SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Marko Subašić

GEOMETRIJSKI DEFORMABILNI MODEL ZA ANALIZU MEDICINSKIH SLIKA

MAGISTARSKI RAD

Zagreb, 2003.

Magistarski rad je izrađen u Laboratoriju za signale i sustave Zavoda za elektroničke sustave i obradbu informacija

Mentor: Prof. dr. sc. Sven Lončarić

Magistarski rad ima: 131 stranicu

Rad br.:

Sadržaj

Poglavlje 1

Uvod

Čovjek 90% informacija o svojoj okolini prima putem vida. Slika stoga za čovjeka oduvijek ima posebno značenje i čest je predmet stvaranja, proučavanja, obrade i pohrane. Razvoj digitalne tehnologije i digitalne obrade signala otvorio je nove mogućnosti u obradi slika. Kako je slika kao nositelj informacija, prisutna u svim područjima ljudske djelatnosti, primjena digitalne obrade slike praktički je neograničena. Pod pojmom digitalna obrada slike podrazumijeva se primjena različitih metoda na sliku u diskretnoj formi s ciljem postizanja željene promjene na slici. Tipično, radi se o poboljšanju slike za ljudsku interpretaciju. Digitalna analiza slike svojevrsna je nadogradnja digitalne obrade slike gdje je cilj izvući bitne informacije iz slike. Najčešće je motivacija za digitalnu analizu slike, automatska interpretacija slike odnosno svojevrsna zamjena ili oponašanja čovjeka.

Jedan tip operacije u digitalnoj analizi slike je segmentacija. Segmentacija se može opisati kao postupak izdvajanja interesantnog objekta na slici od ostalih dijelova slike. Segmentacija je stoga često i prvi korak u daljnjoj interpretaciji slike. Složenost problema segmentacije ovisi o samoj slici i njenim svojstvima kao što su kvaliteta, prisutnost šuma i utjecaju metode akvizicije slika. Složenost segmentacije također ovisi i o svojstvima objekta koji se segmentira kao što su oblik, relativan položaj u slici, homogenost, itd.

Razvijene su brojne i raznolike metode segmentacije slika koje se mogu podijeliti prema svojoj složenosti na jednostavnije i na složenije. Jedna takva grupa složenijih metoda segmentacije slika su deformabilni modeli, a njihov cilj je opisati željeni objekt na slici matematičkim modelom. Vrste deformabilnih modela razlikuju se po korištenom matematičkom modelu. U sam model ugrađena su neka znanja o objektu koji se segmentira, koja sužuju broj mogućih ishoda segmentacije. Deformabilni modeli funkcioniraju tako da se prvo zada inicijalni oblik matematičkog modela koji se onda deformira (mijenjajući parametre modela) dok ne poprimi oblik i poziciju željenog objekta. Podvrste deformabilnih modela se isto tako razlikuju i po algoritmu deformacije. Rezultat segmentacije, označena regija objekta od interesa na slici, upotrebljava se za daljnju analizu.

Jedna od značajnijih područja ljudske djelatnosti gdje je digitalna analiza slike našla veliku primjenu je medicina. Moderni medicinski uređaji kao što su ultrazvuk, CT (kompjuterska tomografija), MR (magnetska rezonancija), koji se koriste u dijagnostici ili pri operativnim zahvatima često daju slike npr. određenog dijela tijela. Obučeni liječnici takve slike pregledavaju i analiziraju njihov sadržaj, pronalaze objekt (npr. organ) od interesa, analiziraju ga i mjere. Iako moderni medicinski uređaji imaju velike mogućnosti, analizu sadržaja slika, dakle i segmentaciju slike, još uvijek najčešće radi čovjek. U najjednostavnijem obliku ručna segmentacija provodi se tako da liječnik rukom nacrta obrise objekta na slici. Na takvu segmentaciju utječe subjektivna procjena liječnika, što rezultira različitim rezultatima: kada dva liječnika segmentiraju istu sliku ili kada isti liječnik segmentira istu sliku ali s vremenskom distancom između dvije segmentacije. Još jedan problem predstavlja činjenica da najnoviji medicinski uređaji proizvode sve veće i veće količine podataka tj. slika tako da segmentacija slika jednog pacijenta zahtjeva previše vremena i postaje jako zamorna za liječnike, što ujedno smanjuje i preciznost segmentacije. Ti problemi nastoje se riješiti automatiziranom digitalnom analizom odnosno segmentacijom slike koja treba ponuditi veću ponovljivost segmentacije i rasteretiti liječnike dugotrajnog i zamornog posla.

Brojne metode segmentacije se uspješno koriste na medicinskim slikama, a novi modaliteti slika najnovijih medicinskih uređaja neprestano stvaraju nove izazove za digitalnu analizu slike. Dodatni izazove predstavljaju velika važnost medicinskih slika i visoka preciznost i kvaliteta koju medicinska struka traži od digitalne analize slike.

Veliku popularnost u analizi medicinskih slika stekli su upravo deformabilni modeli gdje se već duže vrijeme uspješno primjenjuju. Svoju popularnost stekli su zahvaljujući činjenici da dobro funkcioniraju na slikama lošije kvalitete, u prisutnosti intenzivnijeg šuma ili raznih artefakata, što je česta pojava upravo na slikama koje daju medicinski uređaji. Primjeri medicinskih slika prikazani su na slici 1.1 dok su primjeri segmentacije tih istih slika pomoću deformabilnih modela prikazani na slici 1.2.

Sredinom 90-ih godina pojavili su se geometrijski deformabilni modeli, kao odgovor na neke probleme dotadašnjih deformabilnih modela i od tada se uspješno koriste i u obradi medicinskih slika.

Sve gore navedene metode spominju se u kontekstu segmentacije dvodimenzionalnih slika

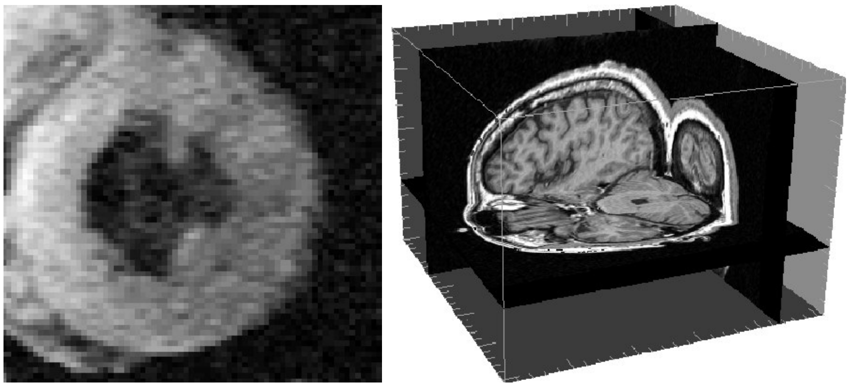

(a) (b)

Slika 1.1: Raznolikost oblika i kvalitete kod medicinskih slika. (a) 2D MR slika lijeve klijetke srca. (b) 3D MR slika mozga

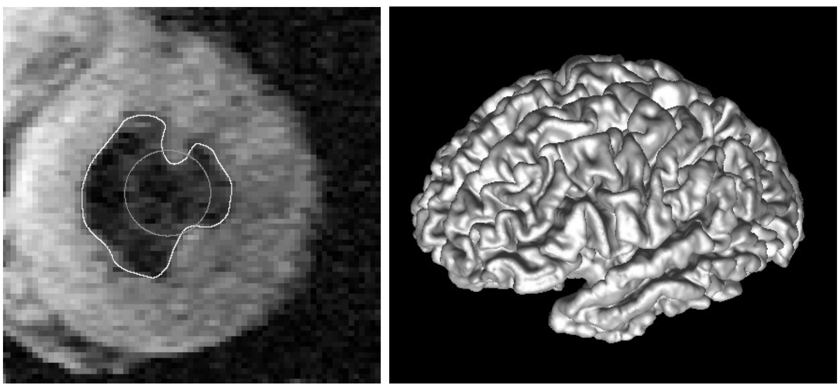

(a) (b)

Slika 1.2: Primjeri segmentacija medicinskih slika. (a) Segmentacija lijeve klijetke gdje sivi krug predstavlja inicijalni oblik, a bijela krivulja završni oblik deformabilnog modela. (b) Rezultat segmentacije CT slika mozga no gotovo sve se te metode mogu primijeniti i primjenjuju se na višedimenzionalne slike (3-D, 4-D...).

U ovom radu, geometrijski deformabilni model primijenjen je na problem segmentacije aneurizme abdominalne aorte iz niza CT slika.

1.1 Terminologija

Slijede objašnjenja često korištenih pojmova u ovom radu.

Slika, kao predmet proučavanja digitalne obrade slike, prvi je pojam koji treba definirati. Riječ slika koristi se kao direktan prijevod engleske riječi *image*. Pojam *image* u kontekstu digitalne obrade slike (engl. *digital image processing*) najčešće označava dvodimenzionalnu sliku, kao i hrvatska riječ slika, no može označavati i trodimenzionalne ili višedimenzionalne podatke čemu više odgovara hrvatska riječ volumen. U opisima metoda i algoritama u poglavljima 2 i 3 pojam slike odnosi se uglavnom na dvodimenzionalne slike, iako se većina metoda može primijeniti i na volumene ili na višedimenzionalne podatke. Primjer dvodimenzionalne slike je fotografija, dok primjer trodimezionalne slike može biti više fotografija snimljenih u vremenskom nizu. Još jedan primjer trodimenzinalnih slika su CT snimke koje su sačinjene od niza (slika) presjeka snimanog objekta.

Općenita definicija slike bila bi: *slika je optičko predočenje objekta obasjanog izvorom svjetlosti (zračenja).* Iako je boja važan sastavni dio slika, u digitalnoj obradi slike najviše se koriste crno bijele slike, odnosno jedina bitna informacija na slici tada je intenzitet svjetlosti. Dvodimenzionalna slika može biti predstavljena funkcijom intenziteta $I(x, y)$, gdje su x i y dvije prostorne koordinate. Domena slike je $D_I \subset \mathbb{R} \times \mathbb{R}$.

$$I : D_I \to \mathbb{R} \tag{1.1}$$

Općenito su funkcija $I(x, y)$ i varijable x i y kontinuirane i tada čine analognu sliku.

Digitalna obrada slike, koja se odvija na računalu, traži diskretnu formu slike $I_d(i, j)$ gdje su $i = 1, \ldots, N$ i $j = 1, \ldots, M$ diskretne prostorne varijable. Diskretizacija se može definirati kao preslikavanje kontinuirane funkcije u $\mathbb{R}^2$ na polje s konačnim brojem elemenata.

$$D : \mathbb{R}^2 \longmapsto \mathbb{Z}^2 \tag{1.2}$$

$$I(x, y) \xmapsto{D} I_d(i, j), \qquad x, y \in \mathbb{R}, \quad i, j \in \mathbb{Z} \tag{1.3}$$

Polje diskretnih točaka može imati proizvoljnu geometriju, no najčešće se uzima pravokutna mreža elemenata nazvana *raster*. Za element polja najčešće se uzima pravokutnik dimenzija Δx i Δy što odgovara i koracima otipkavanja. Takva diskretna slika može se predstaviti matricom dimenzija $N \times M$. Veza između kontinuirane i diskretne slike tada je dana sa

$$I_d(i,j) = I(i\Delta x, j\Delta y), \tag{1.4}$$

Sama vrijednost funkcije I_d treba biti kvantizirana na određeni broj razina. Kvantizacija je definirana kao preslikavanje kontinuirane varijable (svjetline) na skup s konačnim brojem (Q) diskretnih vrijednosti

$$[0,\infty] \overset{Q}{\longmapsto} \{g_1, g_2, \ldots, g_Q\}. \tag{1.5}$$

Broj diskretnih vrijednosti Q najčešće odgovara broju bitova n_b odabranom za pohranu vrijednosti elementa slike, tako da je $Q = 2^{n_b}$.

Svojstva funkcije $I_d(i,j)$ ovise o izvoru zračenja, o fizičkim svojstvima samog objekta, o metodi akvizicije slika i o odabranoj diskretizaciji. Svi ti parametri određuju kvalitetu slike $I_d(i,j)$.

Najmanji element diskretne slike je piksel (engl. *pixel*) što je skraćenica od *picture element*. svaki piksel određen je sa svojim koordinatama (i,j) i svojom vrijednošću I_d. Ukoliko se radi o trodimenzionalnim podacima uobičajeni naziv je voksel (engl. *voxel*) što je skraćeno od *volume element*.

Model se može definirati kao *reprezentacija nekih (ne nužno svih) značajki objekta. Svrha modela je vizualizacija te razumijevanje strukture ili ponašanja objekta te omogućavanje eksperimentiranja te predviđanja utjecaja promjena ulaza ili promjena svojstava modela.* Pojam deformabilnih modela koji je često korišten u ovom radu označava matematički model koji opisuje oblik i položaj objekta na slici. Deformabilni model pod određenim utjecajima mijenja svoj oblik i položaj od početnog ka završnom koji bi trebao najbolje opisivati oblik i položaj samog objekta na slici.

Medicinske slike su sve slike koje se koriste u medicinskoj praksi. U širem smislu tu ulaze i fotografije npr. promjena na koži, no u užem smislu tu se misli na slike koje stvaraju elektronički medicinski uređaji, kao što su magnetska rezonancija (MR), kompjuterska tomografija (CT), ultrazvuk itd. [24].

U ovom radu korištene su CT slike pa slijedi kratak opis kompjuterske tomografije. Preciznije, radi se o rendgenskoj kompjuterskoj tomografiji gdje se određuje prostorna (3-D) distribucija optičke gustoće (koeficijenta prigušenja rendgenskih zraka) u strukturi koja se snima. Prostorna distribucija se određuje matematičkom rekonstrukcijom na temelju mjerenja propuštanja rendgenskih zraka iz više različitih smjerova. Najčešće se koristi jedan točkasti izvor zračenja, čije se zračenje usmjerava prema detektoru na suprotnoj strani objekta. Projekcije se snimaju na luku od 360°postepenom rotacijom izvora i detektora za određeni kut (npr. 1°). Nakon snimanja jednog presjeka snima se sljedeći presjek koji je u odnosu na prethodni pomaknut u smjeru osi rotacije. Nakon snimanja projekcije se obrađuju i stvaraju se slike projekcija pomoću matematičke rekonstrukcije (npr. Fourierova rekonstrukcija ili projekcijom unazad). Svaki presjek je dvodimenzionalna slika no niz presjeka čini volumen. Prostorna rezolucija takvog snimanja je 0.1 do $1mm^2$ u ravnini presjeka, a debljina presjeka odnosno udaljenost između dva presjeka iznosi 1 do $10mm^2$. Broj snimljenih presjeka kreće se od nekoliko pa do stotinjak. Slike presjeka su najčešće rekonstruirane u matricu 512×512. Rezolucija kontrasta je obično oko 0.5% ukupnog raspona signala. Moderne verzije CT uređaja koriste više detektora te ne trebaju rotaciju izvora i senzora čime smanjuju vrijeme snimanja. CT se najčešće koristi za strukturalno snimanje, no uz upotrebu kontrasta može se koristiti za funkcionalno snimanje. Funkcionalno snimanje uz upotrebu kontrasta najveću primjenu ima u kardiologiji.

U ovom radu korištene su slike ljudskog abdomena, a objekt od interesa je abdominalna aorta. Da bi se dodatno istaknula aorta u njen krvotok ubačeno je kontrastno sredstvo koje dobro upija gama zrake. Zahvaljujući tome unutrašnjost aorte se jasno vidi na CT slikama. Snimanje krvnih žila pomoću kontrastnog sredstva naziva se angiografija, a kombinacija angiografije i CT-a naziva se angiografija kompjuterskom tomografijom (engl. *computer tomography angiography*) ili skraćeno CTA.

Ovaj rad napravljen je u suradnji s radiološkim odjelom Sveučilišne bolnice u Grazu, u Austriji, gdje je Dr. Erich Sorantin pružio medicinsku ekspertizu.

1.2 Organizacija rada

Nastavak rada organiziran je na sljedeći način:

- U poglavlju 2 dan je sažet pregled problema i metoda segmentacije slika. Opisane su i neke od manje složenih metoda segmentacije slika, a među njima je opisana većina metoda koje su korištene u ovom radu.

- U poglavlju 3 dan je detaljniji opis i klasifikacija deformabilnih modela. Više pažnje posvećeno je geometrijskom deformabilnom modelu koji je poznatiji pod nazivom level-set deformabilni model. Opisani su i detalji numeričke implementacije geometrijskih deformabilnih modela.

