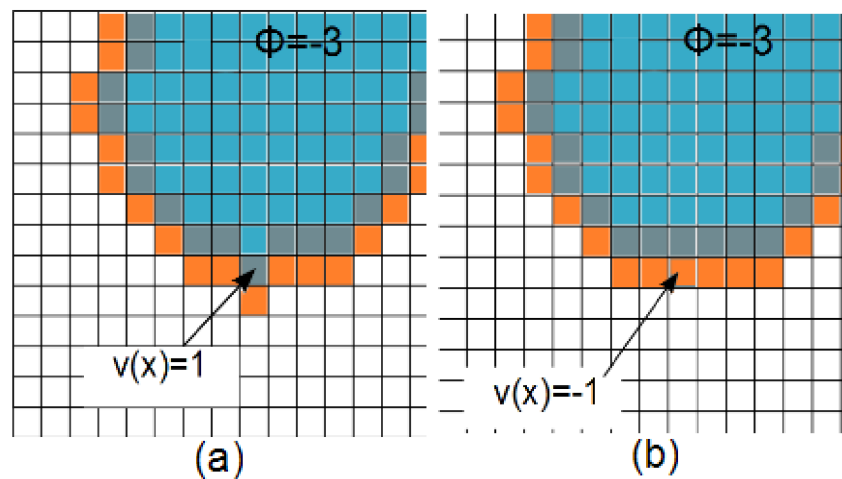
Obrázok 21: Zmršťovanie povrchu v 2D. V označenom bode sa povrch zmrští. (a) Pred zmrštením, (b) Zmrštenie, (c) Zcelistvenie povrchu.

stáva nekonzistentná a musíme uskutočniť tzv. záplatu. Preto treba podobne ako v predchádzajúcom prípade, aby sme zaradili všetky body  $y$  z okolia  $N(x)$  (viď rovnica (13)) bodu  $x$ , ktorých hodnota  $\Phi$  je rovná  $-3$ , do zoznamu  $L_{out}$  a nastaviť  $\Phi(y) = -1$ . Túto situáciu demonštruje obrázok 21, kde oranžová farba reprezentuje zoznam  $L_{out}$  a sivá farba zoznam  $L_{in}$ . Na obrázku 21 (c) je možné badať zbytočné body vo vonkajšom obale, ktoré ale budú odstránené až vo fáze zmazania zbytočných bodov povrchu (viď obrázok 22 (b)).

## Zmazanie zbytočných bodov povrchu

Po vykonaní operácií rozťahovania a zmršťovania povrchu sa často vyskytujú nadbytočné body v zoznamoch  $L_{in}$  a  $L_{out}$ . Sú to body, ktoré v predchádzajúcom kroku tvorili hranicu a v ďalšom kroku sa z nich stanú body vnútorné, avšak naďalej reprezentujú hranicu objektu, čo nie je správne. Aby sa zachovala topológia hranice povrchu, je nevyhnutné takéto body eliminovať nasledovne. Po kroku rozťahovania povrchu je nutné všetky body  $x \in L_{in}$ , ktorých všetky susedné body  $y \in N(x)$  majú hodnotu  $\Phi(y)$  zápornú, nastaviť ako body vnútorné a teda  $\Phi(x) = -3$ .

Podobne po fáze zmršťovania povrchu, vznikajú nadbytočné body hranice mimo samotného objektu. Je nutné všetky body  $x \in L_{out}$ , ktorých všetky susedné body  $y \in N(x)$  majú hodnotu  $\Phi(y)$  kladnú, nastaviť ako body vonkajšieho prostredia povrchu s  $\Phi(x) = 3$ .



Obrázok 22: Ukážka zmazania zbytočných bodov hranice. (a) Výsledok zmazania zbytočných bodov po fáze rozťahovania povrchu, (b) Výsledok zmazania zbytočných bodov po fáze zmršťovania povrchu.

Popísané kroky šírenia sa povrchu sú hlavnou súčasťou algoritmu metódy FLSM. V každom jednom kroku evolučného procesu sa každý bod hraničnej reprezentácie posunie o maximálne jeden obrazový bod.

### 5.1.3 Velocity field

Po popise hlavných princípov modelu ostáva ešte popis pohybu a podmienok zmeny tvaru daného povrchu, čo je kľúčový prvok metódy. Jedná sa o už spomínanú energiu, ktorá pôsobí na daný objekt [25, 28, 33, 34, 35]. Celková energia pôsobiaca na popísaný deformovateľný povrch je v princípe určená vonkajšou a vnútornou silou (viď rovnica (15)). Vonkajšia (externá) sila pôsobí na povrch a tým ho deformuje. Väčšinou je táto sila odvodená od média, na ktorom sa povrch vyvíja. V oblasti

spracovania obrazu môže byť toto médium samotná obrazová informácia, z ktorej je táto externá sila vypočítaná.

Ďalej sú na povrch kladené požiadavky vyžadujúce hladkosť a súvislosť povrchu. Práve vďaka sile vnútornej, je toto kritérium splnené. Vnútna sila nie je vlastnosťou prostredia, ale naopak, je vlastnosťou daného povrchu a určuje mieru jeho elastickej. Túto vlastnosť využívame na to, že veľa krát chceme rekonštruovať povrch nejakých reálnych objektov, ktoré majú často súvislý a do istej miery hladký povrch. Môžeme teda rekonštruovať aj tvary, ktoré sú v skutočnosti hladké, ale zdrojové dáta sú zaťažené obrazovými artefaktami. Zjednodušená reprezentácia celkovej energie  $E$  pôsobiacej na povrch je znázornená na rovnici (15), kde  $F_{int}$  je vnútorná a  $F_{ext}$  je vonkajšia sila pôsobiaca na povrch.

$$E = F_{int} + F_{ext}. \quad (15)$$

V oblasti rekonštrukcie objektov z obrazu pomocou klasickej metódy LSM [15,16,17,19] sa používa na výpočet externej sily v danom bode informácia z konkrétnych obrazových dát, ktoré zároveň stanovujú veľkosť tejto sily (viz rovnica (16)). Smer vektoru takto získanej sily je potom totožný so smerom normály v danom bode povrchu.

V metóde FLSM [25,26,35] však na veľkosti ani na smere tejto sily nezáleží. Tu má externá sila (VF), formu binárnej masky. Nadobúda teda v bode  $x$  hodnoty +1 alebo -1. Kladná hodnota  $v(x)$  znamená, že daný bod  $x$  sa nachádza v oblasti záujmu, a teda že sa má povrch v danom bode rozťahovať. Záporná hodnota  $v(x)$  naopak znamená, že bod  $x$  je na pozadí oblasti záujmu, a teda sa v tomto bode bude povrch zmršťovať. To je základný stavebný kameň vývoja povrchu reprezentujúceho objekt.

$$P(x, y, z) = -|\nabla G_{\sigma} * I(x, y, z)|. \quad (16)$$

V dobe písania tejto práce existujú minimálne dva prístupy ako pracovať s VF. Jedným z nich je prístup, kde sa toto pole externej sily ráta iteratívne v každom kroku procesu, pre všetky body hranice povrchu [25,35]. Je to spôsob ktorý bol pôvodne navrhnutý v [25] pre metódu FLSM.

Druhým prístupom je spôsob, kde sa VF vypočíta iba raz a potom sa s ním pracuje [26]. Takýto spôsob je preferovaný aj v tomto návrhu vďaka jeho vlastnostiam.

Ak vychádzame z charakteru VF, zistíme, že môže byť reprezentované akoukoľvek binárnou maskou. To znamená, že podkladom pre VF môže byť výstup ľubovolnej segmentácie daného modelu nejakou technikou, ktorej výstup je binárna maska segmentovaného objektu. Samozrejme tu nastáva otázka, prečo by sme chceli používať ako základ na segmentáciu deformovateľným povrchom inú techniku nižšej úrovne, keď už táto technika dodá požadovaný výsledok? Odpoveď však tkvie v charaktere DP. Jedná sa o elastický spojitý objekt odolný voči šumu, ktorý môže

rekonštruovať objekt záujmu z predsegmentovaných dát tým, že použije predchádzajúcu segmentáciu ako svoje externé silové pole. Rekonštrukcia objektov pomocou DP tak už má k dispozícii istú informáciu o objekte a snaží sa ho modelovať elastickým modelom, čo sa nedá tak jednoducho docieľiť nízkoúrovňovými technikami. Dá sa tak využiť topológia DP na segmentáciu lokálnych objektov záujmu.

Podľa [35,36] sa dá pre metódu LS generovať VF pomocou metód založených na štatistike a pravdepodobnosti, vytváraním pravdepodobnostných modelov. Keďže VF má formu binárnej masky, záleží jeho vyhodnotenie, respektíve modelovanie obrazu pravdepodobnostnými modelmi na počiatkovej inicializácii povrchu. S ohľadom na tieto skutočnosti boli navrhnuté tieto varianty VF založené na pravdepodobnostných modeloch:

- modified Chan-Vese segmentation criterion [26,34],
- mean and variance separation [35].

### Modified Chan-Vese segmentation criterion

Segmentácia podľa Chan-Vese kritéria [26] vedie na rozdelenie obrazu do dvoch regiónov (popredie a pozadie) minimalizovaním energie. Nech  $f(x)$  vyjadruje intenzitu obrazu v bode  $x$ . Ďalej priemerná intenzita popredia  $\Omega$  a pozadia  $\Omega_b$  je  $c_1$  a  $c_2$ . Potom je energia  $E$  definovaná nasledovne:

$$E(c_1, c_2, \Gamma) = \lambda_1 \int_{\Omega} (f(x) - c_1)^2 dx + \int_{\Omega_b} (f(x) - c_2)^2 dx + \mu \int_{\Gamma} dx + \nu \int_{\Omega} dx, \quad (17)$$

kde  $\int_{\Gamma} dx$  je dĺžka hranice  $\Gamma$ ,  $\int_{\Omega} dx$  je plocha objektu a  $\lambda_1, \lambda_2, \mu, \nu$  sú nenulové váhy. Keď vychádzame z toho, že internú energiu riešime samostatným krokom smoothing step, tak volíme  $\mu = \nu = 0$ . Ďalej úpravou rovnice (17) podľa [26], dostávame popis VF podľa požiadaviek, teda zaujíma nás iba znamienko výslednej sily. Výsledný popis má tvar:

$$v(x) = \begin{cases} 1 & \text{ak } -\lambda_1 (f(x) - c_1)^2 + \lambda_2 (f(x) - c_2)^2 \geq 0 \\ -1 & \text{ak } -\lambda_1 (f(x) - c_1)^2 + \lambda_2 (f(x) - c_2)^2 \leq 0 \end{cases} \quad (18)$$

### Mean and variance separation

Oddelením popredia od pozadia len na základe priemerných hodnôt intenzít predpokladáme zhodný rozptyl pre oba segmenty, čo často vedie na nesprávnu segmentáciu. Včlenením logaritmu pravdepodobnosti normálneho rozloženia  $N(\mu, \sigma)$  priamo do energie umožňuje separáciu priemeru a odchýlky [35] nasledovne:



$$E = \log N(\mu, \sigma) H(-\phi(x)) + \log N(v, \sigma_v) H(\phi(x)) dx, \quad (19)$$

kde korešpondujúci gradient je:

$$\nabla E(x) = \left( \frac{I(x) - v}{\sigma_v} \right)^2 - \left( \frac{I(x) - u}{\sigma_u} \right)^2 + \log \left( \frac{\sigma_v}{\sigma_u} \right)^2, \quad (20)$$

kde  $\sigma_u$  je priemerná odchýlka pozadia obrazu a  $\sigma_v$  priemerná odchýlka popredia obrazu.