- U poglavlju 4 dan je opis problema segmentacije aneurizme abdominalne aorte te je dan pregled dosadašnjih istraživanja na tom području.
- U poglavlju 5 dan je detaljan opis osnovnog level-set algoritma korištenog u ovom radu.
- U poglavlju 6 iznesene su dvije modifikacije osnovnog level-set algoritma koje imaju za cilj njegovo brže izvođenje. Te modifikacije su dio glavnog doprinosa ovog rada.
- U poglavlju 7 dan je detaljan opis četiri različita pristupa razvijena u sklopu ovog rada, kojima se nastoje riješiti specifični problemi segmentacije aneurizme abdominalne aorte.
- U poglavlju 8 iznesen je zaključak.
- Na kraju rada dan je popis publikacija vezanih za ovaj rad i bibliografija.

Poglavlje 2

Segmentacija slika

Segmentacija slike je jedan od najvažnijih i najraširenijih koraka u postupcima analize slike. Segmentacijom se nastoji sliku podijeliti na regije (segmente) koje odgovaraju strukturalnim elementima slike odnosno na regije koje bi omogućile izdvajanje interesantnih objekata iz ostatka slike. Često se segmentacije slike uspoređuje s vizualnim procesom razdvajanja objekta i pozadine kojeg provodi čovjekov vizualni sustav, uglavnom na temelju jedne karakteristike. Računalni sustavi za segmentaciju pružaju više mogućnosti i sliku mogu razdvajati na temelju više karakteristika. Računalna segmentacija slike time ne samo da zamjenjuje čovjeka nego i proširuje postojeće mogućnosti.

Metode segmentacije općenito se zasnivaju na dvije osnovne karakteristike vrijednosti piksela: diskontinuitet i sličnost. Diskontinuiteti intenziteta točaka na slici predstavljaju granice među regijama te se slika dijeli na na regije omeđene, na takav način, pronađenim granicama. Postoji više metoda detekcije rubova, kao što su Gaussov detektor ruba, Cannyjev detektor ruba, Sobelov detektor ruba, itd. Kada se koristi sličnost intenziteta točaka slike, konačne regije slike činit će međusobno slične točke. Metode koje koriste sličnost vrijednosti piksela baziraju se na upotrebi praga, izrastanju regija, stapanju i cijepanju regija.

Princip sličnosti regije i princip diskontinuiteta u osnovi su ekvivalentni. Npr. ukoliko su na slici samo homogene regije sa izraženim diskontinuitetima na svojim granicama (idealni uvjeti), rezultati segmentacije trebali bi biti isti bez obzira koristi li se sličnost regija ili se traže diskontinuiteti. Zbog manje idealnih uvjeta u praksi, kao što su prisutnost šuma ili varijacije u svjetlini, nije svejedno koji se pristup koristi i odabir odgovarajuće metode uvelike ovisi o svojstvima same slike.

Metode koje traže diskontinuitete na slici koriste male prostorne maske definirane faktorima težine svakog svog elementa. Pomicanjem maske preko slike i zbrajanjem umnožaka faktora težina sa pripadajućim vrijednosti piksela stvara se nova slika čiji elementi imaju vrijednosti koje odgovaraju jačini diskontinuiteta. Ovisno o veličini i konfiguraciji faktora težine, maske mogu biti korištene za izoliranih točaka, ili unaprijed zadanih strukturalnih elemenata kao što su linije. Za detekciju rubova među homogenim regijama koriste se razni operatori. Najpoznatiji je gradijentni operator koji daje iznos amplitude gradijenta u nekoj točki slike. Primjer gradijentnog operatora dan je jednadžbom (2.1).

$$G[f(x,y)] = \sqrt{\left(\frac{\partial f(x,y)}{\partial x}\right)^2 + \left(\frac{\partial f(x,y)}{\partial y}\right)^2} \tag{2.1}$$

Ovakav gradijentni operator je euklidska norma derivacija u smjeru koordinatnih osi. Pojam gradijent slike često se spominje u ovom radu te se u nastavku pod gradijentom slike podrazumijeva jednadžba (2.1) osim ako nije drugačije navedeno.

Drugi poznati operator je Laplaceov operator zasnovan na drugoj derivaciji prikazan jednadžbom (2.2).

$$L[f(x,y)] = \frac{\partial^2 f(x,y)}{\partial x^2} + \frac{\partial^2 f(x,y)}{\partial y^2} \tag{2.2}$$

Razvijeni su mnogi drugi operatori za detekciju ruba, a glavni nedostatak svih njih je nemogućnost funkcioniranja u prisutnosti jačeg šuma.

Kod segmentacije na temelju sličnosti vrijednosti piksela, najraširenija i najpoznatija je metoda upotrebe praga. Osnovni princip ove metode je podjela prostora vrijednosti piksela na dva ili više intervala. Vrijednosti koje određuju granice tih intervala nazivaju se vrijednosti praga. Sve točke slike tada se grupiraju prema tome kojem intervalu pripadaju. Broju intervala vrijednosti odgovarat će i broj dobivenih regija na slici. Na primjer ukoliko sliku želimo podijeliti na dvije regije upotrebom jedne vrijednosti praga T tada svakom pikselu slike pridružujemo vrijednost nove funkcije $tr(x, y)$ definirane jednadžbom (2.3).

$$tr(x,y) = \begin{cases} 1 & \text{ako je } f(x,y) > T \\ 0 & \text{ako je } f(x,y) \leq T \end{cases} \tag{2.3}$$

Tada pikseli za koje je $tr(x, y) = 1$ pripadaju jednoj regiji, a pikseli koji za koje je $tr(x, y) = 0$ pripadaju drugoj regiji.

Vrijednost praga može biti zadana za cijelu sliku i tada se to naziva globalni prag. Vrijednost praga može biti definirana pomoću neke lokalne karakteristike piksela kao što je npr. srednja vrijednost susjednih piksela. Tada se to naziva lokalnim pragom $T(x, y)$.

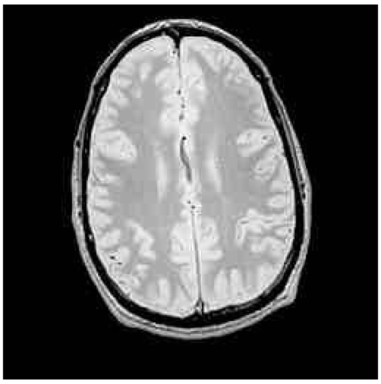

(a)

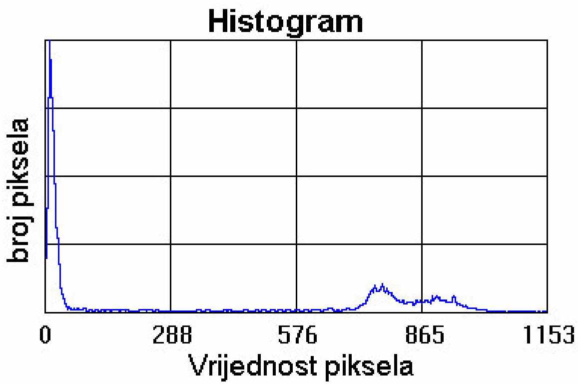

(b)

Slika 2.1: Primjer MR slike mozga (a) i odgovarajućeg histograma (b).

Za automatizirano određivanje praga, često se koristi funkcija histograma. Ovdje se intenzitet slike $f(x, y)$ promatra kao slučajna varijabla koja ima funkciju gustoće vjerojatnosti $p_f(f)$. Sama funkcija gustoće vjerojatnosti sadrži globalne informacije o slici no ona često nije poznata pa ju je potrebno procijeniti iz same slike upotrebom empiričke funkcije gustoće vjerojatnosti $\hat{p}_f(f)$ koja se naziva histogram. Ako pretpostavimo da slika ima L diskretnih razina svjetline i da je $n_k,\ \ k = 0, \ldots L - 1$ broj piksela koji imaju intenzitet k, tada je histogram definiran jednadžbom (2.4)

$$\hat{p}_f(f) = \frac{n_k}{n}, \quad k = 0, 1 \ldots, L - 1, \tag{2.4}$$

gdje je n sveukupni broj piksela na slici. Primjer slike i pripadajućeg histograma prikazan je na slici 2.1. Lokalni maksimumi histograma često predstavljaju srednje vrijednosti većih regija ili objekata na slici, a lokalni minimumi između dva maksimuma pogodni su za vrijednost praga kako bi na slici razdvojili te dvije regije.

Izrastanje regije je metoda koja grupira piksele u regije ili manje regije u veće. Započinje se s zadanim početnim točkama (engl. *seed points*) kojima se onda pridružuju susjedni pikseli sličnih karakteristika. Razlike postoje u definiranju susjedstva svake točke slike, npr. koliko točaka čini susjedstvo jedne točke i kako su one razmještene.

Stapanje i cijepanje regija ne kreće od početnih točaka, već je cijela slika podijeljena na određen broj proizvoljnih regija koje se onda stapaju ovisno o sličnosti ili cijepaju ovisno o različitosti. Stapanje ili cijepanje regija mogu biti upotrebljeni u bilo kojoj kombinacija npr., uzastopno cijepanje pa stapanje ili nekoliko cijepanja pa nekoliko stapanja.

Mapa udaljenosti još je jedna metoda segmentacije koja se koristi u ovom radu. To je funkcija $DM(p)$ definirana jednadžbom (2.5).

$$DM : F \longmapsto \mathbb{R},\ F \subset D_I, DM(p) = min(dist(p, (D_I \setminus F)), \tag{2.5}$$

Ovdje je domena mape udaljenosti skup F koji je podskup domene slike D_I. Mapa udaljenosti svakoj točki p svoje domene pridružuje vrijednost udaljenosti (obično euklidske) između točke p i najbliže točke koja nije u skupu F. Mapa udaljenosti koristi se u level-set metodi (poglavlje 5) i u jednoj modifikaciji level-set modela predstavljenoj u ovom radu (odlomak 7.3). Također se pokazala korisnom kod estimacije središta regija u odlomcima 7.3 i 7.4.

Gore navedene metode segmentacije smatraju se metodama niže složenosti (engl. *low level*) jer u svom funkcioniranju oslanjaju uglavnom samo na jednu značajku slike i funkcioniraju dobro samo na slikama visoke kvalitete. To su ujedno i jedne od prvih metoda segmentacije slike. Nakon njih razvijene su brojne složenije metode segmentacije koje osim samih značajki slike uključuju i određenu količinu znanja o svojstvima objekta koji se segmentira. Zahvaljujući uključenom znanju iz skupa svih mogućih rezultata segmentacije izbačeni su oni manje vjerojatni za konkretni objekt koji se segmentira.

Deformabilni modeli predstavljaju jednu takvu složeniju metodu segmentacije slike. Kod deformabilnih modela objekt na slici se nastoji opisati matematičkim modelom. Algoritam deformabilnog modela transformira početni model s ciljem da model svojim oblikom dovoljno precizno opiše oblik i položaj objekta na slici. Kada je postignuta zadovoljavajuća preciznost opisa, algoritam se zaustavlja. Znanje je kod deformabilnih modela ugrađeno u sami matematički model koji koristi te se tip i parametri odabranog matematičkog modela određuju prema svojstvima objekta kojeg se segmentira i prema svojstvima same slike. U kombinaciji sa deformabilnim modelom redovito se koristi jedna ili više metoda niže složenosti kako bi se povećala kvaliteta segmentacije.

Segmentacija medicinskih slika se smatra jednim od najtežih područja segmentacije slika. To je posljedica velikih varijacija oblika i kompleksnosti oblika medicinskih struktura, kao i prisutnost artefakata na slikama i ograničenja metoda snimanja medicinskih slika. Brojne metode segmentacije, pogotovo one veće složenosti, uspješno se primjenjuju ili su predmet intenzivnog istraživanja u svijetu. Veliki problem kod automatske segmentacije je robustnost. Gotovo sve metode zahtijevaju prethodno podešavanje parametara, početnih vrijednosti ili redoslijeda operacija te su vrlo osjetljive na njihove promjene. Osjetljivost na primjene parametara raste kod slika lošije kvalitete kao što su medicinske slike. Rješenje tog problema traži se u kombiniranom korištenju više različitih metoda segmentacije.

Poglavlje 3

Deformabilni modeli

3.1 Uvod

Deformabilni modeli mogu se najjednostavnije opisati kao krivulje ili površine definirane na domeni slike koje se raznim metodama pomiču prema željenom objektu na slici, s ciljem da ta krivulja ili površina, svojim oblikom i položajem, što preciznije opiše objekt na slici. Načini na koje se deformabilni modeli pomiču, tj. deformiraju, razlikuju vrste deformabilnih modela. Primjer segmentacije deformabilnim modelom dan je na slici 3.1 gdje se može pratiti evolucija deformabilnog modela od inicijalnog stanja na slici 3.1(c) pa do konačnog oblika na slici 3.1(f).

Prvi deformabilni modeli [10],[32] bili su krivulje koje su se mijenjale pod utjecajem unutarnjih sila, definiranih na samoj krivulji ili površini, i vanjskih sila definiranih pomoću podataka na slici. Unutarnje sile imaju funkciju da održavaju model glatkim tijekom deformacija. Uloga vanjskih sila je da privuku model granici objekta od interesa. Osim ograničenja koje drži model glatkim, u unutarnje sile mogu se ugraditi i dodatni uvjeti prilagođeni svojstvima objekta na slici, što deformabilni model čini manje osjetljivim na loše uvjete na slici. Iako ovakva formulacija opisuje samo jednu grupu deformabilnih modela, gotovo sve kasnije varijante deformabilnih modela imaju ekvivalentne elemente koji odgovaraju unutarnjim i vanjskim silama.

Svoju veliku popularnost deformabilni modeli stekli su zahvaljujući članku "Snakes: Active Contours" od Kass, Witkin, i Terzopoulos [10]. Do danas, deformabilni modeli postali su jedno od najaktivnije i najuspješnije istraživanih područja u segmentaciji slika. U literaturi se koriste različita imena za deformabilne modele kao što su: zmije (engl. *snakes*), aktivne konture ili površine (engl. *active contours or surfaces*), baloni (engl. *balloons*), deformabilne konture ili površine (engl. *deformable contours or surfaces*) itd.

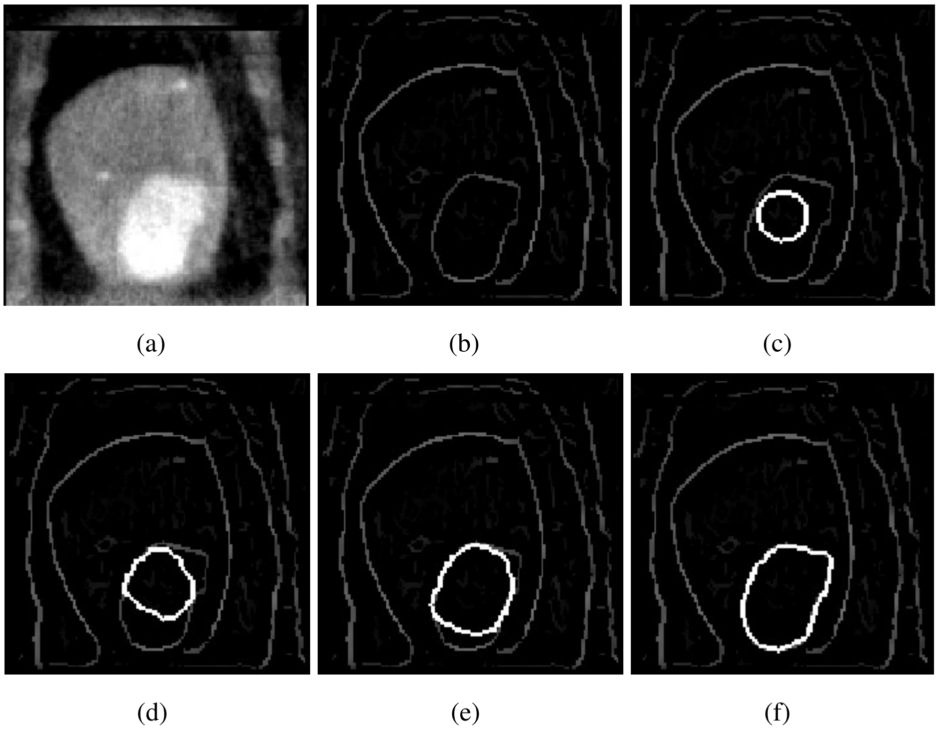

Slika 3.1: Primjer segmentacije deformabilnim modelom. (a) CT slika lijeve klijetke. (b) detektirani rubovi na slici. (c) inicijalna deformabilna kontura (d)-(f) Kretanje deformabilne konture prema rubu lijeve klijetke.