### 5.1.4 Smoothing step

Fáza smoothing step je zodpovedná za vnútornú silu  $F_{\text{int}}$  povrchu. V FLSM rozdiel od pôvodnej metódy LS [16, 17] je interná sila oddelená od sily vonkajšej. Tu sa teda nejedná o jednotnú silu, ktorá určuje vývoj povrchu. Vnútorná sila je zodpovedná za hladkosť a mieru elasticity modelu. Podľa autorov metódy FLSM [25] je numerické vyjadrenie krivosti povrchu funkcie  $\Phi$  zhodné s procesom vyhladzovania Gaussovým filtrom.

Fáza vyhladzovania tak vystupuje v celkovom procese vývoja povrchu ako samostatná fáza, oddelená od samotného pohybu povrchu. Na rozdiel od pôvodnej metódy, kde v každom kroku je treba rátať divergenciu gradientu [25] pre celý povrch, aby sa zabezpečil správny vývoj povrchu. Metóda FLSM využíva iba filtrovanie funkcie  $\Phi$ , reprezentujúcej povrch, ktoré využíva jednoduché integer operácie. Nepochybne je to jedna z hlavných vlastností metódy, ktoré dramaticky znižujú výpočtové nároky a celkový čas potrebný na výpočet.

Hlavnou výhodou separátneho riešenia je, že fáza vyhladzovania nemusí byť vykonávaná každú iteráciu, pokiaľ je hodnota šumu obrazu menšia. Pre podrobnejší popis je možné dodatočné informácie vyhľadať v príslušnej literatúre [25,26]. Ďalšie detaily vrátane popisu algoritmu sú zhrnuté v kapitole 6.

## 5.2 Riadenie a krokovanie procesu segmentácie

Manuálna, alebo inak povedané interaktívna segmentácia prebieha za pomoci zásahu užívateľa. Základom je myšlienka krokovania segmentácie. Deformovateľný povrch v podobe funkcie LS sa časom vyvíja podľa definície modelu. V každej iterácii výpočtu sa povrch deformuje a prispôbuje a vytvára tak postupne výsledok segmentácie. Tento priebeh je možné sledovať vždy po určitom počte iterácií a popri tom ho riadiť.

Ak zoberieme do úvahy, že nástroj potrebuje k zahájeniu segmentácie popis hraničných bodov počiatočného povrchu a zodpovedajúce VF, ktoré ovláda externú silu pôsobiacu na model, zistíme že týmto stavom môže byť ktorákoľvek iterácia. V podstate je výsledkom každej iterácie popis povrchu

objektu množinou bodov a môžeme tento stav považovať za počiatočný stav ďalšieho kroku. Ak užívateľ zistí v niektorej iterácii, že vypočítané VF nie je príliš vyhovujúce, je možné ho vypočítať znovu z aktuálneho stavu segmentácie a použiť takým spôsobom, že sa bude pokračovať v poslednej iterácii. Za tohto predpokladu je možné vytvoriť niečo ako históriu segmentácie.

## 5.2.1 História priebehu segmentácie

História priebehu segmentácie vznikla ako dôsledok vlastností použitej metódy level-set. Ide o unikátnu vlastnosť segmentačného nástroja. Je možné ukladať výsledok iterácií ľubovoľne často. Celá informácia, ktorú je treba uchovávať je explicitná reprezentácia funkcie  $\Phi$  v podobe množiny bodov. Tak sa dá kedykoľvek nahradiť existujúci povrch povrchom z niektorej predošlej iterácie.

Históriu je možné využiť v prípade, kedy sa segmentácia vyvinula nesprávne v istom kroku a je treba pozmeniť priebeh. Ak sa vrátíme zopár krokov späť, môžeme tak zmenou parametrov a následným pokračovaním v segmentácii dosiahnuť žiadaného výsledku. Táto vlastnosť zvyšuje mieru interaktivity na vyšší level. Dané rozšírenie znižuje aj celkový čas na získanie správneho výsledku. Samotná segmentácia môže trvať aj niekoľko minút a ak by užívateľ zistil až po niekoľkých minútach, že nie je s výsledkom spokojný, musel by proces opakovať znova, pričom len pár posledných krokov mohlo viesť k nesprávnemu výsledku. Preto s pomocou histórie je možné dosiahnuť žiadaného výsledku v kratšom čase.

## 5.2.2 Určenie smeru vývoja povrchu

Podľa teoretického popisu metódy FLSM vieme, že sa deformovateľný povrch môže zmršťovať alebo rozťahovať a to v každom bode ľubovoľne. Ako povrch podlieha externej sile, tak sa deformuje oboma smermi a môže tak vytvárať dutinky, izolované povrchy a ďalšie topologické variácie.

Niekedy je však podľa cieľu segmentácie jasné, že by sa mal povrch iba rozťahovať alebo naopak iba zmršťovať. Taká situácia môže nastať napríklad pri segmentácii povrchu celého mozgu, pričom nás nezaujímajú vnútorné štruktúry. Pokiaľ by sa povrch aj rozťahoval aj zmršťoval, tak by mohol vzniknúť povrch reprezentujúci mozog, ale aj so segmentovanými štruktúrami v jeho vnútri. Mohol by tak vzniknúť model, ktorý by obsahoval dutinky a celkový povrch by vo vnútri nebol konzistentný. Ak by sa povrch v takomto prípade iba rozťahoval, vytvoril by sa konzistentný model neobsahujúci dutiny. Obrovská výhoda tohto prístupu je v niektorých prípadoch až dvojnásobné urýchlenie vývoja povrchu.

Podobne je to s nastavením, kedy sa bude povrch iba zmršťovať. Ak umiestnime do priestoru počiatočný povrch tak, že geometricky obaluje cieľový objekt, je možné tento proces urýchliť až dva krát. Jedná sa teda o ďalšie urýchlenie segmentácie, ktoré pomaly vedie až k real-time segmentácii deformovateľným povrchom.

## 5.3 Segmentačný nástroj

V tejto časti predstavím fungovanie navrhnutého nástroja, popíšem aké sú jeho možnosti, vlastnosti, výhody a nevýhody. Segmentácia je rozdelená do viacerých krokov a hlavne možných scenárov. Prvým krokom procesu je inicializácia a zadanie počiatočných podmienok. Vzápätí nasleduje fáza, v ktorej sa užívateľ rozhodne, či sa chce do procesu zapájať a daný proces ovplyvňovať, alebo po nastavení istých parametrov nechá proces segmentácie prebehnúť takmer automaticky. Potom podľa účelu a žiadaného výsledku zvolí užívateľ konkrétnu variantu. Keďže sa jedná o nástroj, ktorý by mal byť čo najviac interaktívny, je venovaná väčšia pozornosť manuálnej segmentácii, teda takej, kde je vyžadovaný zásah užívateľa.

Zaujímavou vlastnosťou navrhnutého nástroja je možnosť kombinovať poloautomatickú a automatickú segmentáciu pri segmentácii tých istých dát. Je možné začať proces poloautomatickou metódou so zásahom užívateľa a v ktorejkoľvek fáze procesu je možné segmentáciu pozastaviť a na podnet užívateľa pokračovať metódou automatickou, ktorá bude brať ako počiatočný stav výsledok metódy manuálnej. Možnosti riadenia, krokovania a návratu procesu segmentácie je viacero a sú podrobnejšie popísané v kapitole 5.2.

### 5.3.1 Inicializácia

Prvým krokom úspešnej segmentácie je v tomto prípade inicializačný krok. Pozostáva zo zadania počiatočného povrchu v dátach, ktoré zadá užívateľ. V princípe nezáleží na tvare počiatočného povrchu, avšak povrch musí byť uzavretý. Zadávanie tohto povrchu bude riešené explicitným zadávaním súradníc priestorového objektu. Konkrétne je navrhnutý počiatočný objekt tvaru kvádra. Čo sa týka zadaných parametrov, musí užívateľ zadať rozmery a umiestnenie kvádra v priestore volumetrických dát. V rámci zvýšenia interaktivity je navrhnutá nadstavba navrhnutého nástroja, ktorá interaktívne rieši zadávanie počiatočných podmienok. Podrobnejší popis a ďalšie vlastnosti nadstavby sa nachádzajú v kapitole 5.4.

Ešte pred krokom spustenia evolúcie je treba vygenerovať VF na základe vstupných dát a použitej metódy rátania typu VF. Vytvorené VF má formu objemových dát rovnakých rozmerov ako zdrojové dáta. Je preto možné zobrazovať aj tento objem rovnakým unifikovaným spôsobom ako zdrojové dáta.

### **5.3.2 Manuálna segmentácia**

Manuálna segmentácia vyžaduje počas procesu vstupy od užívateľa, ktorý takto usmerňuje a riadi segmentáciu. Na začiatku je potrebné vykonať inicializáciu. Tá pozostáva z nasledujúcich krokov:

- inicializovanie počiatočného povrchu,
- vypočítanie VF na základe potrebných parametrov pre daný spôsob rátania VF,
- povolenie/nepovolenie vyhladzovania, nastavenie miery vyhladzovania a parametrov vyhladzovacieho jadra,
- určenie počtu iterácií.

Ďalej je možné nastaviť použitie histórie, určiť smery deformácie a zobrazenie želaného výstupu. Po nastavení týchto parametrov je možné pristúpiť k spusteniu segmentácie a celý proces ovládať, krokovať a uskutočňovať návraty v iteráciách.

### **5.3.3 Automatická segmentácia**

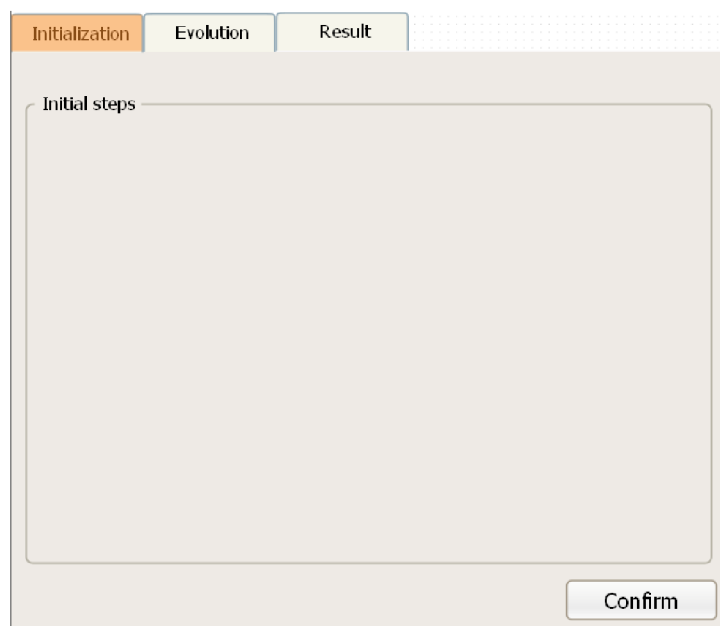
Automatická segmentácia vyžaduje menšiu interaktivitu od užívateľa, ale predsa len je treba istý zásah. Tento zásah spočíva vo vykonaní a nastavení inicializačných krokov ako sú popísané v manuálnej segmentácii. Tu sa však proces segmentácie nedá krokovať, ani používať história. Podľa nastavených parametrov sa model vyvíja a proces končí, keď sa dosiahne konečného kritéria [25]. Spomenutý variant však neponúka žiaden náhľad a nie je možné dopredu odhadnúť celkový čas výpočtu.

### **5.3.4 Zobrazenie výsledku**

Zobrazenie výsledku je možné na konci segmentácie. Zobrazíť je však možné viacero výsledkov, a to výslednú funkciu, ktorá reprezentuje segmentovaný objem, objem reprezentujúci VF, alebo originálne dáta, v ktorých je farebne zvýraznený výsledok segmentácie. Malo by byť možné s výslednými dátami pracovať v 3D priestore.