Deformabilni modeli mogu biti implementirani na kontinuiranoj domeni tako da je moguće postizanje preciznosti veće od veličine jednog piksela, što je vrlo korisno i poželjno svojstvo u obradi medicinskih slika.

Deformabilni modeli mogu se, u osnovi, podijeliti na dvije porodice: *parametarski deformabilni modeli* i *geometrijski deformabilni modeli*. Parametarski deformabilni modeli su eksplicitno zadani u svojoj parametarskoj formi i u toj formi se vrši deformacija. Parametarska forma omogućuje interakciju s deformabilnim modelom i zbog svoje kompaktnosti, brzu implementaciju pogodnu za izvršavanje u realnom vremenu. Nedostatak parametarske forme deformabilnih modela je taj što nije moguće na jednostavan način mijenjati topologiju deformabilnog modela (cijepanje jedne konture u više njih ili stapanje više kontura). Geometrijski deformabilni modeli mogu jednostavno mijenjati topologiju. Kod geometrijskih deformabilnih modela, krivulja ili površina zadana je u implicitnom obliku kao jedna razina (engl. *level-set*) skalarne funkcije više dimenzije. Usprkos fundamentalnim razlikama među dva tipa deformabilnih modela, principi na kojima se oni zasnivaju prilično su slični.

Sve vrste deformabilnih modela zahtijevaju inicijalizaciju tj. određivanje početnog oblika i položaja deformabilnog modela. Inicijalizacija se može obaviti:

- ručno od strane operatera (eksperta), najčešće uz pomoć grafičkog korisničkog sučelja,
- automatski, na način da poseban algoritam procjeni pogodan početni položaj i oblik deformabilnog modela.

Uspjeh segmentacije, osim kod jednostavnijih problema segmentacije, uvelike ovisi o inicijalizaciji. Stoga se, u pravilu, najbolji rezultati postižu ručnom inicijalizacijom, no nedostatak je što to za operatera može biti zamorno, a uključuje i subjektivno odlučivanje. Kvaliteta automatske procjene početnog stanja deformabilnog modela ovisna je o upotrebljenom algoritmu i o konkretnoj slici. Kod jednostavnijih problema segmentacije može se upotrijebiti i stohastička inicijalizacija, gdje se deformabilnom modelu dodjeljuje slučajno odabrani položaj i oblik.

U nastavku poglavlja bit će opisani parametarski i geometrijski modeli. Za obje porodice deformabilnih modela bit će iznesena podjele na podvrste. Parametarski i geometrijski deformabilni modeli podijeljeni su na primarne formulacije (prve koje su se pojavile) i na formulacije bazirane na minimizaciji energije.

Te podjele nisu jedine moguće i ne omogućavaju razvrstavanje svih razvijenih deformabilnih modela no iz takvih podjela moguće je uočiti sličnosti parametarskih i geometrijskih deformabilni modela. Druga moguća i često korištena podjela deformabilnih modela bazira se na tipu metode segmentacije niže složenosti koju koriste (slično kao podjela metoda niže složenosti u podglavlju 2). Tu razlikujemo dvije skupine deformabilnih modela:

- deformabilni modeli zasnovani na detekciji rubova odnosno diskontinuiteta na slici,
- deformabilni modeli zasnovani na sličnosti regija na slici.

U opisivanju deformabilnih modela veća težina stavljena je na geometrijske (*level-set*) deformabilne modele koji su korišteni u istraživanju provedenom u sklopu ovog rada.

3.2 Parametarski deformabilni modeli

Kod parametrskih deformabilnih modela, model je zadan u parametarskoj formi. Primjer parametarskog zapisa jedne krivulje u dvije dimenzije prikazan je jednadžbom 3.1.

$$\mathbf{x}(s) = (x(s), y(s)), s \in [0, 1] \tag{3.1}$$

Najčešća implementacija parametarskih deformabilnih modela podrazumijeva odabir parametra (najčešće duljine) te diskretizaciju te parametrizacije. Ovim postupkom dobije se konačan broj točaka (markera) čije se pozicije mijenjaju u skladu s aproksimacijom jednadžbe kretanja. Takav pristup daje dovoljnu preciznost kod relativno malih promjena/kretanja. Kod većih i kompleksnijih promjena dolazi do problema. Npr. moguće je da dva markera dođu blizu jedan drugome što može dovesti do numeričke nestabilnosti. Tada je potrebna reparametrizacija ili povećanje rezolucije rastera. Tu je i prije spomenuti problem promjene topologije za koji je potrebno tražiti *ad-hoc* rješenja

Parametarski deformabilni modeli mogu se podijeliti prema formulaciji na formulaciju koja minimizira energiju i na formulaciju s dinamičkim silama. Prva formulacija pruža mogućnost korištenja brojnih metoda minimizacije, dok druga formulacija pruža veću slobodu u izboru vanjskih sila.

3.2.1 Formulacija minimizacije energije

Osnovna premisa formulacije deformabilnih modela koja minimizira energiju je traženje krivulje ili površine koja minimizira određenu energetsku funkciju. Energetska funkcija $\mathcal{E}(\mathbf{x})$ (jednadžba (3.2)) tipično se sastoji od dva dijela: funkcional unutarnje energije $\mathcal{S}(\mathbf{x})$ i funkcional potencijalne energije $\mathcal{P}(\mathbf{x})$.

$$\mathcal{E}(\mathbf{x}) = \mathcal{S}(\mathbf{x}) + \mathcal{P}(\mathbf{x}) \tag{3.2}$$

Funkcional unutarnje energije $S(\mathbf{x})$ daje modelu određena svojstva kao što su napetost, glatkoća itd. Najčešći oblik $\mathcal{S}(\mathbf{x})$ prikazan je jednadžbom (3.3)

$$\mathcal{S}(\mathbf{x}) = \frac{1}{2}\int_0^1 \alpha(s)\left|\frac{\partial \mathbf{x}}{\partial s}\right|^2 + \beta(s)\left|\frac{\partial^2 \mathbf{x}}{\partial s^2}\right|^2 ds \tag{3.3}$$

Prva derivacija daje elastičnost modelu odnosno sprječava istezanje dok druga derivacija sprječava savijanje modela odnosno daje mu krutost, $\alpha(s)$ i $\beta(s)$ su težinski faktori koji se najčešće uzimaju kao konstante. Često se uzima da je $\beta(s) = 0$ jer se pokazalo da druga derivacija ne utječe značajno na funkcioniranje deformabilnog modela, a ukoliko je dužina luka uzeta kao parametar s tada i sama prva derivacija sprječava savijanje tj. izglađuje deformabilni model.

Funkcional potencijalne energije $\mathcal{P}(\mathbf{x})$ definiran je na domeni slike, kao integral funkcije potencijalne energije $P(x, y)$ po krivulji $\mathbf{x}(s)$ (jednadžba (3.4)). Primjer funkcije potencijalne

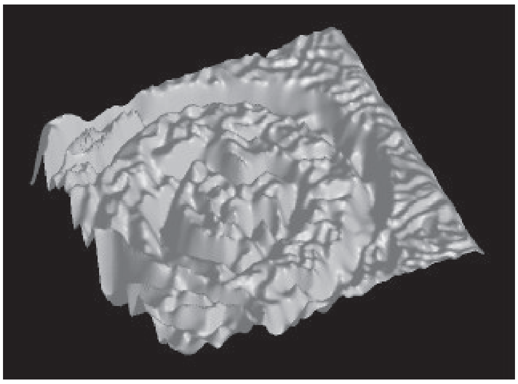

Slika 3.2: Primjer funkcije potencijalne energije $P(x, y)$ izvedene iz slike srca 1.1(a).

energije izvedene iz slike 1.1(a) dan je na slici 3.2.

$$\mathcal{P}(\mathbf{x}) = \int_0^1 P(\mathbf{x}(s))ds \tag{3.4}$$

$\mathcal{P}(\mathbf{x})$ treba imati minimum na granici objekta od interesa na slici. Tipičan oblik funkcije potencijalne energije prikazan je jednadžbom (3.5)

$$P(x, y) = -\omega \left| \nabla \left[G_\sigma(x, y) * I(x, y) \right] \right|^2, \tag{3.5}$$

gdje je ω pozitivni faktor težine, $G_\sigma(x, y)$ je dvodimenzionalna Gaussova funkcija sa standardnom devijacijom σ, ∇ je gradijent operator, a $*$ je dvodimenzionalni operator konvolucije. Konstante α, β i ω određuju ponašanje deformabilnog modela, a njihove vrijednosti trebaju biti unaprijed zadane što predstavlja ograničenje za potpuno automatsku segmentacije.

Problem nalaženja krivulje $\mathbf{x}(s)$, koja minimizira energetski funkcional $\mathcal{E}(\mathbf{x})$, naziva se problem varijacije [34]. Rješenje tog problema mora zadovoljavati i Euler-Lagrangeovu funkciju prikazanu jednadžbom (3.6).

$$\frac{\partial}{\partial s}\left(\alpha \frac{\partial \mathbf{x}}{\partial s}\right) - \frac{\partial^2}{\partial s^2}\left(\beta \frac{\partial^2 \mathbf{x}}{\partial s^2}\right) - \nabla P(\mathbf{x}) = 0 \tag{3.6}$$

Na jednadžbu (3.6) može se gledati kao na jednadžbu ravnoteže sila

$$\mathbf{F}_{int}(\mathbf{x}) + \mathbf{F}_{pot}(\mathbf{x}) = 0 \tag{3.7}$$

gdje su unutarnja i potencijalna (vanjska) sila dana sa

$$\mathbf{F}_{int}(\mathbf{x}) = \frac{\partial}{\partial s}\left(\alpha\frac{\partial \mathbf{x}}{\partial s}\right) - \frac{\partial^2}{\partial s^2}\left(\beta\frac{\partial^2 \mathbf{x}}{\partial s^2}\right) \tag{3.8}$$

$$\mathbf{F}_{pot}(\mathbf{x}) = -\nabla P(\mathbf{x}) \tag{3.9}$$

Dakle korištenje metode minimizacije energije dovodi do već spomenutih unutarnjih i vanjskih sila.

Da bi se našlo rješenje jednadžbe (3.6) deformabilnu konturu treba učiniti dinamičkom na način da se $\mathbf{x}(s)$ tretira kao funkcija vremena t i parametra s tj. $\mathbf{x}(s,t)$. Parcijalna derivacija $\mathbf{x}$ po vremenu tada je jednaka lijevoj strani jednadžbe (3.6).

$$\gamma\frac{\partial \mathbf{x}}{\partial t} = \frac{\partial}{\partial s}\left(\alpha\frac{\partial \mathbf{x}}{\partial s}\right) - \frac{\partial^2}{\partial s^2}\left(\beta\frac{\partial^2 \mathbf{x}}{\partial s^2}\right) - \nabla P(\mathbf{x}) \tag{3.10}$$

Konstanta γ služi izjednačavanju mjernih jedinica s lijeve i desne strane jednadžbe. Kada se rješenje $\mathbf{x}(s,t)$ stabilizira, lijeva strana jednadžbe (3.10) iščezava i dobivamo rješenje jednadžbe (3.6). Takav pristup u kojem parcijalnu derivaciju po vremenu svodimo na nulu, ekvivalentan je gradijentnoj metodi minimizacije u kojoj tražimo lokalni minimum jednadžbe (3.3).

3.2.2 Formulacija dinamičkih sila

U prethodnom odlomku deformabilni model je postavljen kao statički problem u koji je onda uvedena umjetna varijabla t kako bi se minimizirala energija. Ponekad je zgodnije formulirati deformabilni model direktno iz dinamičkog problema pomoću sila. Tada je moguće upotrijebiti općenitije oblike funkcija vanjske sile, a ne samo oblik potencijalne sile.

Prema drugom Newtonovom zakonu, dinamika krivulje $\mathbf{x}(s,t)$ mora zadovoljavati sljedeću diferencijalnu jednadžbu

$$\mu\frac{\partial^2 \mathbf{x}}{\partial t^2} = \mathbf{F}_{prig}(\mathbf{x}) + \mathbf{F}_{int}(\mathbf{x}) + \mathbf{F}_{ext}(\mathbf{x}), \tag{3.11}$$

gdje je μ koeficijent mase, $\partial^2\mathbf{x}/\partial t^2$ predstavlja inerciju, a $\mathbf{F}_{prig}(\mathbf{x})$ je sila prigušenja definirana kao $-\gamma\partial\mathbf{x}/\partial t$ gdje je γ koeficijent prigušenja. U segmentaciji slika najčešće se uzima koeficijent mase μ jednak nuli zbog mogućeg štetnog utjecaja inercije na točnost segmentacije. Naime uslijed inercije deformabilni model ne bi se mogao zaustaviti na granici regije već bi prešao

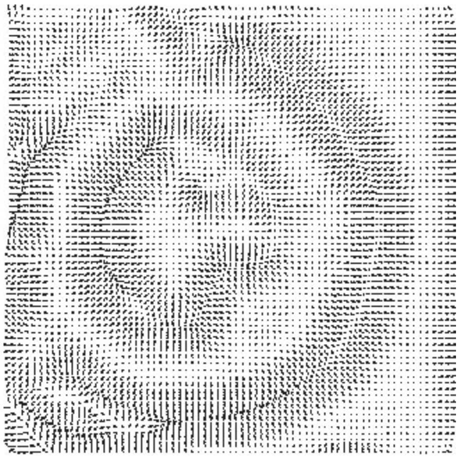

Slika 3.3: Primjer polja sile definiranog vektorskim tokom gradijenta.

preko. Ukoliko se deformabilni model iz nekog razloga ne bi vratio natrag, segmentacija bi bila pogrešna. Dinamika deformabilnog modela tada se može opisati s jednadžbom (3.12).

$$\gamma \frac{\partial \mathbf{x}}{\partial t} = \mathbf{F}_{int}(\mathbf{x}) + \mathbf{F}_{ext}(\mathbf{x}) \tag{3.12}$$

Interna sila $\mathbf{F}_{int}(\mathbf{x})$ ista je kao u (3.8) dok vanjska sila $\mathbf{F}_{ext}(\mathbf{x})$ može ali i ne mora imati oblik potencijalne sile. Često je ukupna vanjska sila zadana kao suma pojedinačnih vanjskih sila od kojih svaka na svoj način doprinosi ispravnoj segmentaciji. Primjer jedne vanjske sile izvedenih iz slike 1.1(a) prikazan je poljem vektora na slici 3.3

3.3 Geometrijski deformabilni modeli

Geometrijske deformabilne modele neovisno su predstavili Caselles et al. [3] i Malladi et al. [16] i oni predstavljaju elegantan način rješavanja najvećeg ograničenja parametarskih deformabilnih modela: mijenjanje topologije. Evolucija ovih deformabilnih modela ovisi o geometrijskim svojstvima a ne o parametrizaciji. Prvi geometrijski deformabilni modeli zasnivali su se na teoriji evolucije krivulja. Nakon njih predstavljeni su geometrijski deformabilni modeli kojima je u osnovi minimiziranje energetske funkcije. Zajedničko svima njima je korištenje level-set metode tako da se u literaturi najčešće susreću pod nazivom level-set deformabilni modeli.

3.3.1 Teorija evolucije krivulja

Teorija evolucije krivulja proučava deformacije krivulja pomoću geometrijskih parametara kao što su vektor normale i zakrivljenost nasuprot parametrima proizašlim iz parametrizacije krivulje. Neka je krivulja zadana kao $\mathbf{x}(s,t) = [x(s,t), y(s,t)]$, gdje s predstavlja proizvoljnu parametrizaciju, a t je vrijeme. Unutra okrenutu jediničnu normalu krivulje možemo označiti sa $\mathbf{n}$, a njenu zakrivljenost s κ [23]. Evoluciju krivulje u smjeru normale tada opisuje jednadžba (3.13).

$$\frac{\partial \mathbf{x}}{\partial t} = V\mathbf{n} \tag{3.13}$$

V određuje brzinu evolucije funkcije pa se naziva naziva funkcijom brzine. Krivulja koja se kreće u proizvoljnom smjeru, uvijek se može reparametrizirati kako bi se dobila jednadžba kretanja (3.13). To je posljedica činjenice da deformacija u smjeru tangente utječe na parametrizaciju krivulje, ali ne i na njen oblik.