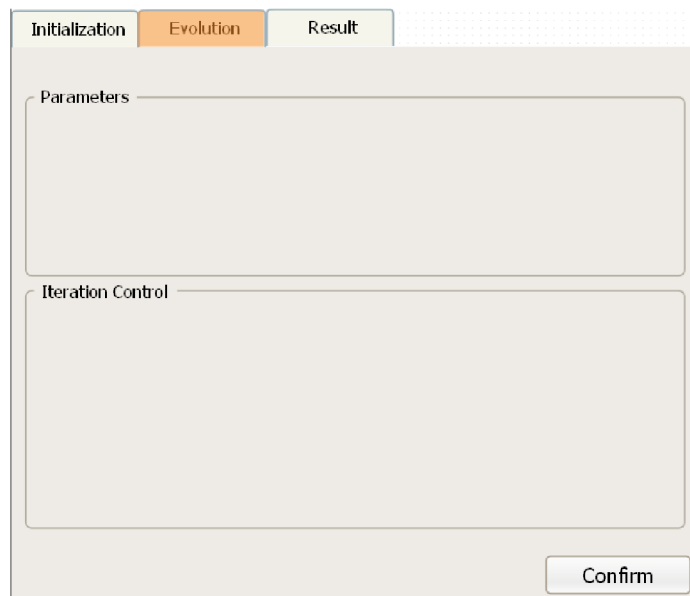
## **5.4 Návrh nadstavby nástroja**

Nadstavba navrhnutého nástroja by mala zvýšiť interaktivitu práce s ním. Mala by hlavne obsahovať grafické užívateľské rozhranie určené na ovládanie procesu segmentácie. Ďalej by mala obsahovať zobrazovanie dát a prvky na interakciu a manipuláciu so zdrojovými dátami. V rámci navrhnutého jadra nástroja je mnoho interaktívnych prvkov, ktoré sa nedajú dostatočne ovládať bez grafického rozhrania. To je hlavná motivácia na realizovanie nadstavby.



Obrázok 23: Náčrt GUI: Časť inicializácia.

Z užívateľského hľadiska je potrebné grafické užívateľské rozhranie. Keďže cieľom tejto práce je implementovanie metódy FLSM určenej na segmentáciu obrazových dát, je vhodné ponúknuť užívateľovi v čo najväčšej miere možnosť interaktívnej práce. Bez GUI pravdepodobne nebude plne využitý potenciál implementovanej techniky.



Obrázok 24: Náčrt GUI: Časť Evolúcia povrchu.

V kapitole 5.1 je popísaná hrubá schéma procesu segmentácie. Skladá sa z viacerých fáz ako inicializácia, evolúcia a zobrazenie výsledku. Bolo by vhodné navrhnuť rozhranie pre užívateľa

takým spôsobom aby odpovedalo prechodom medzi fázami, aby teda GUI reprezentovalo stav, v ktorom sa práve nachádza proces segmentácie.



Obrázok 25: Náčrt GUI: Časť zobrazovania výsledkov.

Rozhranie bude obsahovať všetky nutné ovládacie prvky potrebné na úplné nastavenie procesu segmentácie a takisto prvky, ktoré budú uľahčovať celkovú prácu. Vyčerpávajúci zoznam parametrov a nutných prvkov je uvedený v kapitole 5.1. Vzhľadom na nemalý počet ovládacích prvkov a množstva užívateľských vstupov, bude treba vhodne priestorovo a logicky rozmiestniť tieto prvky. Je teda snaha navrhnuť GUI čo najprehľadnejšie. Bude sa skladať z troch hlavných logických celkov, ktoré budú ďalej členené podľa potreby. Týmito celkami sú:

- inicializácia (obrázok 23),
- evolúcia modelu (obrázok 24),
- zobrazenie výsledkov (obrázok 25).

Každý z týchto troch celkov by mal mať oddelené GUI kvôli prehľadnosti. Hrubý návrh týchto častí je uvedený na príslušných ilustráciách.

### 5.4.1 Interaktívne zobrazovanie povrchu

Ďalší prvok, ktorý zvyšuje mieru interaktivity, je prvok zobrazovania povrchu vyvíjajúceho sa modelu počas procesu segmentácie. Vzhľadom na relatívne malú časovú náročnosť výpočtu segmentácie, by bolo žiadúce vždy po niekoľkých krokoch zobrazovať 3D model výsledného povrchu. Na tento účel je vhodné použiť techniku *Marching Cubes* určenú na vytvorenie

polygonálnej reprezentácie povrchu objemových dát. V takom prípade by nebola vyžadovaná úplná presnosť a detailnosť výsledného povrchu, pretože výsledný povrch by plnil len orientačný a hrubý účel.

## 6 Implementácia

Implementácia navrhutej diplomovej práce je realizovaná v prostredí Microsoft Visual Studio 2008 v jazyku C++ na operačnom systéme Microsoft Windows XP. Navrhnutý nástroj je implementovaný ako modul do open-source segmentačného nástroja MDSTk<sup>7</sup> a segmentuje volumetrické medicínske dáta metódou FLSM. V čo najväčšej miere využíva štruktúry a funkcie už implementované v danom nástroji. Ďalej využíva funkcie na manipuláciu s objemovými dátami, ktoré sú potrebné na základnú prácu s dátami a výsledkom segmentácie a zobrazovanie volumetrických dát. Manipuláciou sa rozumie nakladanie s dátami ako s trojrozmerným objektom umiestneným v priestore, s ktorým sa dajú prevádzať základné operácie ako zmena merítka, posun, rotácia a interaktívne prezeranie jednotlivých rezov v dátach. MDSTk umožňuje kombinovanie jeho modulov reťazením v príkazovom riadku. Jedná sa teda o konzolové riadenie práce s dátami. Užívateľské vstupy sú zo spomenutých dôvodov prijímané z príkazového riadku a týmto spôsobom je implementovaný aj môj nástroj. Mal by teda byť schopný prijať dáta z reťazca predošlých modulov, dané dáta spracovať a následne ich zaslať na zobrazenie. Z hľadiska modulárnej výstavby toolkitu MDSTk je táto fáza dosiahnuteľná a zrealizovateľná. Môj nástroj musí byť teda logicky rozdelený do dvoch hlavných častí:

- modul v MDSTk,
- jadro metódy fast level-set.

V návrhu bola zahrnutá aj nadstavba, ktorá by mala práve zvýšiť interaktivitu segmentácie. Nadstavba bola implementovaná ako plugin do freeware aplikácie 3DimViewer od spoločnosti 3Dim Laboratory s.r.o (<http://www.3dim-laboratory.cz>). Aplikácia 3DimViewer je prehliadač obrazových medicínskych dát. Na rozdiel od nástroja MDSTk, poskytuje aj grafické rozhranie. Využíva pritom knižnice z nástroja MDSTk. Nadstavba môjho nástroja na segmentáciu je teda implementovaná ako plugin do aplikácie 3DimViewer so svojim vlastným grafickým užívateľským rozhraním. Jadro tejto aplikácie mi bolo poskytnuté za účelom vypracovania nadstavby diplomovej práce od spoločnosti 3Dim Laboratory, s.r.o.

### 6.1 Reprezentácia základných prvkov

Medzi základné kľúčové prvky nástroja patria hlavne objemové dáta a reprezentácia samotnej vzdialenostnej funkcie  $\Phi$ , ktorá určuje deformovateľný model.

Na segmentáciu sú v prvom rade potrebné zdrojové volumetrické dáta, ktoré sú v konkrétnej forme 3D maticou voxelov. Ako bolo spomenuté, tieto dáta a ich reprezentácia sú súčasťou toolkitu

<sup>7</sup> <http://mdstk.sourceforge.net/home.html>



MDSTk. Dôležité však je, že na segmentáciu metódou FLSM je potrebné nejakým spôsobom reprezentovať ďalšie štruktúry, ktoré sú odvodené zo zdrojových dát a majú rovnakú dimenziu. Ako najvhodnejšie a najefektívnejšie riešenie bol zvolený prístup reprezentovania týchto prvkov rovnakým typom ako zdrojové dáta (viď obrázok 29), ktorý je zobrazený pomocou crossplanes v MDSTk toolkit). Jedná sa konkrétne o reprezentáciu vzdialenostnej funkcie  $\Phi$  a externého silového poľa  $F$ . Obe tieto štruktúry majú teda zhodnú typovú reprezentáciu a zhodné priestorové riešenie ako zdrojové dáta. Pre jednotnú manipuláciu a zobrazovanie týchto štruktúr sa tento spôsob ukázal ako najefektívnejší.

Ďalej pre samotnú reprezentáciu povrchu je potrebné uchovávať jeho hraničné body. Na tento účel je použitý kontajner `std::list<coordinate>`, ktorý vyhovuje požiadavkám kladeným na túto štruktúru. Jedná sa o operácie ako vkladanie, mazanie a presúvanie položiek. Z hľadiska najjednoduchšej réžie pri zachovaní funkčnosti bola zvolená práve táto štruktúra.

Operácie a funkcie, ktoré sa podieľajú na segmentácii využívajúc tieto základné štruktúry, sú popísané v ďalších podkapitolách tejto kapitoly.

## 6.2 Segmentačný nástroj

Segmentačný nástroj (SN) obsahujúci implementáciu metódy FLSM reprezentuje jadro diplomovej práce. Ako bolo spomenuté, bol navrhnutý ako modul do existujúceho MDSTk. Pre tento účel je implementovaný v dvoch základných programových moduloch na najvyššej abstraktnej úrovni. Prvým programovým modulom je trieda `mdsLevelSet`, ktorá implementuje rozhranie použité ako modul prijímaný toolkitom MDSTk. Má zadaný formát a slúži ako rozširovanie MDSTk a zároveň ako ovládací prvok implementovanej metódy. Ďalším hlavným programovým modulom je práve trieda `LevelSet3DCore`, ktorá reprezentuje jadro samotnej segmentácie a jej príslušný model.

### 6.2.1 Modul do MDSTk

Je objektom typu `mds::mod::CModule` zdedený z typu pre modul reprezentovaný v MDSTk. Slúži ako rozhranie a prostredník medzi MDSTk toolkitom a mojím SN. Ďalej plní funkciu získavania vstupov od užívateľa, ktoré sú potrebné na segmentáciu. Tie následne sprostredkuje modulu jadra aplikácie, ktorá ich využíva.

Keďže moduly v MDSTk sa prevádzujú na úrovni príkazového riadku, vstupy sú tiež zadávané cez príkazový riadok práve prostredníctvom tohoto vstupného modulu. Po spustení spracuje parametre a riadi proces segmentácie volaním príslušných metód jadra metódy FLSM. Tento postup

je znázornený na algoritme 1. Konkrétne parametre vstupu sú uvedené v nápovede vyvolanej v príkazovom riadku prepínačom -h, alebo v Príloha B: Obsah CD.

- Krok 1:** Inicializovanie  $\Phi, F$  a listov  $L_{in}$  a  $L_{out}$ ;
- Krok 2:** Vytvorenie Gaussovej masky  $G$ ;
- Krok 3:** Zadanie počiatkovej hodnoty funkcie  $\Phi$ ;
- Krok 4:** Vypočítanie velocity field  $v$ ;
- Krok 5:** Voľba automatickej/manuálnej segmentácie;

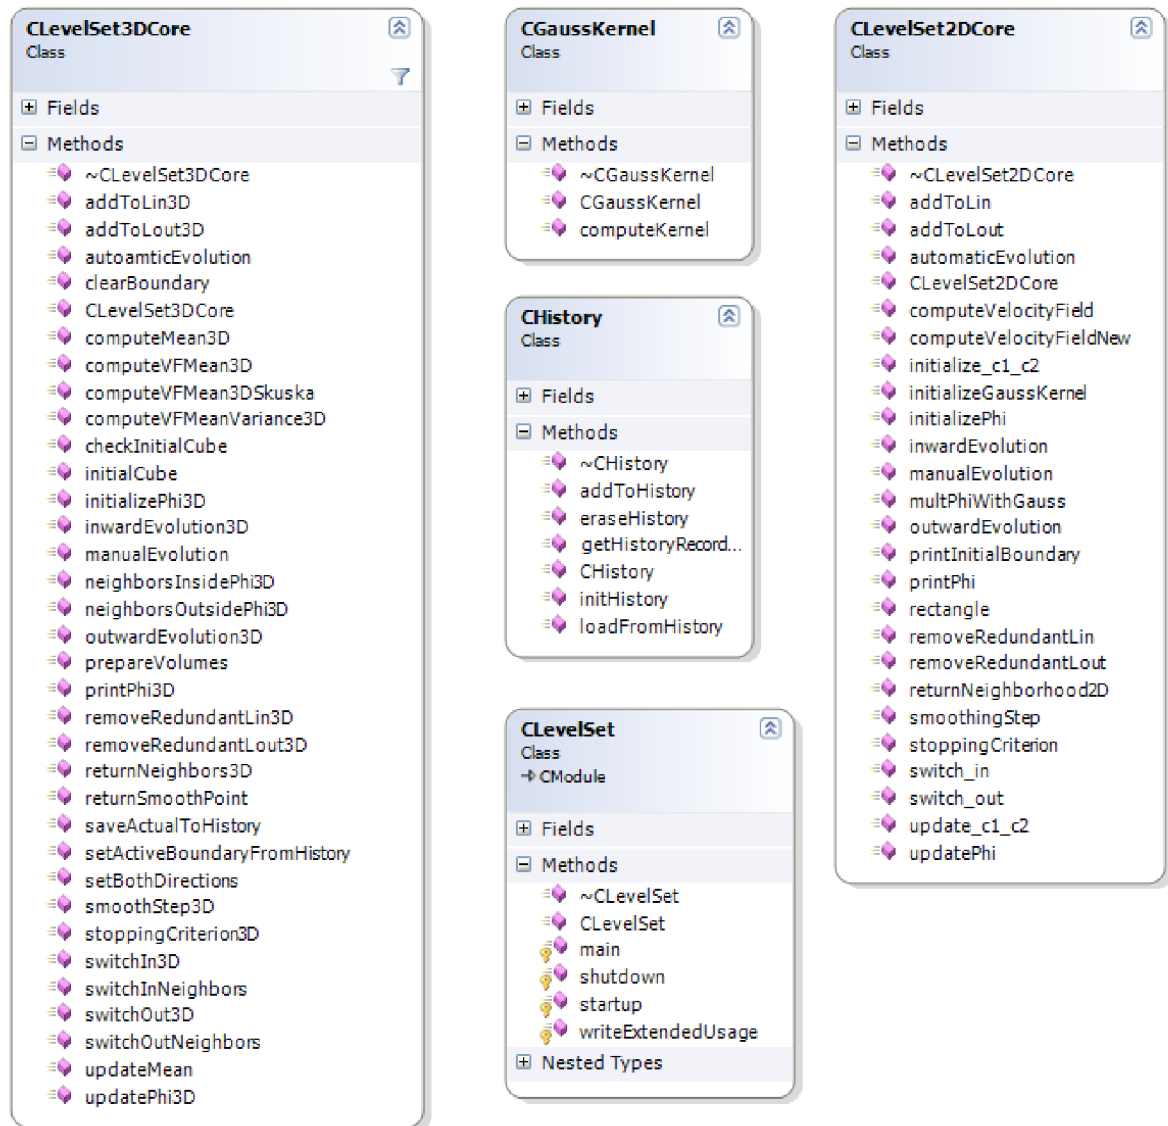
*Algoritmus 1: Postup segmentácie metódou level-set*

## 6.2.2 Jadro segmentácie

Jadro segmentácie je súhrnný názov pre viacero modulov, ktoré boli implementované. Súčasťou sú triedy **CLevelSet3DCore**, **CLevelSet2DCore**, **CHistory** a **CGaussKernel**. Názorný a podrobný prehľad týchto tried a ich metód je znázornený na obrázku 26 (uvedené metódy sú len základné, ktoré sa priamo týkajú evolúcie povrchu). Jadro segmentácie implementuje navrhnutý nástroj využívajúci metódu FLSM v triede *CLevelSet3DCore* a využíva konkrétne triedu *CHistory* na správu histórie a triedu *CGaussKernel* na vyhladzovanie povrchu. Algoritmus samotného priebehu je znázornený na algoritme 1.

- Krok 1: while** nie je dosiahnuté kritérium konca **do:**
  - Outward evolution;
  - Remove redundant points in  $L_{in}$ ;
  - Inward evolution;
  - Remove redundant points in  $L_{out}$ ;
- Krok 2: If** ( Je požadované vyhladzovanie )
  - Vyhladzovací krok;
- Krok 3:** Výsledná funkcia  $\Phi$ ;

*Algoritmus 2: Automatická segmentácia*



Obrázok 26: Diagram tried nástroja.

Podľa návrhu disponuje nástroj možnosťou manuálnej aj automatickej segmentácie. Z týchto postupov si je možné pri segmentácii vybrať, ktorý sa použije. Postup pri automatickej segmentácii je znázornený na algoritme 2 a postup manuálnej segmentácie na algoritme 3. V oboch prípadoch sú potrebné kroky, ktoré vlastne reprezentujú matematické operácie práce s vyvíjajúcim sa modelom popisujúcim segmentáciu. V nasledujúcich odsekoch budú stručne popísané tie najzákladnejšie metódy, ktoré tento vývoj riadia. Pre teoretický podklad viď kapitola 5.1. Pre podrobnejší popis viď [25,26].

**Krok 1: For**  $i=1$  to počet iterácií **do:**

- Outward evolution;
- Remove redundant points in  $L_{in}$ ;
- Inward evolution;
- Remove redundant points in  $L_{out}$ ;

**Krok 2: If** ( Je požadované vyhladzovanie )

- Vyhladzovací krok;

**Krok 3: If** ( Je požadovaný zápis do histórie )

- Zápis do histórie;

**Krok 4:** Výsledná funkcia  $\Phi$ ;

*Algoritmus 3: Manuálna segmentácia.*

## 6.3 Kľúčové metódy vývoja povrchu

V tejto sekcii sú popísané kľúčové operácie vývoja povrchu, ktoré sú pre danú metódu špecifické a nenahraditeľné. Popis týchto operácií slúži na lepšie zorientovanie sa v danej problematike.

### 6.3.1 Outward Evolution

Ako bolo v návrhu spomenuté, jedná sa o operáciu, pri ktorej dochádza k rozťahovaniu povrchu. Situáciu ilustruje obrázok 20. Z obrázku je zrejmé, že dochádza mimo iné k zámene bodov medzi hraničnými listami  $L_{in}$  a  $L_{out}$ . Pre uskutočnenie fázy rozťahovania treba prejsť všetky body zoznamu  $L_{out}$ , ktorý reprezentuje vonkajšiu hranicu a každý bod  $x$  vyšetriť, či sa bude hýbať. Kritériom je práve hodnota externého silového poľa. Ak je  $F(x) = 1$ , znamená to, že bod  $x$  sa musí odstrániť zo zoznamu vonkajšej hranice a pridať medzi body tvoriace vnútornú hranicu. Danú operáciu vykonáva metóda *SwitchIn(x)*.

#### SwitchIn(x)

Jedná sa o implementáciu výmeny bodov medzi zoznamami.

- Krok 1: Zmaž bod  $x$  z  $L_{out}$  a pridaj ho do  $L_{in}$ . Nastav  $\Phi(x) = -1$ .
- Krok 2:  $\forall y \in N(x)$  spĺňajúce  $\Phi(y) = 3$ , pridaj  $y$  do  $L_{out}$  a nastav  $\Phi(y) = 1$ .

## 6.3.2 Inward Evolution

Podobne ako operácia *outward evolution*, realizuje pohyb hranice. Tu sa však pohybuje povrch dovnútra, teda sa zmršťuje. Situáciu ilustruje obrázok 21. Vykonáva sa tak, že sa prejdú všetky body zo zoznamu  $L_{in}$  a je nutné zistiť, ktoré z nich majú tendenciu sa hýbať do vnútra na základe podmienky  $F(x) = -1$ . Musíme teda vymeniť hraničný bod  $x$  vnútornej hranice a vonkajšej použitím operácie *SwitchOut(x)*.

### SwitchOut(x)

Podobne ako *SwitchIn(x)*, vymieňa body medzi zoznamami, ale v opačnom poradí.

- Krok 1: Zmaž bod  $x$  z  $L_{in}$  a pridaj ho do  $L_{out}$ . Nastav  $\Phi(x) = 1$ .
- Krok 2:  $\forall y \in N(x)$  spĺňajúce  $\Phi(y) = -3$ , pridaj  $y$  do  $L_{in}$  a nastav  $\Phi(y) = -1$ .

## 6.3.3 Zmazanie zbytočných bodov

Zmazanie zbytočných bodov je operácia, pri ktorej sa z oboch zoznamov hraničných bodov vymažú body, ktoré sú v hranici nadbytočné a sú výsledkom pohybu povrchu. Ako sa povrch pohybuje, vymieňajú sa body medzi zoznamami a pridávajú sa nové. Ale po každej iterácii ostávajú v reprezentácii hranice aj body, ktoré odrážajú minulý stav hranice a musia byť preto odstránené. Situáciu ilustruje obrázok 22. Podľa toho či odstraňujeme zbytočné body po fáze rozťahovania alebo zmršťovania, používam operácie *Remove redundant points in  $L_{in}$*  a *Remove redundant points in  $L_{out}$* .

### RemoveRedundantPointsFromLin()

Zmazanie zbytočných bodov z vnútornej hranice.

$\forall x \in L_{in}$ , ak  $\forall y \in N(x)$ ,  $\Phi(y) < 0$ , vymaž  $x$  z  $L_{in}$  a nastav  $\Phi(x) = -3$ ,

kde  $N(x)$  je okolie bodu  $x$ .

### RemoveRedundantPointsFromLout()

Zmazanie zbytočných bodov z vonkajšej hranice.

$\forall x \in L_{out}$ , ak  $\forall y \in N(x)$ ,  $\Phi(y) > 0$ , vymaž  $x$  z  $L_{out}$  nastav  $\Phi(x) = 3$ ,

kde  $N(x)$  je okolie bodu  $x$ .

### 6.3.4 Kritérium konca segmentácie

Kritérium konca segmentácie je využívané v metóde automatickej segmentácie. Táto segmentácia iteruje, pokiaľ nie je splnená podmienka ukončenia. Týka sa vyšetrenia všetkých bodov hranice. Podmienky sú definované nasledovne:

$$F(x) = -1 \text{ for all } x \in L_{\text{out}},$$

$$F(x) = 1 \text{ for all } x \in L_{\text{in}}.$$

$F(x)$  je hodnota velocity field v bode  $x$ . Teda pokiaľ všetky body vonkajšej hranice povrchu majú tendenciu sa pohybovať smerom do vnútra objektu a zároveň všetky body vnútornej hranice majú tendenciu sa pohybovať smerom od objektu, tak nastáva rovnováha a povrch sa ďalej nepohybuje. To je považované za kritérium konca segmentácie.

Podľa [26] však pri segmentácii kde sa vyšetruje kritérium konca, nastáva situácia, kedy dané kritérium nemusí byť nikdy splnené. Totiž, ak sa aplikuje vyhladzovací krok, čo je vlastne reprezentácia elastickej sily modelu, tak dochádza aj v zdanlivo konečnom stave k oscilácii hraničných bodov práve kvôli samotnému vyhladzovaniu. Je preto vhodné zvoliť dodatočné kritérium, ktoré zahŕňa stanovenie množstva hraničných bodov, ktoré môžu oscilovať. Podľa [26] je vhodné zvoliť počet týchto bodov na 0,001% všetkých hraničných bodov. Daný poznatok bol využitý v tejto práci.