Najopsežnije istražene deformacije krivulja su deformacija zakrivljenošću i konstantna deformacija. Deformacija pod utjecajem zakrivljenosti opisana je jednadžbom (3.14),

$$\frac{\partial \mathbf{x}}{\partial t} = \alpha\kappa\mathbf{n} \tag{3.14}$$

gdje je α proizvoljna konstanta. Ovakva jednadžba izglađuje krivulju i sažima je u točku. Jednadžba (3.14) ima sličan učinak kao i unutarnje sile kod parametarskih deformabilnih modela.

Konstantna deformacija opisana je jednadžbom (3.15),

$$\frac{\partial \mathbf{x}}{\partial t} = v_0\mathbf{n} \tag{3.15}$$

gdje je v_0 konstanta koja određuje smjer i brzinu deformacije.

3.3.2 Level-set metoda

Level-set metoda omogućuje promjenu topologije deformabilnog modela i glavni je razlog njezine upotrebe. Level-set metodu predstavili su Osher i Sethian [17].

Level set metoda implicitno predstavlja krivulju, koja se u smjeru normale kreće brzinom V, kao skup točaka iste vrijednosti (engl. *level set*) dvodimenzionalne skalarne funkcije. Ta skalarna funkcija naziva se level-set funkcija i najčešće je definirana na domeni slike, a njena svrha je pružanje implicitne reprezentacije krivulje. Najčešće je krivulja zadana kao nulta razina (engl. *zero-level set*) level-set funkcije. Slika 3.4 prikazuje primjer level-set funkcije i

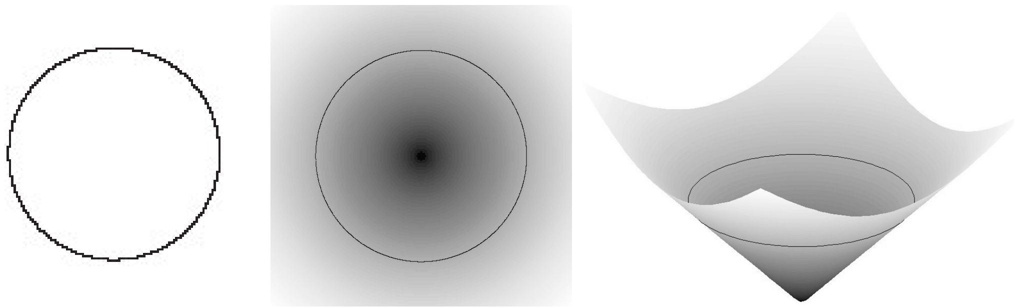

(a) (b) (c)

Slika 3.4: Primjer reprezentacije krivulje pomoću level-set funkcije. (a) Početna krivulja. (b) Level-set funkcija (gledana odozgo) u koju je uključena krivulja kao njena nulta razina. (c) Trodimenzionalni prikaz level-set funkcije s krivuljom kao nultom razinom.

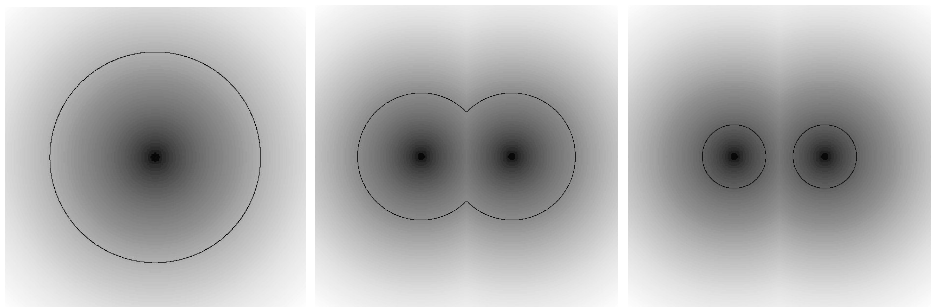

(a) (b) (c)

Slika 3.5: Primjer promjene topologije (cijepanja) krivulje na nultoj razini dok level-set funkcija ostaje glatka.

pripadajuće krivulje (tamnija kružnica). Umjesto deformiranja krivulje kroz vrijeme, level-set metoda deformira krivulju mijenjajući vrijednosti level-set funkcije kroz vrijeme. Dobro svojstvo ovakve formulacije je da nulta razina odnosno krivulja može mijenjati topologiju dokle god je level-set funkcija glatka [16]. Promjena topologije krivulje prikazana je na slici 3.5.

Jednadžbu evolucije krivulje (3.13) sada se može izraziti pomoću level-set funkcije $\Phi(x, y, t)$ i njene nulte razine, krivulje $\mathbf{x}(s, t)$.

$$\Phi[\mathbf{x}(s, t), t] = 0 \tag{3.16}$$

Diferenciranjem jednadžbe (3.16) dobivamo jednadžbu (3.17),

$$\frac{\partial \Phi}{\partial t} + \nabla\Phi \frac{\partial \mathbf{x}}{\partial s} = 0 \tag{3.17}$$

gdje $\nabla\Phi$ predstavlja gradijent od Φ. Ako uzmemo da je funkcija Φ negativna unutar nulte razine, a pozitivna izvana, tada je jedinična normala na level-set krivulji definirana jednadžbom (3.18).

$$\mathbf{n} = -\frac{\nabla\Phi}{|\nabla\Phi|} \tag{3.18}$$

Uvrštavanjem (3.13) i (3.18) u jednadžbu (3.17) dobivamo jednadžbu (3.19).

$$\frac{\partial \Phi}{\partial t} = V|\nabla\Phi| \tag{3.19}$$

Funkcija brzine V najčešće ovisi o zakrivljenosti κ koja se određuje prema jednadžbi (3.20).

$$\kappa = \nabla\frac{\nabla\Phi}{|\nabla\Phi|} \tag{3.20}$$

Jedna od prednosti level-set metode je upravo to što se intrisične geometrijske značajke (normala i zakrivljenost) osnovne krivulje mogu jednostavno odrediti iz level-set funkcije Φ. Odnos jednadžbi (3.19) i (3.16) pružaju osnove za evoluciju krivulje pomoću level-set metode.

Svaki deformabilni model potrebno je, prije korištenja, inicijalizirati zadavanjem početnog stanja krivulje. Kod level-set metode potrebno je prema inicijalnoj krivulji konstruirati skalarnu funkciju Φ. Najčešće se Φ definira kao funkcija udaljenosti s predznakom (3.21).

$$\Phi(\mathbf{p}) = \pm dist(\mathbf{p}, \mathbf{x}(s)) \tag{3.21}$$

Udaljenost se računa od svake točke $\mathbf{p}$ slike (domene funkcije Φ) pa do najbliže točke krivulje $\mathbf{x}(s)$. Predznak ovisi o tome je li točka unutar ($-$) ili izvan ($+$) krivulje.

U samoj level-set formulaciji deformabilnog modela mora biti i komponenta koja predstavlja vezu deformabilnog modela i slike tj. komponenta koja će zaustavljati deformabilni model na granicama regija. Komponenta koja predstavlja vezu između deformabilnog modela i slike uglavnom ima smisla samo na nultoj razini. U jednadžbi (3.19) funkcija brzine V mora sadržavati komponentu koja povezuje deformabilni model i sliku.

Proširivanje funkcije brzine

Ono što se u jednadžbi (3.19) podrazumijeva, a nije toliko očito je da funkcija brzine treba biti definirana za sve razine funkcije Φ, a ne samo za njenu nultu razinu tj. krivulju $\mathbf{x}$. Dakle ne samo da je krivulja ugrađena u funkciju više dimenzije nego je u nju uključena i njena funkcija brzine V. Preciznije bi bilo jednadžbu (3.19) zapisati kao

$$\frac{\partial \Phi}{\partial t} = V_{pr} |\nabla \Phi| \tag{3.22}$$

gdje je V_{pr} polje brzina koje je na nultoj razini jednako danoj brzini V. Novo polje brzine V_{pr} naziva se proširena brzina i ona mora zadovoljavati uvjet da se približavanjem nultoj razini V_{pr} približava brzini V.

$$\lim_{p \to a} V_{pr}(p) = V(a) \tag{3.23}$$

Ovdje je a točka na nultoj razini. Konstruiranje polja brzine V_{pr} nije trivijalno jer određene komponente funkcije brzine V imaju smisla samo na slici tj. samo na nultoj razini funkcije Φ. Tako na primjer zaustavna komponenta g funkcije brzine u jednadžbi (3.24) ima funkciju zaustaviti jedino krivulju na nultoj razini, dok na druge razine funkcije Φ ona ne bi trebala djelovati. Ostale komponente funkcije brzine u (3.24) su zakrivljenost κ i normala $\mathbf{n}$, definirane su na čitavoj domeni funkcije Φ.

Polje brzine V_{pr} treba biti konstruirano tako da funkcija Φ zadrži oblik funkcije udaljenosti od nulte razine (3.21) što je nužno za funkcioniranje level-set metode. Tada je računanje geometrijskih značajki (zakrivljenost i normale) preciznije te omogućava preciznost veću od veličine piksela. Ukoliko bi funkcija Φ izgubila formu funkcije udaljenosti trebalo bi napraviti reinicijalizaciju tj. zaustaviti evoluciju funkcije Φ, naći trenutnu nultu razinu i konstruirati novu funkciju Φ kao funkciju udaljenosti od nove nulte razine. Takva reinicijalizacija zahtjeva određeno vrijeme no ima i neke prednosti koje će biti opisane u sljedećem odlomku.

Istraživači su isprobavali više modela proširivanja funkcije brzine V za različite primjene [26]. Možda najlogičniji pristup predstavili su Malladi et al. [16] gdje se svakoj točki slike dodjeljuje brzina najbliže točke krivulje nulte razine. Mana pristupa je što je traženje najbliže točke krivulje za svaku točku slike računalno zahtjevno pa stoga i nepraktično. Pristup je ilustriran na slici 3.6.

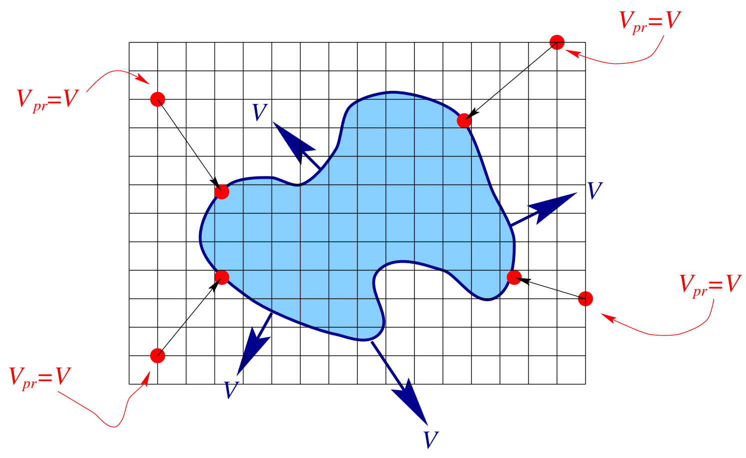

Slika 3.6: Konstruiranje proširene brzine.

Uski pojas proširenja

Glavni nedostatak level-set metoda za deformabilne modele je taj što umjesto računanja položaja za točke jedne krivulje, moramo računati položaj (vrijednost) za svaku točku slike budući je funkcija Φ definirana na cijeloj slici. Sada umjesto za jednu krivulju, proračune vršimo za više krivulja tj. za sve razine funkcije Φ.

Kako je nama stvarno interesantna jedino krivulja na nultoj razini možemo se koncentrirati na njeno usko susjedstvo i sve proračune vršiti samo u uskom području oko nulte razine. Usko područje definirano je kao pojas širine k u čijem se središtu nalazi krivulja nulte razine. Nekoliko je razloga za takav pristup.

- *Brzina*: Vršenje matematičkih operacija na cijeloj domeni u dvodimenzionalnom slučaju traži $O(N^2)$ operacija, a u trodimenzionalnom slučaju $O(N^3)$. N je broj točaka domene (slike ili volumena) uzduž jedne stranice. Za trodimenzionalan slučaj broj potrebnih matematičkih operacija raste jako strmo pa je računanje na cijelom volumenu nepraktično dok se upotrebom uskog pojasa broj potrebnih operacija smanjuje na $O(kN^2)$. Ovdje je k je širina uskog pojasa dok sama nulta razina ima $O(N^2)$ točaka.

- *Proširivanje varijabli*: Kako je prikazano u prethodnom odlomku, Funkciju brzine V potrebno je proširiti na cijelu domenu funkcije Φ, za što nema trivijalnog i praktičnog načina. Upotrebom uskog pojasa takvo proširenje potrebno je napraviti samo za ograničeni broj točaka unutar uskog pojasa.

- *Vremenski korak*: Vremenski korak u diskretnoj realizaciji level-set metode mora zadovoljavati tzv. CLF uvjet (objašnjen u odlomku 3.5.1) koji je zadan maksimalnom brzinom V_{pr} na cijeloj domeni dok je upotrebom uskog pojasa taj uvjet ograničen na točke unutar uskog pojasa.

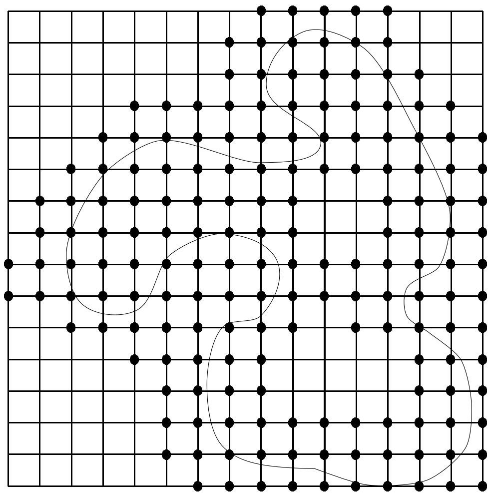

Slika 3.7: Uski pojas oko krivulje predstavljen je crnim točkama.

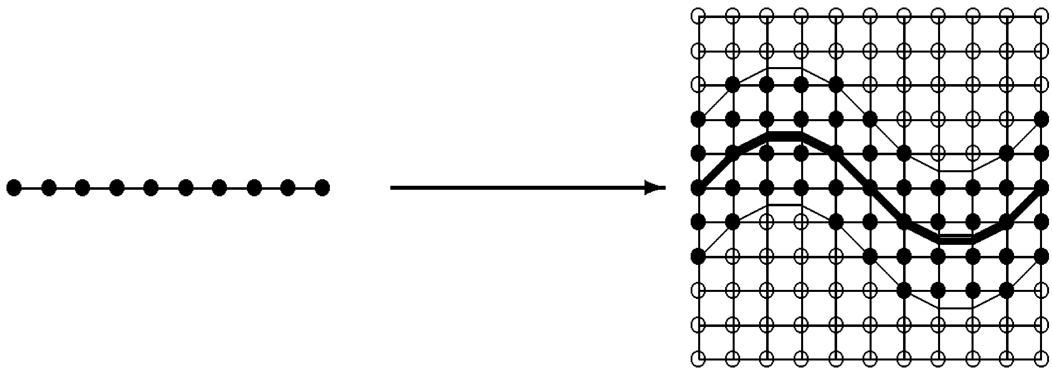

Slika 3.8: Točke uskog pojasa prate se pomoću jednodimenzionalnog vektora.

Na slici 3.7 prikazan je primjer krivulje sa pripadajućim uskim pojasom na diskretnoj domeni. Domena funkcije Φ predstavljena je dvodimenzionalnom matricom dok se za praćenje uskog pojasa koristi jednodimenzionalni vektor (slika 3.8). Korištenje uskog pojasa u više-dimenzionalnom slučaju je jednostavno budući osvježavanje vrijednosti funkcije Φ ne ovisi o strukturi uskog pojasa. Vrijednosti funkcije Φ osvježavaju se samo u uskom pojasu dok se izvan uskog pojasa ne mijenjaju. Kada se nulta razina približi granici uskog pojasa evolucija se zaustavlja i konstruira se novi uski pojas i funkcija Φ bazirani na trenutnom položaju nulte razine. Taj postupak naziva se reinicijalizacija. Kako nulta razina nikada ne dosegne granicu (kraj) uskog pojasa, korištenje uskog pojasa nema negativan utjecaj na njeno kretanje.