### 6.3.5 Velocity field

V rámci práce boli implementované dva varianty externého silového poľa. Prvý variant využíva modifikované segmentačné kritérium Chan-Vese [34] a druhý spôsob pracuje s pravdepodobnostnými modelmi obrazu.

Vzhľadom na skutočnosť, že je navrhovaný segmentačný nástroj uchopený ako istý modul do MDSTk toolkitu, sú spomenuté skutočnosti s ohľadom preferovaného prístupu k VF výhodou. MDSTk toolkit totiž disponuje mnohými segmentačnými technikami, ktorých výstup je vhodný na využitie navrhovanou metódou level-set (pre prehľad segmentačných techník medicínskych dát vhodných na VF vid' [13]). Do úvahy spadajú nasledovné segmentačné techniky, ktoré môžu byť z MDSTk použité ako VF:

- histogram thresholding,
- fuzzy C-means,
- EM based segmentation,
- region Growing.

## 6.4 Výstup nástroja

Výstupom sú opäť volumetrické dáta. Keďže reprezentácia vzdialenostnej funkcie reprezentujúcej povrch segmentačného povrchu a tiež velocity field je zhodná s reprezentáciou vstupných dát, je možná rovnaká manipulácia s nimi. Zobrazuje sa teda buď velocity field, výsledok segmentácie v podobe vzdialenostnej funkcie  $\Phi$  (farebná reprezentácia), alebo zdrojové dáta obohatené o hranicu povrchu reprezentujúceho výsledok segmentácie. S každým výstupom je možné manipulovať ako so zdrojovými dátami. Je teda možná manipulácia s nimi v 3D priestore a je ich tiež možné uložiť vo formáte \*.vml a prezerat' ich neskôr. Ukážka rôznych výstupov tohto nástroja sa nachádza v Príloha A: Ukážky výsledkov.

## 6.5 Implementácia nadstavby segmentačného nástroja

V rámci diplomovej práce mi bola na tento účel poskytnutá aplikácia 3DimViewer od spoločnosti 3Dim Laboratory, s.r.o (<http://www.3dim-laboratory.cz>). Už v návrhu sa s aplikáciou 3DimViewer ráta a nadstavba je realizovaná ako rozšírenie do tejto aplikácie. Jedná sa o programový plugin, ktorý bude mať svoje vlastné grafické užívateľské rozhranie (GUI). Keďže načítanie objemových dát a spôsoby manipulácie s nimi sú obsiahnuté v aplikácii, mojou úlohou bude vytvoriť GUI pre navrhnutý nástroj a integrovať výsledok do už existujúcej aplikácie.

Implementácia bola realizovaná v jazyku C++ v prostredí Microsoft Visual Studio 2008. Nadstavba je realizovaná ako plugin, takže som využil mne poskytnutý projekt a rozšíril ho. Celá aplikácia je cross-platformová a preto využíva na zostavenie projektu zostavovací systém CMake<sup>8</sup>. Pre začlenenie nového pluginu som musel upraviť konfiguráciu a na následné včlenenie pluginu použiť CMake.

Na implementáciu GUI bola využitá cross-platformová knižnica wxWidgets. Na samotné vytváranie GUI bol využitý editor DialogBlocks 4.40 využívajúci wxWidgets<sup>9</sup>.

---

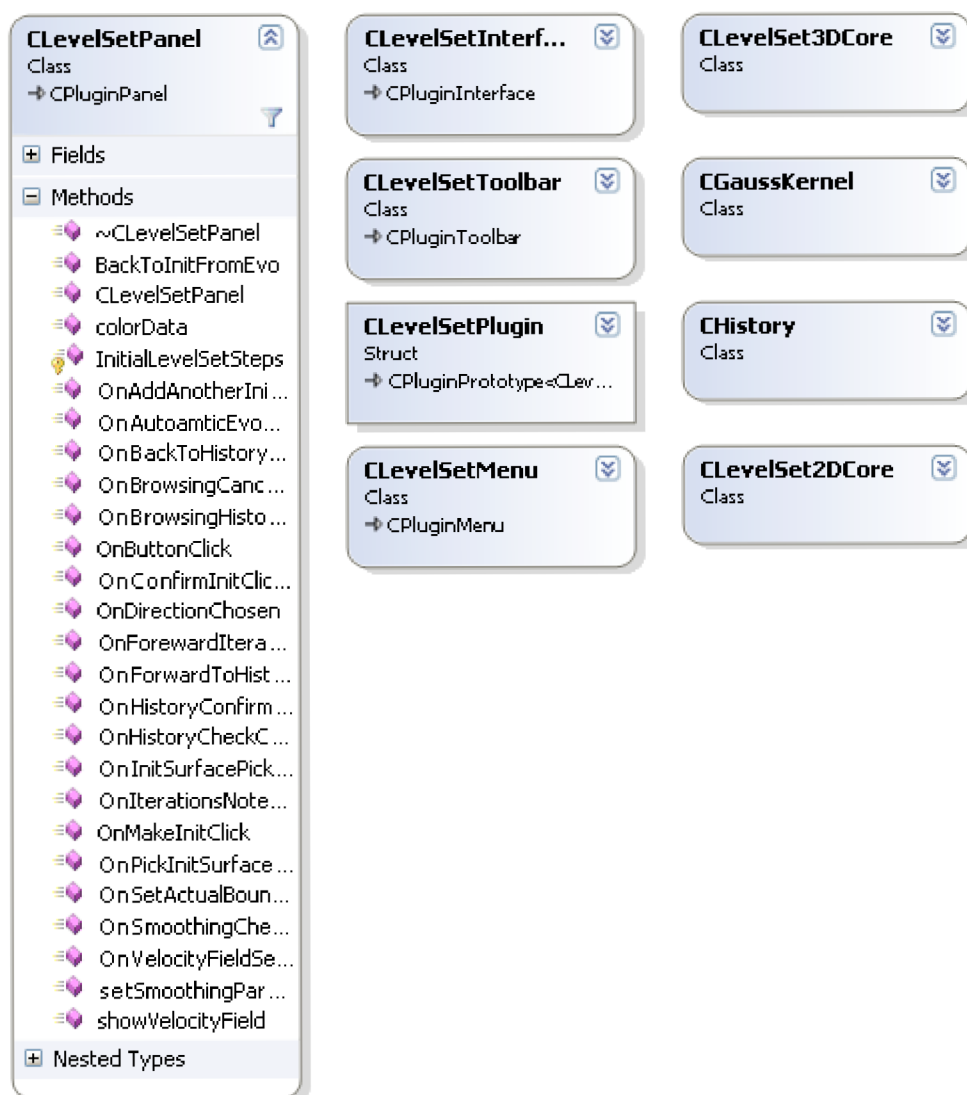
8 <http://www.cmake.org/>

9 <http://www.dialogblocks.com/>

## 6.5.1 Logická stavba

Ako bolo spomenuté, nadstavbou sa rozumie plugin do aplikácie. Je preto nutná znalosť všeobecného rozhrania pluginov. S tým súvisí vytvorenie vlastného pluginu podľa šablóny už existujúcich pluginov a včlenenie tohto pluginu do aplikácie. Ďalej bolo vytvorené GUI, ktoré bolo previazané s rozhraním pluginu. Funkčnosť celej nadstavby zaručuje práve segmentačný nástroj, ktorý je cieľom tejto práce. Bol pre potreby nadstavby len minimálne modifikovaný a začlenený do pluginu. Všetky spomenuté časti sú spojené do jedného funkčného celku.

Takto postavený logický rámec sa odrazil na modulárnej výstavbe pluginu. Na obrázku 27 je znázornený diagram tried pluginu.



Obrázok 27: Diagram tried pluginu.



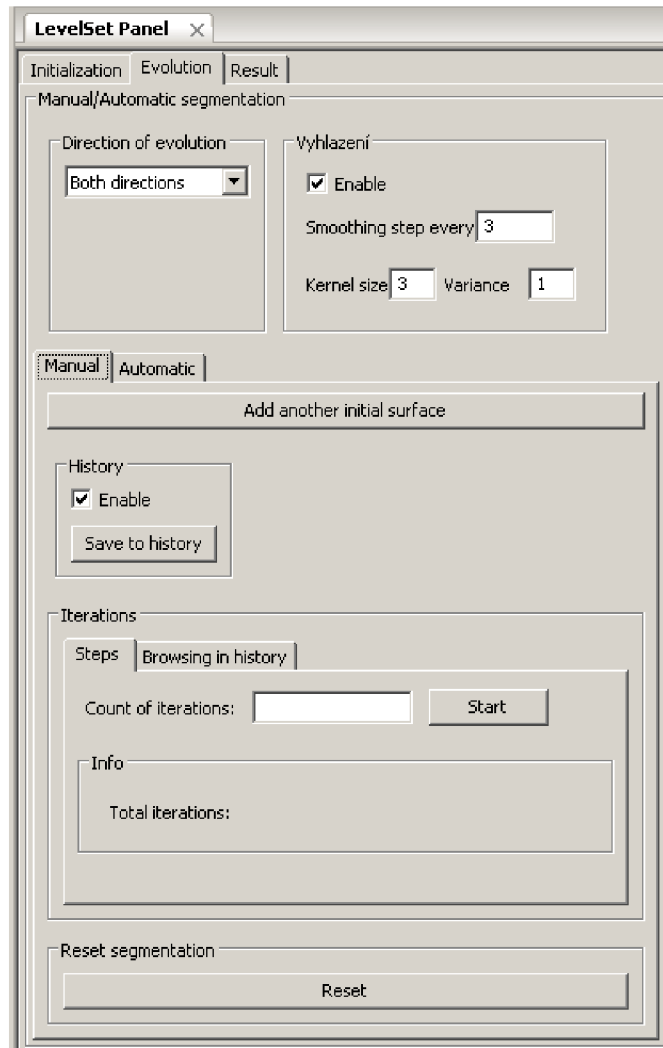
Trieda **CLevelSetPanel** zodpovedá za časť, ktorá implementuje GUI. Implementuje ovládacie prvky určené k práci so segmentačným nástrojom. Metódy tejto triedy sú prevažne callback (riadené udalosťami) funkciami zodpovednými za prepojenie GUI s funkčnou časťou.

Triedy tvoriace prvky rozhrania sú **CLevelSetInterface**, **CLevelSetToolbar**, **CLevelSetPlugin** a **CLevelSetMenu**. Pre implementovanie rozhrania sú nutné a odvodené od vzorových tried pluginov. Funkčná časť pozostáva z tried segmentačného nástroja, ktoré sú do pluginu včlenené. Prehľad týchto tried a ich metód je možné nájsť v kapitole 6.2 Segmentačný nástroj na obrázok 26.

## 6.5.2 GUI

Výsledné grafické užívateľské rozhranie je prístupné v aplikácii 3DimViewer cez položku Level Set plugin vo vlastnom menu. Po jeho zvolení sa zobrazí panel celého pluginu. Pozostáva z prepínacích panelov reprezentujúcich jednotlivé fázy segmentácie popísané na začiatku kapitoly 5.1 Rozbor použitej metódy Fast Level-Set GUI obsahuje pomerne veľa ovládacích prvkov. Ich prítomnosť je však nutná z dôvodu využitia plného potenciálu aplikácie. Medzi jednotlivými panelmi, ktoré reprezentujú fázy výpočtu je možný prechod v rámci povolených operácií nad segmentáciou. Prostredie je implementované na základe návrhu v kapitole 5.4.


Na obrázku 28 je vidno prepínacie prvky znázorňujúce jednotlivé fázy (Initialization, Evolution, Result). Fáza Initialization je zodpovedná za interaktívne zadávanie počiatočných povrchov a ich zobrazovanie. Ďalej je zodpovedná za voľbu typu VF. Fáza Evolution (na obrázku 28) obsahuje prvky určené na proces segmentácie (resp. vývoj deformovateľného povrchu). Obsahuje tiež rozšírenia ako históriu segmentácie, určovanie smeru vývoja povrchu a zadávanie ďalších počiatočných povrchov. Ako bolo spomenuté v návrhu, po dokončení a zobrazení zvoleného počtu iterácií vývoja ostáva aktívna fáza Evolution, kde užívateľ môže zmeniť parametre a pokračovať v evolúcií, alebo môže začať so segmentáciou znova prechodom do fázy Initialization.



Obrázok 28: Ukážka GUI: Fáza evolúcie povrchu.


## 7 Dosiahnuté výsledky

Cieľom tejto práce bola vlastná implementácia metódy FLSM a niekoľkých rozšírení vyplývajúcich z jej vlastností. Metóda FLSM [25] bola navrhnutá v roku 2005. Ide o revolučnú modifikáciu pôvodnej metódy LSM [16]. FLSM však neráta s PDEs, čo má za následok obrovskú časovú úsporu oproti pôvodnej metóde. Dimenzia problému popísaného metódou LSM je teoreticky ľubovlná a je teda vhodná aj na segmentovanie volumetrických dát. V tejto diplomovej práci som využil vynikajúce vlastnosti (viď kapitola 3) klasickej metódy LS [16] a rýchly prístup metódy FLSM na segmentáciu volumetrických medicínskych obrazových dát.



Obrázok 29: Ukážka segmentácie volumetrických dát pomocou implementovaného nástroja. Prostredie modulu v MDSTk.

Zvolená metóda bola v rámci diplomovej práce implementovaná podľa teoretických podkladov [25,26,35]. Ide teda o vlastnú implementáciu, ktorá je rozšírená ešte o niekoľko ďalších vlastností. Medzi rozšírenia patrí história evolúcie modelu, riadenie smeru evolúcie povrchu a rôzne formy generovania externého silového poľa VF (viď kapitola 5.2).



Obrázok 30: Ukážka segmentácie aorty pomocou nadstavby nástroja.

Prostredie 3DimViewer.

História evolúcie je založená na vlastnosti reprezentácie povrchu pomocou metódy FLSM. Je preto možné ukladať stav segmentácie na požiadanie. Keď užívateľ nie je spokojný so súčasným stavom evolúcie, môže sa vracať v uložených záznamoch histórie. Rozšírenie v podobe riadenia smeru evolúcie je vlastnosť založená na oddelených fázach rozťahovania a zmršťovania povrchu. Je tak možné so znalosťou žiadaného výsledku ovplyvniť smer evolúcie modelu, čo môže urýchliť výpočet až dvojnásobne.

Čo sa týka rôznych typov VF, každý typ je inak generovaný a využíva inak vstupné dáta. Majú rôzne vlastnosti a z toho vyplývajúce rôzne účely použitia.

Implementácia vyústila v segmentačný nástroj využívajúci danú metódu v podobe modulu zaradeného do existujúceho toolkitu MDSTk (viď obrázok 29). Tento toolkit slúži primárne na spracovanie obrazu a segmentáciu medicínskych dát. S výsledným nástrojom bolo prevádzané experimentovanie zahrňujúce sledovanie chovania spomenutých rozšírení (viď kapitola 7.1). Súčasťou nástroja je aj implementácia danej metódy v doméne 2D dát. Jednalo sa o medzikrok pri implementovaní 3D variantu. Implementácia 2D variantu je však plne funkčná a použiteľná. Keďže sa táto diplomová práca zaoberá segmentovaním volumetrických dát, je 2D variant len istý doplnok.

Nad rámec diplomovej práce však bola navrhnutá nadstavba, ktorá mala zvýšiť mieru interaktivity pomocou ovládacích prvkov v podobe GUI. Na tento účel mi bola poskytnutá aplikácia 3DimViewer od spoločnosti 3Dim Laboratory s.r.o. Rozšírenie bolo zapracované ako plugin do tejto aplikácie (viď obrázok 30). Disponuje vlastným GUI, ktoré obsahuje množstvo ovládacích prvkov určených na plné využitie potenciálu implementovaného nástroja. Ďalej využíva aplikáciu na manipuláciu s dátami a ich zobrazovanie. Súčasťou návrhu nadstavby bola implementácia interaktívneho zobrazovania povrchu vyvíjajúceho sa modelu v procese segmentácie. Táto časť sa však nepodarila uskutočniť z časového hľadiska. Nie je však vylúčená jej implementácia v budúcnosti.

## 7.1 Experminetovanie

V rámci tejto práce bol implementovaný nástroj na segmentáciu volumetrických medicínskych dát využívajúci techniku FLSM. Počas vývoja daného nástroja boli uskutočňované isté experimenty, ktoré odhalili viacero nových poznatkov a mnohé prepokladané modely chovania potvrdili. Predmetom skúmania bolo viacero oblastí.

Po celú dobu implementácie bola testovaná rýchlosť výpočtu evolúcie modelu. V čase, keď už implementácia bola funkčná, uskutočňoval som testy rýchlosti danej metódy, aby sa potvrdili predpoklady rýchleho výpočtu. Hneď od začiatku bolo zrejmé, že metóda FLSM skutočne dosahuje rýchlejšieho výpočtu ako klasická metóda LSM. Skutočná rýchlosť výpočtu bola odhalená až v momente, kedy bol nástroj optimalizovaný. Po optimalizácii som zistil až štvornásobné zrýchlenie oproti prvej vlastnej funkčnej implementácii. Následne som uskutočnil viacero experimentov s už optimalizovanou implementáciou, ktorých výsledky rozoberiem v tejto kapitole.

Testovanie prebiehalo na počítači s procesorom Intel Pentium 1,70 GHz s 1,00 GB RAM. Testovacie dáta pozostávali z dvoch volumetrických medicínskych dát. Jedná sa o CT dáta rozmerov  $541 \times 541 \times 175$  a  $541 \times 541 \times 260$  voxelov. V prvom prípade sa jedná o CT scan ľudskej hlavy a druhé

testovacie dáta sú CT scan hrudnej oblasti ľudského tela s pridanou kontrastnou látkou do krvného obehu na zvýraznenie tepien.

Hlavnou sledovanou veličinou pri experimentoch bol výsledný čas segmentácie s ohľadom na množstvo obrazových bodov obsiahnutých vo výslednom deformovateľnom povrchu, veľkosť počiatočného povrchu a množstvo vykonaných iterácií nutných na dosiahnutie výsledku. Ďalej bol sledovaný vplyv množstva vyhladzovacích krokov na celkový výpočtový čas. Ďalej som overoval predpoklad, že ovplyvňovaním smeru vývoja povrchu len na rozťahovanie alebo zmršťovanie, je možné urýchliť výpočet v najlepšom prípade až dva krát. Ďalej sa experimentovaniu podrobila oblasť velocity field. Jeho možnosti, druhy a využitie. V nasledujúcej časti tejto kapitoly popíšem konkrétne experimenty spomenutých oblastí.

Segmentácia	Dáta	Počet iterácií	Veľkosť modelu [bodov]	Počet a veľkosť počiatočných povrchov	Celkový výpočtový čas
1: Aorta	541×541×260	200	315,03 tis.	1: 30×30×20 2: 20×20×20 3: 20×20×10	23,09
2: Očná bulva	541×541×175	40	74,47 tis.	1: 20×20×10	0,58s
3: Lebka	541×541×175	380	4,309 mil.	1: 50×50×30 2: 50×50×30	5min. 13,92s
4: Povrch hlavy*	541×541×175	300	22,96 mil.	1: 200×200×100	3min. 49,03s

Tabuľka 1: Porovnanie segmentačných úloh pomocou implementovaného nástroja. \* - okrem hlavových a kostených dutín.

Tabuľka 1 znázorňuje experimenty so segmentáciou. Uvádza len niekoľko z mnohých experimentov, ktoré boli vykonané. Všetky testy vedú k rovnakým záverom. Čím je model reprezentujúci segmentáciu väčší (obsahuje viac obrazových bodov), tým je výpočtový čas väčší a zároveň rovnaký počet iterácií trvá na väčšom modeli dlhší čas z dôvodu väčšieho množstva hraničných bodov povrchu. Ďalej som z testov zistil, že pri vhodnom zadávaní viacerých počiatočných povrchov je možné dosiahnuť požadovaný výsledok v kratšom čase a s menším počtom iterácií ako pri zadaní iba jedného povrchu. Je to dôsledok toho, že model je reprezentovaný všetkými počiatočnými povrchmi,

aj keď sú oddelené. Počas evolúcie sa potom tieto povrchy ľubovoľne spoja alebo rozdelia a stále budú všetky povrchy reprezentované ako celok.

Zo segmentácie č. 3 a 4 v tabuľke 1 je zrejmy veľký výpočtový čas. Modely síce obsahujú milióny bodov, ale výsledok segmentácie je buď model lebky alebo celej hlavy bez vnútorných dutín. Podobný výsledok je však možné dosiahnuť viacerými nízkoúrovňovými technikami (napr. thresholding) a výpočtový čas bude v rádoch sekúnd. Z tohoto pohľadu sa javí využitie implementovaného nástroja ako nevhodné na podobné druhy segmentácie. Využíva metódu založenú na objektoch (výsledný povrch je objekt a reprezentuje iný objekt v dátach) a je teda vhodnejšie použitie na segmentovanie konkrétnych objektov v dátach. Vhodným príkladom môže byť segmentácia č. 1. Ide o segmentáciu aorty, ktorej výsledný model popisujúci tento objekt mal skoro štvrt' milióna bodov a výpočtový čas bol 23 sekúnd. Na rozdiel od segmentovania lebky, ktorá ma príliš členitý povrch, je povrch aorty relatívne hladký, čo sa prejaví na kratšom čase segmentovania.

Segmentácia	Počet iterácií	Veľkosť modelu [bodov]	Smer vývoja povrchu	Celkový výpočtový čas
4	300	28,34 mil.	rozťahovanie	2min. 23,13 s
2	40	74,49 tis.	rozťahovanie	0,46 s

Tabuľka 2: Ukážka výsledku segmentácie ovládaním smeru evolúcie povrchu. Hodnota položky Segmentácia (4) odkazuje na segmentáciu z Tabuľka 1. Pri zhodných počiatkových podmienkach sa zvolením smeru evolúcie (rozťahovanie) zmenšil celkový výpočtový čas.

Tabuľka 2 poskytuje informácie o experimentoch vykonaných ovplyvňovaním smeru evolúcie povrchu. Toto kritérium bolo zvolené na niektorých segmentáciách z tabuľky 1 za rovnakých podmienok. Je to možné použiť v prípade kedy vieme, že inicializačný povrch sa nachádza celý vo vnútri cieľového objektu. Najväčšia časová úspora bola v prípade segmentácie č. 4 z tabuľky 2, kde evolúcia týmto spôsobom dosiahla rovnakého výsledku ako segmentácia č. 4 z tabuľky 1 a spotrebovala pritom o 37% menej času. V prípade segmentácie č. 2 sa jedná o urýchlenie o 21% oproti segmentácií bez ovplyvňovania smeru evolúcie. Tabuľka 2 teda potvrdzuje predpoklady z návrhu o kratšom výpočtovom čase ovplyvnením smeru evolúcie.

Testovaniu som podrobil aj silové pole velocity field. Implementované boli dva druhy. Oba druhy VF sú v konečnom dôsledku vhodné na segmentovanie tých istých štruktúr. Prvý typ je modifikované Chan-Vese kritérium segmentácie. Druhý typ pracuje s pravdepodobnostným rozložením intenzít v daných dátach. Princíp týchto dvoch metód je rozdielny, ale nakoniec môžu byť schopné modelovať tie isté situácie.