Praćenje, kada će jedna točka nulte razine doći do granice uskog pojasa predstavlja dodatno opterećenje na računalne zahtjeve. Kompromisno rješenje, koje se koristi u ovom radu, je da se u uskom pojasu izvrši nekoliko iteracija te se onda uski pojas reinicijalizira, bez obzira koliko se nulta razina približila rubu uskog pojasa. Širina uskog pojasa i broj iteracija međusobno su povezani. Preveliki broj iteracija u odnosu na širinu uskog pojasa doveo bi nultu razinu do ruba uskog pojasa te bi nestalo nulte razine unutar uskog pojasa. Kako se kod reinicijalizacije traži nova nulta razina u samom uskom pojasu takva situacija dovela bi do pogreške u radu algoritma. Premalen broj iteracija, kada nulta razina ne bi došla niti blizu ruba uskog pojasa, za posljedicu bi imao prečestu reinicijalizaciju što bi također nepotrebno povećalo računalne zahtjeve. Određivanje optimalne širine pojasa i broja iteracija ovisi o funkciji brzine V, a preko nje o unutarnjim svojstvima deformabilnog modela i o podacima sa same slike. Stoga je nemoguće unaprijed zadati optimalne vrijednosti širine uskog pojasa i broja iteracija, što predstavlja ograničenje za potpuno automatsku segmentaciju. Broj iteracija predstavlja još jedan dodatni parametar sustava koji otežava potpuno automatsku segmentaciju.

Korištenje uskog pojasa može znatno smanjiti kompleksnost u dvodimenzionalnom slučaju, a posebno u trodimenzionalnom slučaju. Time se kompleksnost geometrijskih deformabilnih modela svodi na razinu kompleksnosti parametarskih deformabilnih modela uz zadržavanje specifičnih prednosti (mijenjanje topologije, preciznost i jednostavna prilagodba na višedimenzionalne slučajeve). Time je omogućeno korištenje geometrijskih deformabilnih modela u „stvarnom vremenu".

Širina pojasa k sada predstavlja dodatnu varijablu koju je potrebno odrediti. Ekstreman je slučaj kada je $k = \infty$. Tada nema reinicijalizacije i pristup postaje ekvivalentan punoj level-set metodi te nema nikakvog ubrzanja. Suprotni ekstrem bio bi širina pojasa $k = 3$ tada bi se praktički nakon svakog koraka trebala vršiti reinicijalizacija. Tada bi vrijeme utrošeno na reinicijalizacije nadmašilo vrijeme potrebno za evoluciju samog deformabilnog modela. Pokazalo se da vrijednost $k = 6$ daje prihvatljiv omjer cijene reinicijalizacije i evolucije.

Moguća kompleksnija varijacija pristupa je da širina uskog pojasa nije fiksna već se ona mijenja ovisno o lokalnoj vrijednosti funkcije brzine V. Tamo gdje je brzina veća je širina uskog pojasa, a tamo gdje je brzina manja, manja je i širina uskog pojasa.

3.3.3 Formulacija bazirana na teoriji evolucije krivulja

Kako je sama deformacija geometrijskog deformabilnog modela riješena level-set metodom, glavnina istraživanja deformabilnih modela odnosi se na dizajn funkcije brzine.

Formulacija deformabilnog modela koju su predložili Casseles et al. [3] i Maladi et al. [16] ima sljedeći oblik.

$$\frac{\partial \Phi}{\partial t} = g(\kappa + v_0)|\nabla \Phi| \tag{3.24}$$

Komponenta κ ima istu ulogu kao unutarnje sile kod parametarskih deformabilnih modela. Zakrivljenost κ izglađuje deformabilni model i svodi ga na konveksan oblik. Vođen samo zakrivljenošću deformabilni model (zatvorena krivulja) skuplja se u točku i nestaje. Često se koristi zakrivljenost κ pomnožena s konstantom ε koja omogućuje podešavanje ponašanja deformabilnog modela. Jednadžba (3.24) tada poprima sljedeći oblik.

$$\frac{\partial \Phi}{\partial t} = g(\varepsilon\kappa + v_0)|\nabla \Phi| \tag{3.25}$$

Konstantna brzina v_0, ovisno o predznaku, određuje hoće li se deformabilni model širiti (*balloon force*) ili skupljati. Ukoliko je željeni smjer evolucije deformabilnog modela prema van, v_0 treba biti negativan. U tom slučaju zakrivljenost κ djeluje u suprotnom smjeru. Ukoliko je željeni smjer kretanja deformabilnog modela prema unutra , v_0 treba biti negativna i time omogućuje segmentaciju nekonveksnih oblika. Za automatsku segmentaciju v_0 treba biti unaprijed određen što otvara pitanje izbora optimalne vrijednosti v_0. Najčešće se koristi najjednostavnija varijanta gdje se uzima $v_0 = \pm 1$.

Faktor g predstavlja zaustavni faktor i jedina je veza između slike i deformabilnog modela. Ukoliko želimo da deformabilni model stane na granici objekta ili regije, g treba biti jednak nuli na granici. Najčešće korišteni oblici zaustavnog faktora dani su u jednadžbama (3.26) i (3.27).

$$g = e^{-|\nabla G_\sigma * I|} \tag{3.26}$$

$$g = \frac{1}{1 + |\nabla G_\sigma * I|^p} \tag{3.27}$$

G_σ je Gaussova maska standardne devijacije σ, a za p se najčešće uzimaju vrijednosti 1 ili 2. Svrha Gaussove maske je izglađivanje i uklanjanje šuma tako da je moguće koristiti i druge, sofisticiranije maske. U jednadžbi (3.27) u nazivniku stoji zbrajanje s jedinicom kako bi se izbjeglo dijeljenje s nulom. Zaustavni faktori ovakvih formi imat će vrijednosti bliske nuli na dijelovima slike koji imaju visoku vrijednost gradijenta što se tipično dešava na granicama regija na slici.

Ovakva formulacija geometrijskog deformabilnog modela i zaustavnog faktora funkcionira dobro ako su na slici dobri uvjeti tj. dobar kontrast. Problem je što se često dešava da je gradijent na granici regije mjestimično malen, bilo zbog visoke prisutnosti šuma, bilo zbog varijacije u svjetlini slike. Tada nastaje efekt slabe granice tj. rupe na granici, gdje zaustavni kriteriji (3.26) i (3.27) neće biti jednaki nuli pa neće moći zaustaviti deformabilni model i on će procuriti u susjednu regiju. Kako se geometrijski deformabilni model u formi (3.24) može kretati samo u jednom smjeru, ili prema unutra ili prema van (ovisno o predznaku v_0), to će rezultirati neispravnom segmentacijom. Taj problem posebno je izražen kod medicinskih slika koje često sadrže šum i varijacije svjetline.

Predloženo je više modifikacija formulacije (3.24), tj. funkcije brzine V iz jednadžbe (3.19), i modifikacije zaustavnog faktora g, koje nastoje umanjiti problem slabe granice, no nijedna formulacija nije u potpunosti riješila taj problem, pogotovo ako se radi o većoj rupi na granici regije. Jedna moguća varijacija formulacije geometrijskog deformabilnog modela prikazana je jednadžbom (3.28).

$$\frac{\partial \Phi}{\partial t} = (\kappa + v_0)|\nabla \Phi| - \mathbf{V_{ext}} \cdot \nabla \Phi \tag{3.28}$$

Vanjska brzina $\mathbf{V_{ext}}$ predstavlja vezu deformabilnog modela s podacima na slici i o njemu ovisi uspješnost segmentacije. Za razliku od (3.24), ovdje deformabilni model ne zaustavljaju sami podaci sa slike već ravnoteža svih komponenti brzine, unutarnja i vanjska. U ovom slučaju moguća je situacija da deformabilni model promijeni smjer kretanja kada $\mathbf{V_{ext}}$ prevlada v_0.

3.3.4 Formulacija bazirana na minimizaciji energije

Caselles et al. [4] predložili su deformabilni model koji povezuje formulaciju minimizacije energije parametarskih deformabilnih modela i formulacije geometrijskih deformabilnih modela baziranih na evoluciji krivulje. Polazište takve formulacije je parametarski deformabilni model koji minimizira energetski funkcional dan jednadžbom (3.29).

$$\mathcal{E}(\mathbf{x}) = \alpha \int_0^1 \left|\frac{\partial \mathbf{x}}{\partial s}\right|^2 ds + \beta \int_0^1 \left|\frac{\partial^2 \mathbf{x}}{\partial s^2}\right|^2 ds - \lambda \int_0^1 |\nabla I(\mathbf{x}(s))|\, ds \tag{3.29}$$

Ovdje su α, β i λ realne pozitivne konstante. Funkcional $\mathcal{E}(\mathbf{x})$ odgovara funkcionalu (3.2) s ponešto različitim zadnjim pribrojnikom koji odgovara vanjskoj energiji u 3.2. Uzmimo da je

$\beta = 0$. To činimo iz razloga opisanih u 3.2.1, i zbog toga što to omogućuje izvođenje relacije između parametarskih deformabilnih modela i geometrijskih deformabilnih modela. Jednadžba (3.29) sada je svedena na oblik (3.30).

$$\mathcal{E}(\mathbf{x}) = \alpha \int_0^1 \left| \frac{\partial \mathbf{x}}{\partial s} \right|^2 ds - \lambda \int_0^1 |\nabla I(\mathbf{x}(s))| \, ds \tag{3.30}$$

Minimizirajući funkcional $\mathcal{E}(\mathbf{x})$ nastojimo smjestiti krivulju $\mathbf{x}(s)$ na točke s najvećom $|\nabla I|$ (ovdje u funkciji detektora ruba), dok istovremeno nastojimo zadržati određenu razinu glatkoće krivulje. Jednadžba (3.30) može se generalizirati uvođenjem općenitog detektora ruba:

$$\begin{aligned} & g : [0, +\infty] \to \mathbb{R}^+ \\ & g(r) \to 0 \quad \text{kada} \quad r \to \infty. \end{aligned} \tag{3.31}$$

Tada $-|\nabla I|$ može biti zamijenjeno s $g(|\nabla I|)^2$, što onda daje općeniti energetski funkcional (3.32).

$$\mathcal{E}(\mathbf{x}) = \alpha \int_0^1 \left| \frac{\partial \mathbf{x}}{\partial s} \right|^2 ds + \lambda \int_0^1 g\left(|\nabla I(\mathbf{x}(s))|\right)^2 ds \tag{3.32}$$

Može se pokazati [4], [1] da je minimizacija funkcionala (3.32) ekvivalentna minimizaciji funkcionala (3.33).

$$L_R = \int_0^1 g\left(|\nabla I(\mathbf{x}(s))|\right) \left| \frac{\partial \mathbf{x}}{\partial s} \right| ds \tag{3.33}$$

Kako je $|\partial \mathbf{x}/\partial s| \, ds = dl$ gdje je dl euklidska dužina luka (ili euklidska metrika), onda dobivamo .

$$L_R = \int_0^{L(\mathbf{x})} g\left(|\nabla I(\mathbf{x}(s))|\right) dl \tag{3.34}$$

Euklidska dužina krivulje $\mathbf{x}$ dana je jednadžbom (3.35).

$$L = \int_0^1 \left| \frac{\partial \mathbf{x}}{\partial s} \right| ds = \oint dl. \tag{3.35}$$

Promatrajući izraze (3.34) i (3.35) vidimo da (3.34) predstavlja novu definiciju dužine u kojoj je euklidski element dužine dl otežan za $g\left(|\nabla I(\mathbf{x}(s))|\right)$. Takav faktor težine sadrži informacije vezane za rubove objekta na slici. Funkcional L_R dakle predstavlja definiciju dužine u

Riemannovom prostoru koji je definiran samom slikom [4]. Detektor ruba g uzet je općenito tako da se u ovakvoj formulaciji može upotrijebiti bilo koji detektor ruba.

Na ovaj način kada pokušavamo detektirati objekt na slici mi nastojimo minimizirati novu definiciju dužine koja uzima u obzir podatke sa slike. Krivulja koja predstavlja minimalan put između dvije točke u prostoru naziva se geodetska krivulja pa ovim pristupom tražimo geodetski krivulju u Riemannovom prostoru. Zbog toga se ovakav tip deformabilnog modela koji nastoji detektirati objekte traženjem geodetske krivulje naziva geodetski deformabilni model ili geodetska aktivna kontura.

Kako bi minimizirali L_R koristi se metoda najbržeg spusta. Stoga treba naći Euler-Lagrangeovu diferencijalnu jednadžbu od (3.33). Dobivena diferencijalna jednadžba koja iz početne krivulje $\mathbf{x_0}$ vodi do lokalnog minimuma L_R prikazana je jednadžbom (3.36).

$$\frac{\partial \mathbf{x}}{\partial t} = g(I)\kappa\mathbf{n} - (\nabla g \cdot \mathbf{n})\mathbf{n} \tag{3.36}$$

Ovdje je κ euklidska zakrivljenost [4], a $\mathbf{n}$ je jedinični vektor normale. Jednadžba (3.36) definira kako se svaka točka krivulje mora kretati da bi se minimizirao L_R. Detektirani objekt tada je dan stabilnim stanjem jednadžbe (3.36), tj. $\partial\mathbf{x}(t)/\partial t = 0$.

Sada još treba na krivulju $\mathbf{x}$ primijeniti level-set metodu. Uvrštavanjem jednadžbe (3.13) u (3.36) dobijemo (3.37).

$$V = g(I)\kappa - \nabla g \cdot \mathbf{n} \tag{3.37}$$

Daljnjim uvrštavanjem u (3.19) dobivamo

$$\frac{\partial \Phi}{\partial t} = g(I)|\nabla\Phi|\kappa - \nabla g \cdot \nabla\phi. \tag{3.38}$$

Izraz (3.38) konačni je izraz za evoluciju geodetskog deformabilnog modela. Desna strana (3.38) predstavlja Euler-Lagrangeov diferencijalnu jednadžbu od (3.33) gdje je krivulja $\mathbf{x}$ predstavljena nultom razinom funkcije Φ. Komponenta $\nabla g \cdot \nabla\phi$ privlači deformabilni model granicama regija i može ga zadržati na granici (∇g usmjerava prema središtu granica). Ilustracija tog djelovanja ilustrirana je na slici 3.9 za jednodimenzionalni slučaj. To je posebno korisno kada postoje (velike) varijacije u vrijednosti gradijenta na granicama regija jer može spriječiti curenje deformabilnog modela kroz rupe na granici.

Formulacija (3.38) nema u sebi uključenu konstantnu brzinu v_0 kao što postoji u formulaciji (3.24). Time je umanjen broj parametara modela što se općenito smatra dobrim. Komponenta

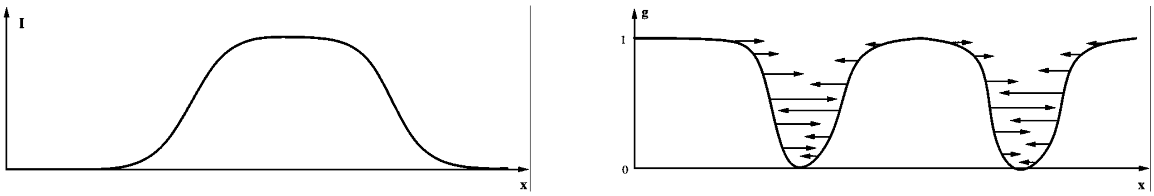

(a) (b)

Slika 3.9: Ilustracija privlačne sile u 1D. (a) I predstavlja originalni signal. (b) detektor ruba g sa silama koje stvara $\nabla g \cdot \nabla \phi$.

$\nabla g \cdot \nabla \phi$ dijelom preuzima funkciju konstantne brzine v_0 i omogućuje detekciju nekonveksnih oblika ako se deformabilni model kreće prema unutra. Konstantna brzina ipak može pomoći u izbjegavanju lokalnih minimuma i u slučaju da se deformabilni model kreće prema van. Konstantna brzina također može ubrzati konvergenciju deformabilnog modela. Stoga u formulaciju (3.38) može biti poželjno dodati konstantnu brzinu koja se može dodati u komponentu $g(I)\kappa|\nabla\Phi|$ koja minimizira površinu unutrašnjosti deformabilnog modela. Uvrštavanjem dobivamo sljedeću modificiranu jednadžbu

$$\frac{\partial \Phi}{\partial t} = g(I)(\kappa + v_0)|\nabla \Phi| - \nabla g \cdot \nabla \phi, \tag{3.39}$$

a krivulja $\mathbf{x}$ na nultoj razini pomiće se tada prema jednadžbi (3.40).

$$\frac{\partial \mathbf{x}}{\partial t} = g(I)(\kappa + v_0)\mathbf{n} - (\nabla g \cdot \mathbf{n})\mathbf{n} \tag{3.40}$$

Jednadžba 3.39 tada minimizira funkcional

$$L_R + v_0 P(\mathbf{x}), \tag{3.41}$$

gdje je $P(\mathbf{x})$ funkcija koja daje površinu unutrašnjosti krivulje $\mathbf{x}$.