Ďalším poznatkom je, že ako velocity field môže byť použitý výstup inej segmentačnej metódy, ktorá má charakter binárnej masky. Teda v prostredí MDSTk alebo 3DimViewer je možné dáta spracovať nejakou nízkoúrovňovou metódou a jej výstup využiť ako velocity field. Javí sa to ako obzvlášť vhodné, keď napríklad chceme zo spracovaných dát pomocou prahovania vysegmentovať len konkrétny objekt. Podobu velocity field znázorňuje obrázok 31.

## 7.2 Možnosť budúceho vývoja

Ďalší vývoj implementovaného nástroja je v budúcnosti možný a problém segmentácie využitím FLSM rozhodne nie je uzavretý. Najväčší potenciál je v oblasti externých silových polí velocity field. Ako je zrejme z návrhu, sú použité dva typy silového poľa. Ďalší vývoj by sa mohol uberať smerom vytvárania ďalších druhov velocity field, napríklad odhadom pravdepodobnostných funkcií hustoty intenzity (Estimation of intensity Probability Density Functions), podľa teoretických podkladov v [15,35].

Súčasťou rozšírení by mohla byť aj možnosť väčšej interaktivity zadávania počiatočného povrchu. Nástroj v dobe písania tejto práce podporuje zadávanie inicializačného povrchu v tvare kvádra, o ktorého rozmeroch a umiestnení rozhoduje užívateľ. Určite by možnosť vizualizácie počiatočných povrchov vniesla do procesu segmentácie značné množstvo interaktivity a umožnila by hlavne jednoduchšiu a intuitívnejšiu prácu s nástrojom.

Podobne v oblasti zadávania počiatočných povrchov by mohla byť ponuka rozšírená o množstvo iných tvarov a hlavne spôsobov vytvárania týchto prvotných povrchov. Súčasťou by bola ponuka mnohých parametricky vyjadriteľných telies, ako aj možnosť užívateľského vymedzenia priamo v dátach.

Čo sa týka samotného procesu segmentácie, ponúka sa tu možnosť užívateľského zásahu do externého silového poľa velocity field. Jednalo by sa o zadávanie akýchsi umelých hrán priamo do reprezentácie velocity field, ktoré by menili v daných miestach možnosti vývoja povrchu. Mohli by ho v nežiadúcich miestach obmedzovať, alebo naopak dovoliť mu vyvíjať sa aj za hranice istých obmedzení. Manipulácia by vzhľadom na rovnaký charakter silového poľa a zdrojových dát mohla prebiehať cez zobrazovaný objem v aplikácii 3DimViewer. Dané rozšírenie je možné vďaka poňatiu problému ako segmentácie krokovanej, so schopnosťou vrátenia sa do histórie vývoja.

Implementovaný nástroj by teoreticky mohol ďalej nájsť uplatnenie aj v iných oblastiach a odvetviach. Tu sa ponúka možnosť využitia ako výukového nástroja alebo v oblasti strojnictva na odhaľovanie prasklín, trhlin alebo nehomogénnych častí v rôznych materiáloch. Ďalej v oblasti spracovania medicínskych dát by sa dal použiť na "vylepšovanie" už hotovej segmentácie vykonanej



inou metódou práve vďaka možnosti použiť výsledky iných segmentácií ako VF pre môj nástroj. Vo všeobecnosti by sa dal tento nástroj použiť vo všetkých oblastiach, ktoré spracovávajú objemové dáta.

Vzhľadom na fakt, že bol implementovaný aj 2D variant metódy level-set, je možné túto implementáciu v budúcnosti využiť. Doba spracovania 2D obrazu metódou FLSM sa pohybuje v desatinách sekúnd. Po optimalizácii algoritmu by mohol 2D variant slúžiť na real-time video tracking. Sledovali by sa tak oblasti záujmu v reálnom čase na video materiáloch.

## 8 Záver

Cieľom diplomovej práce bolo preštudovanie základov spracovania obrazu a zorientovanie sa v súčasných metódach segmentácie medicínskych dát. Ďalej bolo vyžadované zvolenie vhodnej metódy segmentácie a navrhnutie segmentačného nástroja medicínskych dát.

Po preštudovaní existujúcich segmentačných techník som si zvolil metódu fast level-set, ktorá je variantou klasickej metódy LS a jej hlavnou kvalitou je rýchlosť výpočtu pri zachovaní vynikajúcich vlastností metódy pôvodnej. Princíp metódy tkvie v diskretnom poňatí pôvodnej metódy, čo zvyšuje rýchlosť celkového výpočtu až o dva rády oproti pôvodnej metóde. Zvolená metóda bola implementovaná podľa teoretických podkladov. Jedná sa o vlastnú implementáciu metódy, ktorá vyústila v segmentačný nástroj pre objemové medicínske dáta. Okrem základných vlastností metódy boli implementované vlastné rozšírenia, ktoré boli do výsledného nástroja zahrnuté. S výslednou implemetáciou som prevádzal mnoho experimentov a testov na potvrdenie predpokladaného chovania metódy a zároveň na získanie nových nepopísaných vlastností. Experimenty zahŕňali porovnávanie, vyhodnocovanie a získavanie nových znalostí o realizovanej implementácii. Primárnym cieľom nástroja mala byť segmentácia hlavne objemových medicínskych dát, ale v rámci implementácie bola zrealizovaná aj možnosť segmentovania 2D obrazových dát. V čase písania práce neexistoval dostupný nástroj využívajúci túto metódu a jeho postavenie je jedinečné.

Nad rámec diplomovej práce bola zrealizovaná nadstavba implementovaného nástroja. Tá pozostáva z grafického užívateľského rozhrania pre daný nástroj a následného včlenenia výsledku do existujúcej aplikácie určenej na prácu s medicínskymi dátami ako plugin.

V závere práce boli navrhnuté možnosti budúceho vývoja ako aj oblasti ďalšieho použitia. V konečnom dôsledku sa podarilo vytvoriť interaktívny segmentačný nástroj medicínskych objemových dát, ktorý je vo svojej oblasti jedinečný a vyznačuje sa práve využitím metódy FLSM a väčšou rýchlosťou výpočtu v porovnaní s nástrojmi v rovnakej oblasti pôsobenia. Zaradenie nástroja do existujúcej aplikácie ponúka možnosť využitia v praxi v oblasti medicínskych aplikácií, za čo by som chcel touto cestou poďakovať spoločnosti 3Dim Laboratory, s.r.o.

# Literatúra

- [1] P.A., YUSHKEVIC, J., PIVEN, H.C., HAZLETT, R.G., SMITH, S., Ho, J.C., GEE, G., GERIG: User-guided 3D active contour segmentation of anatomical structures: Significantly improved efficiency and reliability, *NeuroImage* 31 (2006) 1116 – 1128
- [2] M., SONKA, V., HLAVAC, R., BOYLE: *Image Processing, Analysis, and Machine Vision*, PWS Publishing, 1999, ISBN 0-534-95393-X.
- [3] M., SONKA, J.M, FITZPATRICK, *Handbook of medical Imaging*, The International Society for Optical Engineering; 1 edition (June 15, 2000) , ISBN-13: 978-0819436221
- [4] K., NIEMAN, M., ODKERK, B.J.,RENSING, P., OOIJEN, A., MUNNE, R.J., GEUNS, P.J., FEYTER: *Coronary angiography with multi-slice computed tomography*, Department of Cardiology, Thoraxcenter, Rotterdam University Hospital, Netherlands, Early Report Február 2001.
- [5] S.S, AL-AMRI, N.V., KALYANKAR, S.D., KHAMITKAR: *Image segmentation by using edge detection*, *International Journal on Computer Science and Engineering*, 2010.
- [6] P.E, HART: *How the Hough transform was invented [DSP History]*, *Signal Processing Magazine, IEEE*, Vol. 26, No. 6. (23 October 2009), pp. 18-22.
- [7] L., SHAPIRO, G., STOCKMAN: *Computer vision*, The Univeristy of Washington, Department of Computer Science Michigan State Unicersity, Marec 2000.
- [8] BALLARD, D. H.; BROWN, C. M.: *Computer Vision*, Prentice Hall, 1982, ISBN 0-13-165316-4.
- [9] ŠPANEL, M.; BERAN, V.: *Obrazové segmentační techniky*, *Technická zpráva*, Vysoké Učení Technické v Brně, Fakulta Informačních technologií, Ústav Počítacové grafiky a Multimédií, 2005.
- [10] D.L., PHAM, C., XU, J.L, PRINCE: *A survey of current methods in medical image segmentation*, Department of Electrical and ComputerEngineering, The Johns Hopkins University, Baltimore, *Annual Reviewof Biomedical Engineering*, Január 19, 1998.
- [11] C.A, BOUMAN: *Markov Random Fields and Stochastic Image Models*, School of Electrical and Computer Engineering Purdue University, 1995 *IEEE International Conference on Image Processing* 23-26 Október 1995.
- [12] L., LEGENSTEIN: *Simulated Annealing*, Institute for Theoretical Computer Science, január 2010[online], dostupné na URL: <[http://www.igi.tugraz.at/lehre/NNA/WS09/nna\\_SA.pdf](http://www.igi.tugraz.at/lehre/NNA/WS09/nna_SA.pdf)>.
- [13] I.N., BANKMAN: *Handbook of mediactal imaging Processing and analyzis*, Academic Press; Elsevier Science & Technology Books, Január 2009, ISBN 0123739047 978-0123739049.
- [14] A., WEISSMÜLLER, F., VIETZE, D.R., DERSCH, K., HAHN, H., RITTER: *A Neural Network Approach to Adaptive Pattern Analysis the Deformable Feature Map*, *European Symposium on Artificial Neural Networks Bruges*, April 2000.

- [15] C., BAILLARD, C., BARILLOT: Robust 3D segmentation of anatomical structures with level sets, *Medical Image Computing and Computer Assisted Intervention Miccai*, 2000.
- [16] J.A., SETHIAN: *Level Set Methods: Evolving Interfaces in Computational Geometry, Fluid Mechanics, Computer Vision, and Materials Science*, University, 1996, ISBN 0521572029
- [17] R., MALLADI, J. A. SETHLAN: Image processing via level set curvature flow, *Proc. Natl. Acad. Sci. U S A.* 1995 Jul 18;92(15):7046-50.
- [18] J.A., SETHIAN: *Level Set Methods: An Act of Violence - Evolving Interfaces in Geometry, Fluid Mechanics, Computer Vision and Materials Sciences*, 1997.
- [19] R., MALLADI, J.A., SETHIAN, B.C., VEMURI: A Topology Independent Shape Modeling Scheme, *Proceedings of SPIE Volume*, Jún 23 1993.
- [20] A.A., FARAG, H., HASSAN: Adaptive Segmentation of Multimodal 3D Data Using Robust Level Set Techniques, *Proc. of International Conference on Medical Image Computing and Compute Assisted Intervention (MICCAI'04)*, Saint Malo, France, September 26-29, 2004, pp. 143-150.
- [21] O., STANLEY, R.P., FEDKIW: *Level Set Methods: An Overview and Some Recent Results*, *Journal of Computational Physics*, Volume 169, pp. 463-502 (2001).
- [22] J., LARSEN, T.G., KRISTENSEN: An overview of the implementation of Level Set methods, including the use of the Narrow Band method, December 9, 2005.
- [23] J.R., ROMMELSE: A Robust Level Set Algorithm for Image Segmentation and its Parallel Implementation, *Proceedings of the 2002 Int. Symposium on Distributed Computing and Applications to Business, Engineering and Science*, Wuxi, China, December 16-21, 2002, ISBN 7-5629-1881-3, 2002, pp. 36-42.
- [24] M., DROSKEY, B., MEYEREZ, M., RUMPFY, K., SCHALLERZ: An adaptive level set method for medical image segmentation, *Lecture Notes in Computer Science*, 2001, Volume 2082/2001, 416-422, DOI: 10.1007/3-540-45729-1\_43.
- [25] Y., SHI, W.C., KARL: A Fast Level Set Method Without Solving PDEs, *Acoustics, Speech and Signal Processing*, Technical Report No. ECE-2005-02, 2005.
- [26] J., KRÁTKÝ, J., KYBIC: Three-dimensional segmentation of bones from CT and MRI using fast level sets, in *Proceedings of SPIE, Medical Imaging 2008: Image Processing*, vol. 6914, ISBN 9780819470980, SPIE, 2008, 10 p.
- [27] PY., BONDIAU, G., MALANDAIN, S., CHANALET, PY., MARCY, JL., HABRAND, F., FAUCHON, P., PAQUIS, A., COURDI, O., COMMOWICK, I., RUTTEN, N., AYACHE: Atlas-based automatic segmentation of MR images: validation study on the brainstem in radiotherapy context, *Int J Radiat Oncol Biol Phys.* 2005 Jan 1;61(1):289-98.
- [28] T., MCINERNEY, D., TERZEPOULOS: *Deformable Models in Medical Image Analysis: A Survey*, *Medical Image Analysis Volume 1, Issue 2*, June 1996, Pages 91-108.
- [29] M., KASS, A., WITKIN, D., TERZEPOULOS: Snakes: active contours, *International Journal of Computer Vision*, 321-331 (1988).