Ovaj pristup može se primijeniti i na 3D problem upotrebom 3D gradijenta i zamjenom euklidskog elementa dužine luka (dl) sa površinom. Tada se algoritmom, umjesto minimalne dužine, traži minimalna površina.

3.4 Odnos između parametarskih i geometrijskih deformabilnih modela

3.4.1 Odnos između formulacija dinamičkih sila parametarskih deformabilnih modela i geometrijskih deformabilnih modela baziranih na evoluciji krivulja

Ove formulacije dozvoljavaju upotrebu vanjskih sila koje ne moraju imati oblik potencijalne sile. U ovom odlomku bit će pokazan matematički odnos između dviju formulacija. Radi jednostavnosti uzet ćemo jednostavniju formulaciju dinamičke sile parametarskih deformabilnih modela prikazanu u jednadžbi (3.42).

$$\gamma\frac{\partial \mathbf{x}}{\partial t} = \alpha\frac{\partial^2 \mathbf{x}}{\partial s^2} + \mathbf{F}_p(\mathbf{x}) + \mathbf{F}_{ext}(\mathbf{x}) \tag{3.42}$$

Ovdje je $\mathbf{F}_p = \omega_p \mathbf{n}$ sila pritiska koja pokreće deformabilni model u smjeru normale. Kako bi se jednadžba (3.42) izrazila pomoću level-set formulacije potrebno ju je prebaciti u oblik jednadžbe (3.13). Odgovarajuća forma geometrijskog deformabilnog modela tada se može dobiti pomoću jednadžbe (3.19).

Kako kretanje u smjeru tangente utječe samo na parametrizaciju, a ne i na geometriju krivulje, jednadžbu (3.42) možemo transformirati tako da uzmemo u obzir samo komponente sila i smjeru normala. Ukoliko parametar s krivulje $\mathbf{x}(s,t)$ čini parametrizaciju po duljini krivulje, tada se $\partial^2\mathbf{x}/\partial s^2$ može izraziti preko vektora normale $\mathbf{n}$ i zakrivljenosti κ [23].

$$\frac{\partial^2 \mathbf{x}}{\partial s^2} = \kappa\mathbf{n} \tag{3.43}$$

Jednadžbu (3.42) tada možemo napisati kao

$$\frac{\partial \mathbf{x}}{\partial t} = (\epsilon\kappa + V_p + \mathbf{V_{ext}} \cdot \mathbf{n})\mathbf{n} \tag{3.44}$$

gdje je $\epsilon = \alpha/\gamma$, $V_p = \omega_p/\gamma$ i $\mathbf{V_{ext}} = \mathbf{F_{ext}}/\gamma$. Dijeljenjem s γ dobili smo mjerne jedinice brzine s obje strane jednadžbi. Funkciju brzine možemo napisati kao

$$V = \epsilon\kappa + V_p + \mathbf{V_{ext}} \cdot \mathbf{n} \tag{3.45}$$

te ju uvrstiti u jednadžbu (3.19). Dobivamo sljedeću evolucijsku jednadžbu za geometrijski deformabilni model.

$$\frac{\partial \Phi}{\partial t} = V|\nabla \Phi| = (\epsilon\kappa + V_p)|\nabla \Phi| + \mathbf{V_{ext}} \cdot \nabla \Phi \tag{3.46}$$

Oblik evolucijske jednadžbe (3.46) ekvivalentan je obliku (3.28), što ukazuje na ekvivalentnost dviju formi parametarskih i geometrijskih deformabilnih modela, unatoč njihovim različitim polaznim točkama.

3.4.2 Odnos između formulacija minimizacije energije parametarskih i geometrijskih deformabilnih modela

Ekvivalentnost formulacija minimizacije energije kod parametarskih i geometrijskih deformabilnih modela spomenuta je u odlomku 3.3.4 prilikom izvođenja formulacije geodetskih deformabilnih modela. Geodetski deformabilni modeli temelje se na minimizaciji energetskog funkcionala (3.47).

$$\mathcal{E}(\mathbf{x}) = \int_0^1 g\left(|\nabla I(\mathbf{x}(s))|\right) \left|\frac{\partial \mathbf{x}}{\partial s}\right| ds \tag{3.47}$$

Jednadžba (3.47) predstavlja dužinu definiranu metrikom koja je bazirana na podacima sa slike. Pokazano je u [4] i opširnije u [1] da se minimizacijom te dužine minimizira i energetski funkcional (3.48) za parametarsku formu krivulje.

$$\mathcal{E}(\mathbf{x}) = \alpha \int_0^1 \left|\frac{\partial \mathbf{x}}{\partial s}\right|^2 ds - \lambda \int_0^1 |\nabla I(\mathbf{x}(s))|\, ds \tag{3.48}$$

3.5 Numerička implementacija geometrijskog deformabilnog modela

Level-set formulaciju deformabilnog modela

$$\frac{\partial \Phi}{\partial t} = V|\nabla \Phi| \tag{3.49}$$

potrebno je prebaciti u diskretni oblik kako bi se mogla primijeniti na digitalne, rasterizirane slike. Slijedi opis korištenih aproksimacija.

Kod diskretizacije lijeve strane koristi se razvoj u Taylorov red za Φ u trenutku $t + \Delta t$.

$$\Phi(\mathbf{p}, t + \Delta t) = \Phi(\mathbf{p}, t) + \frac{\partial}{\partial t}\Phi(\mathbf{p}, t + \Delta t)\Delta t + O(\Delta t) \tag{3.50}$$

Ovdje $O(\Delta t)$ predstavlja ostatak odnosno funkciju pogreške koja sadrži potencije od Δt^2 ili više, a Δt predstavlja vremenski korak. Derivaciju po vremenu sada možemo zapisati kao

$$\frac{\partial \Phi}{\partial t} = \frac{\Phi(\mathbf{p}, t + \Delta t) - \Phi(\mathbf{p}, t)}{\Delta t} + O(\Delta t). \tag{3.51}$$

Ovaj oblik poznat je kao diferencija prema naprijed (engl. *forward difference*) u vremenu zato što je korišten Taylorov red s pomakom vremena prema naprijed. Za diferenciju prema naprijed uobičajena je notacija (3.52).

$$D^{+a}u = \frac{u(a + \Delta a) - u(a)}{\Delta a} \tag{3.52}$$

Ovdje je u neka općenita funkcija od a. Za diferenciranje po vremenu koristimo diferencijaciju prema naprijed jer pomoću nje, iz jednadžbe (3.49) možemo izvesti oblik pogodan za iterativno računanje novih (sljedećih u vremenu) vrijednosti funkcije Φ. Iterativni oblik za osvježavanje vrijednosti funkcije Φ prikazan je jednadžbom (3.53).

$$\Phi(\mathbf{p}, t + \Delta t) = \Phi(\mathbf{p}, t) - \Delta t V |\nabla \Phi| \tag{3.53}$$

Uvođenjem notacije $\Phi^n_{i,j} = \Phi(i \cdot \Delta x, j \cdot \Delta y, n \cdot \Delta t)$, jednadžbu (3.53) možemo zapisati kao

$$\Phi^{n+1}_{i,j} = \Phi^n_{i,j} + \Delta t V |\nabla \Phi^n_{i,j}|. \tag{3.54}$$

Postoje još operatori diferencije unazad (engl. *backward difference*) D^- i središnje diferencije (engl. *central difference*) D^0 definirani jednadžbama (3.55) i (3.56).

$$D^{-a}u = \frac{u(a) - u(a - \Delta a)}{\Delta a} \tag{3.55}$$

$$D^{0a}u = \frac{u(a + \Delta a) - u(a - \Delta a)}{2\Delta a} \tag{3.56}$$

Norma gradijenta određena je jednadžbom (3.57).

$$|\nabla \Phi| = \sqrt{\left(\frac{\partial \Phi}{\partial x}\right)^2 + \left(\frac{\partial \Phi}{\partial y}\right)^2} \tag{3.57}$$

Za aproksimaciju prostornih derivacija u ovom radu korištena je središnja diferencija

$$\frac{\partial \Phi}{\partial x} \approx \frac{\Phi(x + \Delta x, t) - \Phi(x - \Delta x, t)}{2\Delta x}. \tag{3.58}$$

gdje je Δx pomak u prostoru. Uz $\Delta x = 1$, jednadžbu (3.57) možemo zapisati u obliku

$$|\nabla \Phi_{i,j}^n| \approx \sqrt{\left(\frac{\Phi_{i+1,j}^n - \Phi_{i-1,j}^n}{2}\right)^2 + \left(\frac{\Phi_{i,j+1}^n - \Phi_{i,j-1}^n}{2}\right)^2}. \tag{3.59}$$

U [26] su predstavljene kompleksnije aproksimacije prostornih derivacija koje zadovoljavaju uvjete entropije i očuvanja. Takve aproksimacije motivirane su konkretnim problemima u teoriji evolucije krivulja koji nisu izraženi kod geometrijskih deformabilnih modela. Djelomično su ti problemi eliminirani čestom reinicijalizacijom kod korištenja uskog pojas u level-set metodi (odlomak 3.3.2).

Za zakrivljenost κ najčešće se uzima srednja zakrivljenost. Formula za računanje srednje zakrivljenosti za dvodimenzionalan slučaj dana je jednadžbom (3.60).

$$\kappa = \frac{\Phi_{xx} - 2\Phi_x \Phi_y \Phi_{xy} + \Phi_{yy}}{(\Phi_x^2 + \Phi_y^2)^{3/2}} \tag{3.60}$$

Ovdje Φ_x predstavlja prvu, a Φ_{xx} drugu derivaciju po x-u. Za trodimenzionalan slučaj koristi se jednadžba (3.61).

$$\kappa = \frac{\Phi_{xx}(\Phi_y^2 + \Phi_z^2) + \Phi_{yy}(\Phi_x^2 + \Phi_z^2) + \Phi_{zz}(\Phi_x^2 + \Phi_y^2) - 2\Phi_x\Phi_y\Phi_{xy} - 2\Phi_x\Phi_z\Phi_{xz} - 2\Phi_y\Phi_z\Phi_{yz}}{(\Phi_x^2 + \Phi_y^2 + \Phi_z^2)^{3/2}} \tag{3.61}$$

U jednadžbama zakrivljenosti također se koristi operator srednje diferencije D^0. Aproksimacija druge derivacije tada ima oblik

$$\frac{\partial^2 \Phi}{\partial p^2} \approx \frac{\Phi(p + h, t) - 2\Phi(p, t) + \Phi(p - h, t)}{4h}. \tag{3.62}$$

Korištenje istog operatora diferencije kod zakrivljenosti i kod norme gradijenta pogodno je jer bi u protivnom mogla nastati velika pogreška na desnoj strani jednadžbe (3.49) kod vrlo malih zakrivljenosti.

3.5.1 CLF uvjet stabilnosti

Važan problem kod svake numeričke metode je stabilnost, odnosno pitanje što se dešava s malom greškom u početnim podacima. Metoda bi trebala biti formulirana na takav način da mala greška u početnim podacima ne može nekontrolirano rasti. Precizniju analizu stabilnosti pruža Fourierova analiza stabilnosti. Uvjet stabilnosti koji jednadžba (3.49) mora zadovoljavati naziva se Courant-Friedrichs-Levy uvjet ili skraćeno CFL uvjet [26], [31]. Njime je određeno da svaka točka funkcije Φ ne bi trebala preći više od jedne udaljenosti između susjednih točaka na domeni (slici). Uvjet je prikazan jednadžbom (3.63).

$$\max(V)\Delta t \leq \Delta x \tag{3.63}$$

Maksimum se odnosi na cjelu domenu tj., na brzine na svakoj točki slike. Da bi uvjet (3.63) bio zadovoljen potrebno je odrediti odgovarajuću vrijednost vremenskog koraka Δt. Prostorni korak unaprijed je zadan i najčešće iznosi 1 dok je funkcija brzine V definirana unaprijed zadanim parametrima i samom slikom. Maksimalnu brzinu potrebno je odrediti na čitavoj domeni. Domena osnovne level-set metode je cjela slika dok se upotrebom uskog pojasa domena svodi samo na odabrani uski pojas. Omjer $\Delta t/\Delta x$, kada $\Delta x \to 0$ i $\Delta t \to 0$, naziva se CLF broj i određen je maksimalnim mogućim tokom informacija.

U ovom radu nije vršena automatska procjena maksimalne dozvoljene vrijednosti vremenskog koraka već je metodom pokušaja i pogreški određena dovoljno mala vrijednost Δt da ne dođe do numeričke nestabilnosti, ali niti pretjerano mala što bi nepotrebno usporilo metodu. Takav pristup omogućila je uniformnost ulaznih podataka (CT slike abdomena).

Poglavlje 4

Segmentacija aneurizme abdominalne aorte

4.1 Aneurizme abdominalne aorte

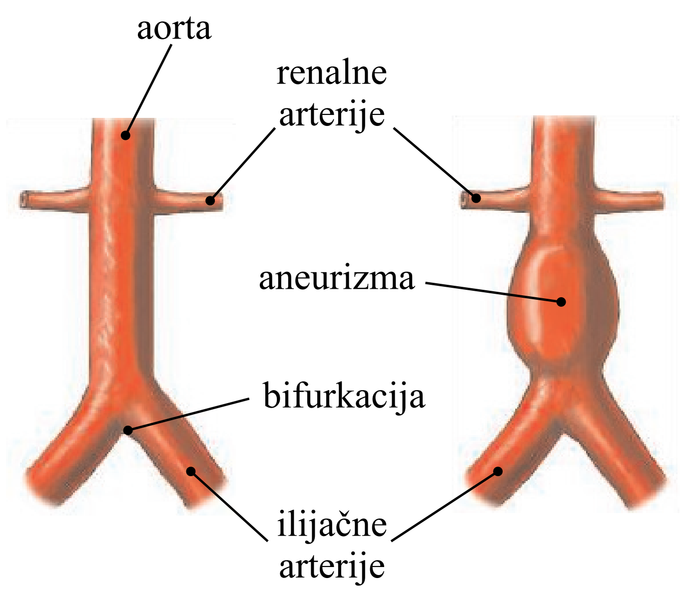

Slika 4.1: Ilustracija zdrave abdominalne aorte (lijevo) i abdominalne aorte s aneurizmom (desno).

Aneurizma abdominalne aorte je vaskularni poremećaj aorte u području abdomena ispod renalnih arterija, a iznad bifurkacije (slika 4.1), koji zahvaća 2% ljudi starijih od 65 godina. Poremećaj se očituje kroz povećanje abdominalne aorte uslijed oslabljenog zida aorte. Uzrok aneurizme abdominalne aorte može biti degenerativno, upalno, mijotičko oboljenje ili arterioskleroza. Ukoliko se aneurizma ne liječi ona se povećava čime se povećava rizik od prsnuća abdominalne aorte. 50% aneurizma abdominalne aorte otkriva se slučajno. Kod 9% pacijenata, aneurizma abdominalne aorte će puknuti uslijed oslabljenog zida abdominalne aorte. $70 - 90\%$ pacijenata sa puknućem aneurizme abdominalne aorte umire.

U dijagnostici aneurizme abdominalne aorte pokazalo se da je promjena volumena dobar pokazatelj rizika pucanja aneurizme. U svijetu se godišnje izvede otprilike $100\,000$ kirurških operacija aneurizme abdominalne aorte. Otvorena operacija je kao metoda, vrlo invazivna i povezana je s visokim vjerojatnostima komplikacija i smrtnosti. Oko 30% svih operacija aneurizme abdominalne aorte radi se endovaskularnom metodom koja je minimalno invazivna. Radi se o endovaskularnom postavljanju proteze (engl. *aortic stent graft*) unutar abdominalne aorte u području aneurizme kako bi se ojačao zid aorte. Čitav zahvat obavlja se kroz mali otvor na pacijentovom bedru. Kako bi zahvat bio uspješno izveden potrebno je odabrati protezu odgovarajuće veličine i oblika, zbog čega je potrebno znati oblik i veličinu abdominalne aorte u području aneurizme. Nakon tretmana postoji mogućnost sužavanja aneurizme, nastavaka rasta aneurizme, oštećenja ili zamora materijala proteze, pomicanja proteze koje onda može prouzročiti začepljenje ili pucanje abdominalne aorte. Zbog toga je potrebno redovito i pažljivo kontrolirati stanje pacijenta nakon operacije.

Za samo dijagnosticiranje, pripremu kirurškog zahvata te praćenje stanja nakon operacije potrebno je snimanje abdominalne aorte. Aneurizma abdominalne aorte može biti snimljena klasičnim rengenskim snimanjem abdomena, ultrazvukom, kompjuterskom tomografijom ili magnetskom rezonancijom. Najčešće upotrebljavana metoda, koja je trenutni zlatni standard, je angiografija kompjuterskom tomografijom (CTA). Primjer CTA presjeka zdrave aorte prikazan je na slici 4.2, a primjer aneurizme prikazan je na slici 4.3.

Nakon snimanja, standardna procedura uključuje ručno ocrtavanje (segmentaciju) aorte na svim CT presjecima u kojima se nalazi. Nakon segmentacije svih presjeka jednostavno se može izračunati volumen aneurizme. Ručna segmentacija je vremenski vrlo zahtjevna pa iskusnom operatoru treba oko 30 minuta za jednog pacijenta. Rezultati ručne segmentacije često variraju kod istog operatera i između različitih operatera. Očekuje se da bi automatska segmentacija omogućila kraće vrijeme analize i povećala ponovljivost rezultata.

U poglavlju 7 često se spominju određeni dijelovi aorte koji su radi lakšeg razumijevana prikazani na slici 4.4. Na slici aorte možemo razlikovati dva dijela: unutrašnjost aorte (slika 4.4(b)) i zid aorte (slika 4.4(c)). Pojam „regija aorte", ovisno o tome dali se segmentira unutarnji ili vanjski rub, označava samo unutrašnjost aorte (slika 4.4(b)), odnosno unutrašnjost i

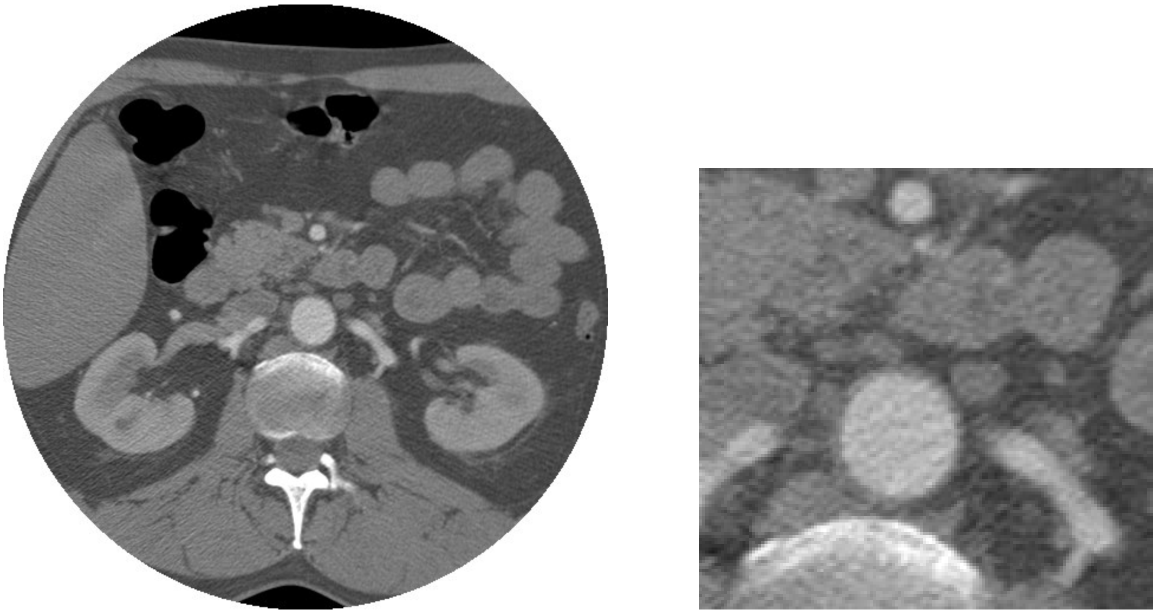

(a) (b)

Slika 4.2: (a) CTA presjek na kojem je zdrava abdominalna aorta. (b) Uvećana aorta.

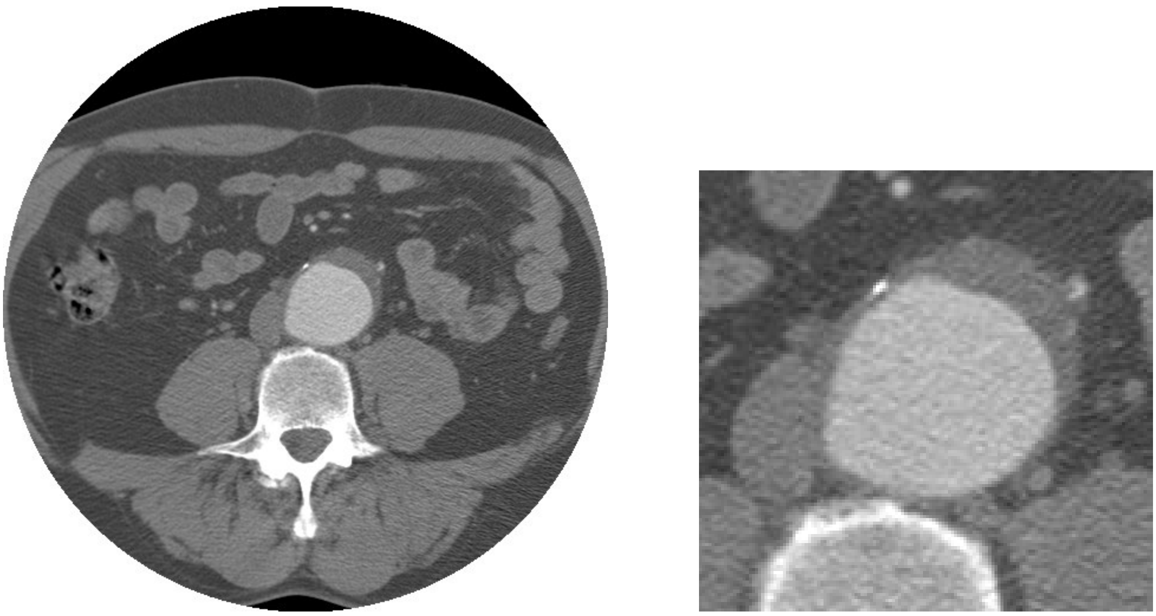

(a) (b)

Slika 4.3: (a) CTA presjek na kojem je aneurizma abdominalne aorte. (b) Uvećana aorta

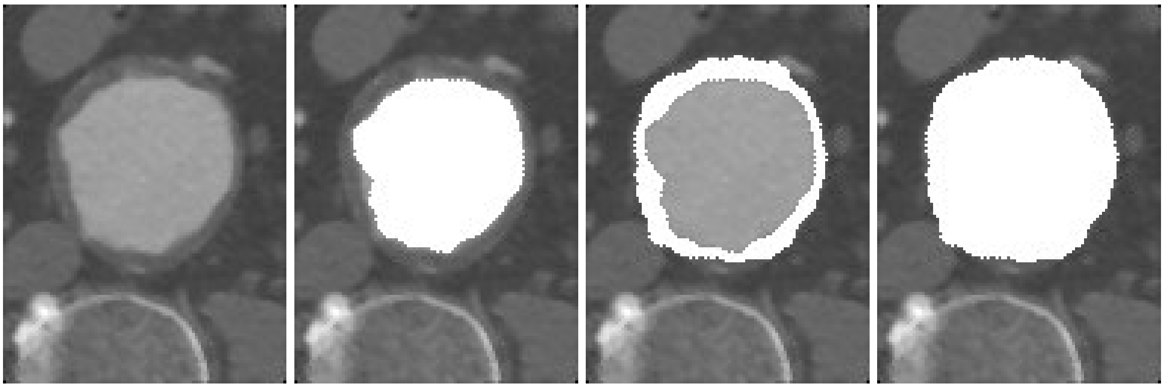

(a) Dio CT presjeka na kojem se nalazi aorte (b) Unutrašnjost aorte (c) Zid aorte (d) Regija aorte

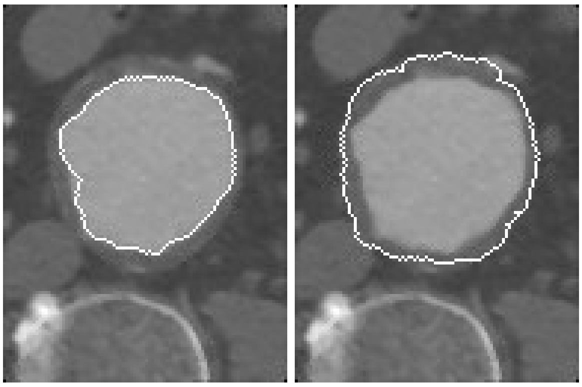

(e) Unutarnji rub aorte (f) Vanjski rub aorte

Slika 4.4: Dijelovi aorte često spominjani u radu (označeno bijelom bojom)

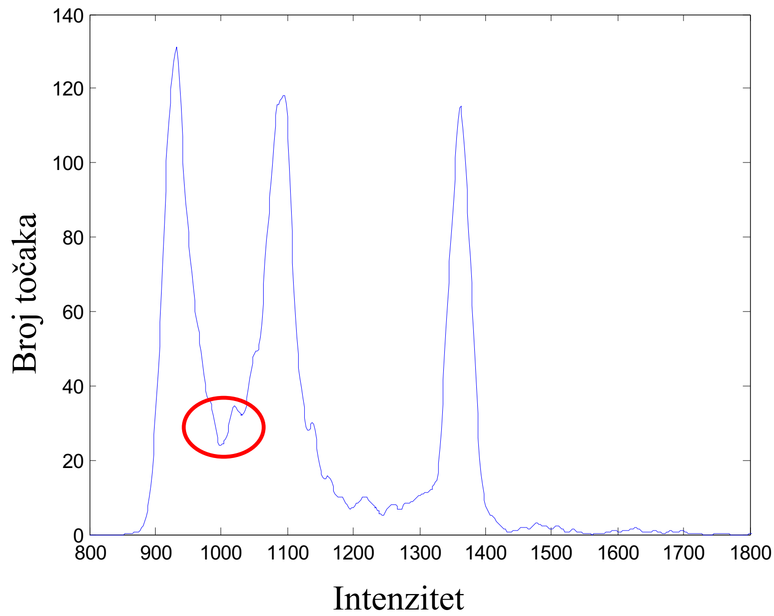

Slika 4.5: Histogram okolice aorte s označenim karakterističnim lokalnim minimumom

zid aorte zajedno (slika 4.4(d)). Kod računanja volumena aneurizme abdominalne aorte koristi se površina regije aorte dobivena segmentacijom vanjskog ruba aorte prikazana slikom 4.4(d). Unutarnji rub aorte (slika 4.4(e)) omeđuje unutrašnjost aorte i zid aorte iznutra, dok vanjski rub aorte omeđuje zid aorte izvana (slika 4.4(f)).

Sve metode segmentacije opisane u poglavlju 7 zahtijevaju od operatera da ručno odabere dio CT volumena u kojem se nalazi cijela aorta. Taj dio ukupnog CT volumena skraćeno se naziva VOI (engl. *Volume Of Iterest*), a slike 4.2(b) i 4.3(b) predstavljaju dijelove presjek koje ulaze u VOI. Sve CT snimke korištene u ovom radu potječu s istog CT uređaja tako da sve snimke imaju određene sličnosti. Jedna od sličnosti je i karakterističan oblik histograma VOI regije. Primjer takvog histograma prikazan je slikom 4.5. Na slici je označen i karakterističan lokalni minimum histograma koji se nalazi na razgraničenju intenziteta regije abdominalne praznine i regije zida aorte. Taj lokalni minimum pojavljuje se na svim CT snimkama i on se koristi u metodama segmentacije aorte opisanim u poglavlju 7.

4.2 Pregled problema i postojećih istraživanja

Kao rezultat segmentacije aneurizme abdominalne aorte, ovisno o primjeni, može se tražiti vanjski rub aorte (granica zida aorte i abdominalne šupljine), unutarnji rub (granica zida aorte i unutrašnjeg krvotoka aorte) ili oboje. Segmentacija unutrašnjeg ruba ne predstavlja veći problem zahvaljujući kontrastnom sredstvu u krvotoku aorte. Zbog kontrastnog sredstva koje dobro upija rendgensko zračenje, unutrašnjost aorte vidi se kao svjetla regija koja se jasno razlikuje od zida aorte. Zahvaljujući dobrom kontrastu i različitim intenzitetima dviju susjednih regija, segmentacija unutarnjeg ruba aorte ne predstavlja problem. Kod tako dobrih uvjeta veliki broj metoda segmentacija dati će dobre rezultate.

Kod segmentacije vanjskog ruba aorte uvjeti su lošiji te se pokazalo da segmentacija vanjskog ruba aorte u području aneurizme predstavlja težak problem. Teškoće stvara činjenica da se vanjski rub aneurizme naslanja (uslijed širenja) na susjedna tkiva koja imaju istu optičku gustoću za rendgenske zrake pa na CT slikama imaju isti intenzitet. Tada je teško razlučiti granicu između aneurizme i okolnog tkiva, dok s druge strane druge susjedne strukture, koje imaju različiti intenzitet, stvaraju jasno vidljivu i „jaku" granicu. Ovom problemu pridonosi i ograničena preciznost CT uređaja. Promjer aneurizme može se između CT presjeka (opet preciznost) znatno mijenjati što također otežava automatsku segmentaciju. Svjetlina i tekstura zida aorte također varira. Unutar samog zida aorte ponekad se javljaju i kalcifikacije (nakupine kalcija) koje imaju visoki intenzitet na slikama te remete homogenost zida aorte, što dodatno komplicira segmentaciju. Primjeri problematičnih struktura koje se pojavljuju kod aneurizme abdominalne aorte prikazani su na slici 4.6. Kod slika snimljenih nakon ugradnje proteze uvjeti su još gori. Proteze su cijele metalne ili imaju metalne dijelove. Metal jako dobro upija rendgensko zračenje, tako da dolazi do zasićenja pa se kod računalne rekonstrukcije slika javljaju artefakti u vidu svijetlih i tamnih pruga koje se radijalno prostiru oko metalnog dijela. Jačina utjecaja artefakata uvelike varira i stvara velike probleme kod automatske segmentacije.

Kod loših uvjeta na slici logičan korak je uključivanje znanja (oblik, položaj itd.) u algoritam segmentiranja kako bi se suzio skup mogućih rezultata segmentacije (poželjno je sužavanje prema točnom rješenju). I takav pristup ima problema kod segmentacije vanjskog ruba aneurizme jer oblik aneurizme jako varira među pacijentima i na slikama istog pacijenta. Budući je aneurizma patološki poremećaj, jedino „sigurno" znanje koje posjedujemo o njenom obliku je da je oblik drugačiji od poznatog oblika zdrave aorte. Ta spoznaja ne može značajno suziti skup mogućih rješenja.

Uzevši u obzir iznesene činjenice ne čudi da je više radova objavljeno o segmentaciji unutarnjeg ruba aorte [12], [33]. Rezultati segmentacije unutarnjeg ruba aorte koriste se za vizualizaciju i za odabir odgovarajuće proteze. U ovu skupinu radova mogu se uvrstiti i radovi koji segmentiraju samu protezu [8], gdje oblik proteze otprilike odgovara unutarnjem rubu aorte, ali se kod segmentacije osim intenziteta točaka unutrašnjosti aorte koriste i metalni dijelovi

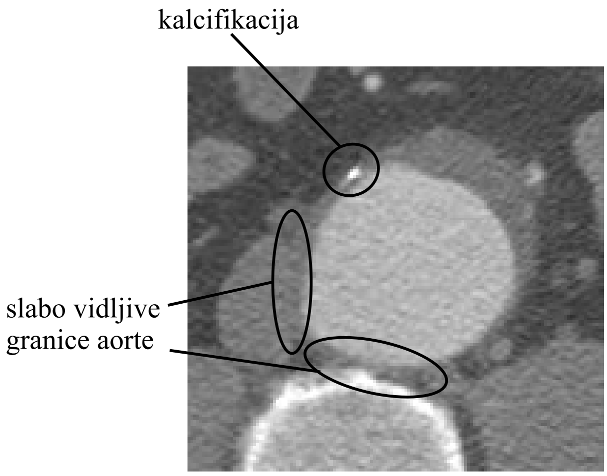

Slika 4.6: Problematične strukture koje se pojavljuju kod aneurizme abdominalne aorte.

proteze.

Literatura vezana za segmentaciju vanjskog ruba je rijetka te slijede kratki opisi dvaju objavljenih radova.