- [30] L.D., COHEN, I., COHEN: Deformable Models for 3D Medical Images using Finite Elements & Balloons, Computer Vision and Pattern Recognition, 1992 .
- [31] “Brain cases by Diagnosis”[online]. Dostupné na URL: <<http://www.mritutor.org/mriteach/brdiag.html>>, last modified 22 júna 2007, citované 9.10.2011.
- [32] F., ZHU, J., TIAN: Modified fast marching and level set method for medical image segmentation, Journal of X-Ray Science and Technology 11 (2003) 193–204.
- [33] D., TERZEPOULOS, J., PLATT, A., BARR, K., FLEISCHER: Elastically Deformable Models, Computer Graphics, Volume 21, Number 4, Júl 1987.
- [34] T.F., CHAN, L.A., VESE, Active contours without edges, IEEE Trans on Image Processing , Vol. 10, No. 2, pp. 266–277, Február 2001.
- [35] J., MALCOLM, Y., RATHI, A., YEZZI, A., TANNENBAUM: Fast Approximate Surface Evolution in Arbitrary Dimension, IS&T/SPIE Symposium on Medical Imaging, 2008.
- [36] D., MAGEE, A., BULLPIT, E., BERRY: Combining 3D Deformable Models and Level Set Methods for the Segmentation of Abnormal Aortic Aneurysms . Proc. British Machine Vision Conference, September 2001, p333-342.

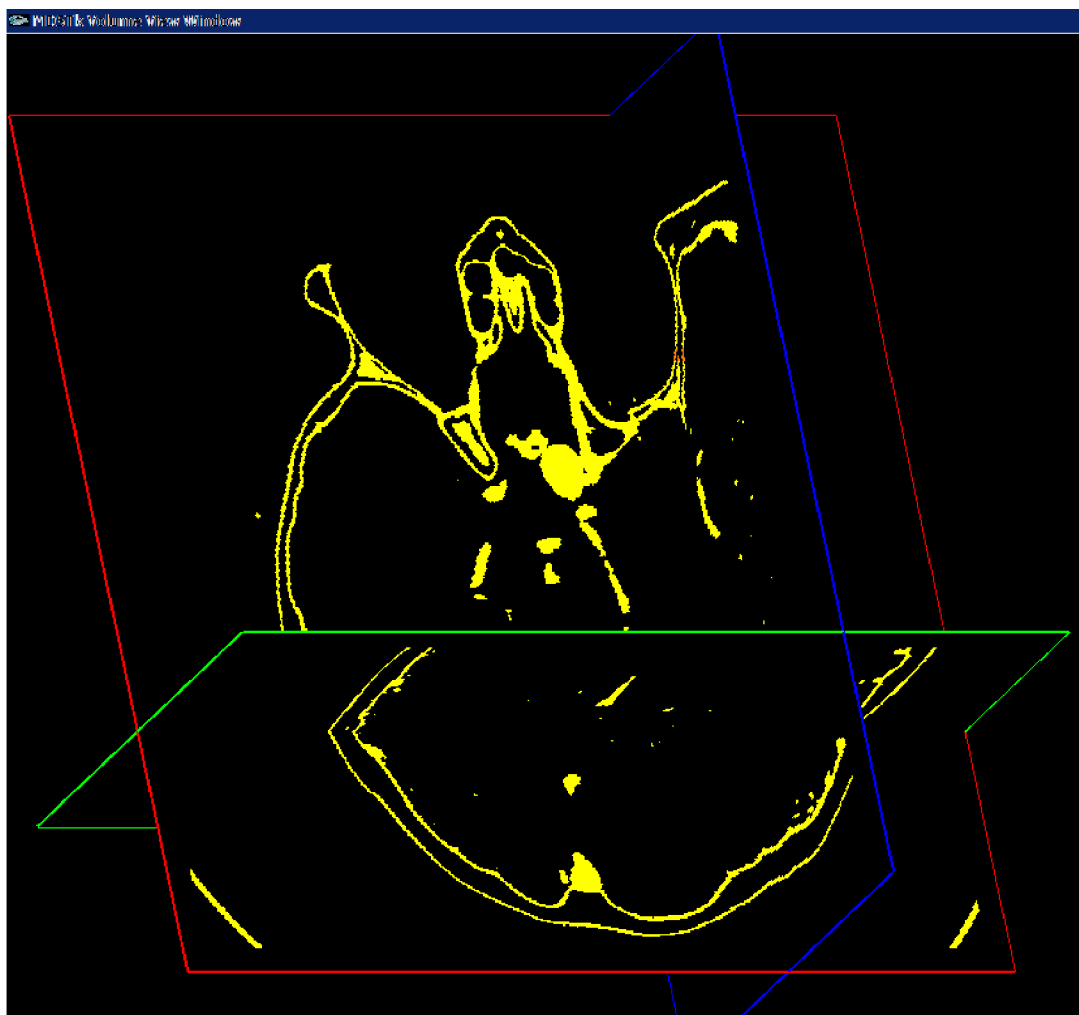
# Zoznam príloh

Príloha A: Ukážky výsledkov


Príloha B: Obsah CD

Príloha C: CD nosič

## Príloha A: Ukážky výsledkov

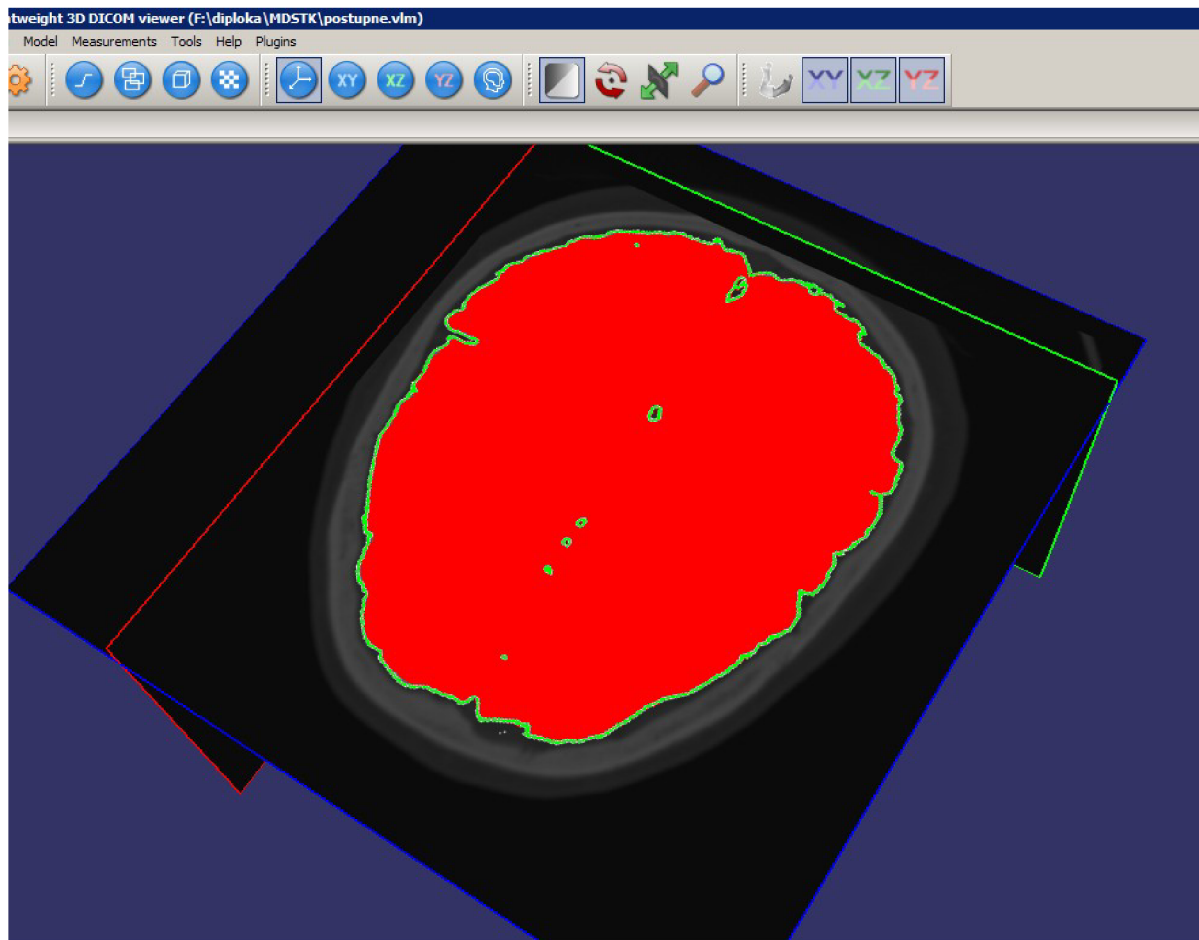


Obrázok 31: Ukážka výstupu modulu *Level Set* v *MDSTk toolkit:velocity field*. Obrázok bol upravovaný pre potreby tlače.




Obrázok 32: Ukážka výstupu nástroja 2D variantu v prostredí MDSTk. Dva štvorce v dátach reprezentujú počiatočné krivky modelu. Obrázok bol spracovaný pre potreby tlače.





*Obrázok 33: Ukážka výstupu segmentácie mozgu pomocou implementovaného nástroja. Obrázok bol pre potreby tlače farebne upravený.*



*Obrázok 34: Ukážka rezu segmentácie mozgu. Obrázok znázorňuje postupný vývoj povrchu z počiatočnej plochy, zachytený každých 10 iterácií.*

# Príloha B:      **Obsah CD**

## Obsah jednotlivých adresárov

- `text` - Technická správa diplomovej práce vo formáte PDF
- `zdroj_subory_nastroja` - Zdrojové kódy segmentačného nástroja
- `zdroj_subory_nadstavby` - Zdrojové kódy nadstavby nástroja
- `MDSTk` - Zdrojové kódy toolkitu, do ktorého bol pridaný výsledný nástroj
- `software` - Dodatočné programy zabezpečujúce správny chod nástroja a jeho nadstavby
- `3DimViewer` - Spustiteľná aplikácia obsahujúca nadstavbu nástroja
- `readme` - Pomocné súbory informačného charakteru s návodom na inštaláciu
- `uziv_prirucka` - Užívateľská príručka k implementovaným aplikáciám
- `vystupy` - Dodatočné ukážky obrazových výstupov a ukážkové video