4.2.1 Pristup I

De Bruijne et al. su u [9] osmislili metodu koja koristili vrstu deformabilnih modela nazvanu *Active Shape Model* (ASM). Pristup koristi statističke modele oblika i rasporeda intenziteta na rubu. Korištene su također CTA slike aneurizme abdominalne aorte, a segmentacija se obavlja presjek po presjek.

U navedenom radu korištena je model distribucije točaka (engl. *Point Distribution Model*, PDM) za opis oblika aorte, gdje je kontura predstavljena kao vektor $\mathbf{x}$ koji sadrži koordinate unaprijed definiranog broja (n) markera koji su definirani kao ekvidistantne točke na krivulji. Pomicanjem markera ta krivulja se poravnava na rub aorte.

$$\mathbf{x} = (x_1, y_1, x_2, y_2, \ldots, x_n, y_n,) \tag{4.1}$$

Kako bi se smanjila dimenzionalnost podataka korištena je analiza glavnih komponenti (engl. *Principle Component Analysis*, PCA). Iz skupa vektora za treniranje određuje se srednji oblik prema jednadžbi (4.2).

$$\bar{\mathbf{x}} = \frac{1}{s}\sum_{i=1}^{s}\mathbf{x_i} \tag{4.2}$$

Pomoću skupa vektora za treniranje i dobivenog vektora srednjeg oblika određuje se kovarijacijska matrica $\mathbf{S}$, dimenzija $2n \times 2n$, prema jednadžbi (4.3).

$$\mathbf{S} = \frac{1}{s-1}\sum_{i=1}^{s}(\mathbf{x_i} - \bar{\mathbf{x}})(\mathbf{x_i} - \bar{\mathbf{x}})^T \tag{4.3}$$

Za kovarijacijsku matricu $\mathbf{S}$ računaju se vlastiti vektori ϕ_i i odgovarajuće vlastite vrijednosti λ_i. Ako sve vlastite vektore uzmemo kao stupce matrice $\mathbf{P} = [\phi_1, \phi_2, \ldots, \phi_{2n}]$, onda se svaki oblik krivulje može opisati jednadžbom (4.4).

$$\mathbf{x} = \bar{\mathbf{x}} + \mathbf{Pb} \tag{4.4}$$

Vektor $\mathbf{b}$ sadržava parametre modela kojih u ovom slučaju ima $2n$, koji se mijenjaju kako bi model mijenjao oblik. Iz skupa svih vlastitih vektora ϕ_i, uzima se manji broj (t) vlastitih vektora kojima odgovara t najvećih vlastitih vrijednosti λ_i. Odabrani vlastiti vektori u sebi sadržavaju najveći stupanj varijacije oblika trenažnih vektora oblika. Odabrani vektori čine stupce nove matrice $\mathbf{M}$ $(2n \times t)$ pomoću koje se sada u jednadžbi (4.5) aproksimiraju svi novi oblici krivulja.

$$\mathbf{x} \approx \bar{\mathbf{x}} + \mathbf{Mb} \tag{4.5}$$

Vektor $\mathbf{b}$ sada sadržava t parametara modela. Testirane su tri varijante određivanja vrijednosti parametara u vektoru $\mathbf{b}$.

Prva varijanta koristi originalni ASM algoritam gdje se novi položaj svakog markera određuje prema profilu raspodjele intenziteta g_i na normali krivulje koja prolazi kroz dotični marker. Promatra se određeni broj točaka s jedne i s druge strane krivulje. Kako bi se umanjio utjecaj globalnog variranja intenziteta, za g_i se uzimaju normalizirana vrijednosti prve derivacije intenziteta u smjeru normale, a ne same vrijednosti intenziteta. Za vrijednosti intenziteta markera pretpostavljena je Gaussova distribucija te se uz pomoć utreniranog srednjeg profila $\bar{\mathrm{g}}$ i kovarijacijske matrice S_g definira funkcija udaljenosti (kvadrat Mahalanobisove udaljenosti) prikazana jednadžbom (4.6).

$$f(\mathrm{g}_s) = (\mathrm{g}_s - \bar{\mathrm{g}})^T \mathbf{S}_g^{-1}(\mathrm{g}_s - \bar{\mathrm{g}}) \tag{4.6}$$

Mahalanobisova udaljenost normirana je na standardnu devijaciju distribucije tako da varijabilnost populacije ne utječe na udaljenost. Minimiziranjem funkcije udaljenosti $f(\mathbf{g}_s)$ maksimizira se vjerojatnost da profil $\mathbf{g}_s$ dolazi iz trenažne distribucije profila. Trenažna distribucija za svaki marker dobivena je iz raspodjela intenziteta za dotični marker na svim presjecima nekoliko CT volumena (nekoliko pacijenata). Minimizacija se postiže odgovarajućim promjenama elemenata vektora $\mathbf{b}$.

U drugoj varijanti, kao mjera sličnosti korištena je normalizirana kroskorelacija N_{cc}.

$$N_{cc} = \frac{\sum_{x=-k}^{k} I_{s-1}(x) \cdot I_s(x)}{\sqrt{\sum_{x=-k}^{k} I_{s-1}(x)^2 \cdot \sum_{x=-k}^{k} I_s(x)^2}} \tag{4.7}$$

Ovdje je I_s vrijednost intenziteta točke profila trenutnog markera, a I_{s-1} je vrijednosti intenziteta točke profila ekvivalentnog markera na referentnom presjeku. Referentni presjek za svaki presjek je njemu susjedni, prethodno segmentirani presjek. Svaki profil ima k točaka s obje strane krivulje. Mijenjanjem vrijednosti elemenata vektora $\mathbf{b}$ ovdje se nastoji maksimizirati N_{cc}.

U trećoj varijanti korištena je funkcija $f(x)$ (4.8) koja nastoji iskoristiti i informacije sadržane u gradijentu slike koko bi privukla markere ka izraženim rubovima na slici i time povećala točnost segmentacije.

$$f(x) = |I(x+1) - I(x-1)| \cdot N_{cc} \tag{4.8}$$

Gledaju se samo vrijednosti gradijenta uzduž normale krivulje pa varijabla x određuje položaj točke na pravcu normale. Uz to, u trećoj varijanti definirana je i *funkcija kazne* koja isključuje pojavu regija niskog intenziteta unutar krivulje (unutar aorte).

Kao referentna krivulja kod segmentacije jednog presjeka, kod sve tri varijante, koristi se krivulja dobivena segmentacijom prethodnog presjeka. Svaka od tri predložene metode zahtjeva ručnu segmentaciju aorte na jednom CT presjeku. Ručno se segmentira presjek u sredini CT volumena te se segmentacija nastavlja u dva smjera: ispod i iznad ručno segmentiranog presjeka. Potrebno je da ručno segmentirani presjek bude u sredini volumena jer se greške u segmentaciji akumuliraju kroz presjeke tako da će presjek koji je najudaljeniji od inicijalnog imati i najveću pogrešku.

Kod prve varijante koja koristi funkciju $f(\mathbf{g}_s)$ potreban je skup trenažnih presjeka pomoću kojih se definira distribucija za svaki marker. Ovaj pristup dao je najlošije rezultate. Kod druge varijante koja koristi kroskorelaciju kao mjeru sličnosti dobiveni su nešto bolji rezultati. Ovdje se kroskorelacija radi za svaki marker s ekvivalentnim markerom iz prethodno segmentiranog, susjednog presjeka. Kod treće varijante koja uz kroskorelaciju koristi i gradijent slike i *funkciju kazne*, dobiveni su najbolji rezultati.

Na temelju rezultata koje su prezentirali De Bruijne et al. u [9] može se primijetiti sljedeće:

- U prvoj varijanti metode (4.6) nastojalo se iskoristiti znanje o distribuciji intenziteta u okolini ruba aorte. Uključivanje znanja je logičan korak kada se pokaže da općenitiji algoritmi segmentacije ne funkcioniraju. Za svaki marker definirana je funkcija distribucije određena na temelju više presjeka iz nekoliko CT volumena. Ovaj pristup dao je najlošije rezultate. To nije toliko čudno ako se uzme u obzir da se duž aorte distribucija piksela s vanjske strane mijenjaju kako se izmjenjuju susjedna tkiva i organi duž aorte. Zbog toga nema smisla konstruirati distribuciju intenziteta na svim presjecima već eventualno samo na ekvivalentnim presjecima iz više volumena. Ovdje bi se pojavio problem određivanja ekvivalentnih presjeka u različitim volumenima (različiti pacijenti). Na izgled distribucije utječe i debljina aneurizme zbog koje su susjedni organi bliži rubu aorte. Distribucija intenziteta unutar aorte konzistentna je za zdravu aortu dok kod aneurizme postaje nepredvidljiva. Sama aneurizma, dakle, onemogućava funkcionalnost određivanja distribucije intenziteta bilo za sve presjeke bilo samo za ekvivalentne.

- Uspješnijom se pokazala upotreba kroskorelacije intenziteta i to među susjednim presjecima. Ovdje se koristi pretpostavka da se izgled, položaj i susjedstvo aorte malo mijenjaju između dva susjedna presjeka. Ta pretpostavka je istinita u većini slučajeva, a iznimka su presjeci gdje aneurizma počinje, odnosno završava. Na tim presjecima moguće su nagle promjene oblika aorte. Ovo je još jedan razlog za odabir inicijalnog presjeka u sredini aneurizme, jer će se eventualne greške na kraju i na početku aneurizme akumulirati i propagirati dalje od aneurizme što je manje važno. Nagle promjene oblika u području aneurizme, iako vrlo rijetke, ipak su moguće te bi prouzročile pogreške u segmentaciji aneurizme.

- Najboljim se pokazao pristup koji objedinjuje najviše kriterija za segmentaciju (detekcija rubova, kroskorelacija intenziteta i funkcija kazne). Iz ovoga se može naslutiti da ovako složeni problem nije moguće riješiti relativno jednostavnim i robusnim algoritmom temeljenim na jednostavnim geometrijskim ili statističkim pravilima. Bolji rezultati postižu se kombiniranjem više takvih pravila/znanja. To donekle odgovara ručnoj segmentaciji gdje operater ocrtava aortu uz pomoć same slike, ali i iskustva i znanja o obliku aorte, poznavanja susjednih tkiva i organa te odgovarajućih fizikalnih modela.

4.2.2 Pristup II

Istraživanje prezentirano u ovom radu, nastavak je istraživanja na segmentaciji aneurizme abdominalne aorte opisanog u [25]. Slijedi kratak pregled te metode segmentacije. Osnovna ideja metode kojom se ona bori s problemima segmentacije vanjskog ruba aorte, može se sažeti ovako: *Ako se odabere početni položaj deformabilnog modela blizu vanjskog ruba aorte, te se ograniči kretanje deformabilnog modela, metoda neće moći puno pogriješiti.*

U navedenom istraživanju korišten je parametarski deformabilni model (3.2) za segmentaciju vanjskog ruba aorte. Sama aorta je trodimenzionalni objekt pa se početna ideja bila upotreba trodimenzionalnog deformabilnog modela. Tada se vanjska granica aorte može predstaviti određenim brojem točaka T na površini aorte. Koordinate svake točke T funkcije su dvije varijable u i v, prema jednadžbi (4.9).

$$T(u,v) = [x(u,v), y(u,v), z(u,v)]^T\,,\ u = 1,\dots,N_U,\ v = 1,\dots,N_V \tag{4.9}$$

Točke T čine deformabilni model te segmentacijski algoritam pomiče te točke od njihovog inicijalnog položaja prema granici aorte. Zbog karakterističnog cjevastog izgleda aorte, prihvatljivo je zabraniti kretanje točaka modela između CT presjeka, odnosno točke koje se nalaze u jednom presjeku mogu se kretati samo po tom presjeku. Tada se uzima da varijabla v predstavlja broj trenutnog presjeka odnosno z koordinatu. Točke T koje se nalaze u jednom presjeku tada definiraju krivulju koja je parametrizirana parametrom u. Izraz (4.9) se tada pojednostavljuje na:

$$T(u,v) = [x(u,v), y(u,v), v]^T\,,\ u = 1,\dots,N_U,\ v = 1,\dots,N_V. \tag{4.10}$$

Jednadžba kretanja (3.10) deformabilnog modela koja minimizira energetsku funkcije oblika (3.2), za trodimenzionalni slučaj poprima sljedeći oblik.

$$\frac{\partial T}{\partial t} - \omega_{01}\frac{\partial^2 T}{\partial u^2} - \omega_{10}\frac{\partial^2 T}{\partial v^2} - \omega_{02}\frac{\partial^4 T}{\partial u^4} - \omega_{20}\frac{\partial^4 T}{\partial v^4} - 2\frac{\partial^4 T}{\partial u^2 \partial v^2} = F(T) \tag{4.11}$$

Ovdje su ω_{ij} težinski koeficijenti, a $F(T)$ predstavlja vanjske sile. Diskretizacijom jednadžbe (4.11) dobije se oblik jednadžbi za određivanje novih koordinata točaka (4.12) koji je pogodan za iterativno izvršavanje na računalu.

$$\begin{aligned}\mathbf{x}^k &= (\mathbf{I} + \tau\mathbf{M})^{-1}\left[\mathbf{x}^{k-1} + \tau F_x(\mathbf{T}^{k-1})\right]\\ \mathbf{y}^k &= (\mathbf{I} + \tau\mathbf{M})^{-1}\left[\mathbf{y}^{k-1} + \tau F_y(\mathbf{T}^{k-1})\right]\end{aligned} \tag{4.12}$$

Ovdje je τ korak diskretizacije, $\mathbf{M}$ je matrica čvrstoće koja opisuje međusobne interakcije između točaka modela a čiji su elementi funkcija konstanti ω_{ij} , a F_x, odnosno F_y su vanjske sile koje djeluju na deformabilni model u x, odnosno y smjeru.

Pojednostavljivanjem se utjecaj matrice $(\mathbf{I}+\tau\mathbf{M})^{-1}$ može nadomjestiti konvolucijom s dvije jezgre (4.13) koje vrše izglađivanje u samoj krivulji $\mathbf{H}_1$ i između krivulja na susjednim presjecima $\mathbf{H}_2$.

$$\begin{aligned} \mathbf{H}_1 &= [k_1, 5k_1, 1-8k_1, 5k_1, k_1] \\ \mathbf{H}_2 &= [k_2, 5k_2, 1-8k_2, 5k_2, k_2]^T \end{aligned} \tag{4.13}$$

Ovdje su k_1 i k_2 težinski koeficijenti. Sile u točkama slike se računaju iz prostornih derivacija energetske funkcije prema slijedećim formulama.

$$\begin{aligned} F_x(x,y,z) &= -k_f \frac{V(x,y,z)_x}{|V(x,y,z)_x| + |V(x,y,z)_y| + \varepsilon} \\ F_y(x,y,z) &= -k_f \frac{V(x,y,z)_y}{|V(x,y,z)_x| + |V(x,y,z)_y| + \varepsilon} \end{aligned} \tag{4.14}$$

Ovdje su V_x i V_y prostorne derivacije energetske funkcije u smjerovima x, odnosno y, k_f je konstanta skaliranja sile, a ε je mala numerička konstanta kojom se izbjegava dijeljenje s nulom i smanjuje utjecaj visokofrekvencijskog šuma.

U ovakvoj formulaciji deformabilnog modela jedina veza između presjeka je konvolucijska matrica $\mathbf{H}_2$ (4.13) a točke modela ne mogu se kretati između presjeka. Stoga ovaj pristup nije u potpunosti trodimenzionalan već je bliži dvodimenzionalnom pristupu, odnosno može se reći da je pristup $2\frac{1}{2}$-D.

Zbog već poznatih problema kod segmentacije vanjskog ruba aorte, metoda je vrlo osjetljiva na inicijalizaciju deformabilnog modela. Rješenje tog problema je potraženo u malo opširnijoj inicijalizaciji deformabilnog modela. Operater treba ručno segmentirati nekoliko presjeka uzduž aorte: prvi, zadnji i još nekoliko između njih. Interpolacijom ručno segmentiranih presjeka dobiju se inicijalne krivulje za sve ostale presjeke. Vanjska energija definirana je jednadžbom

$$E(I) = -G_{\sigma 2} \otimes \exp\left(-\left(\frac{D(x,y,z) - mg_z}{sg_z} \right)^2 - \left(\frac{I(x,y,z) - ms_z}{ss_z} \right)^2 \right) \tag{4.15}$$

gdje je $G_{\sigma 2}$ Gaussova maska čija je funkcija izglađivanje energetske funkcije, $D = |\nabla G_{\sigma 1} \otimes I|$ je gradijent slike I izračunat pomoću 2-D Gaussove maske $G_{\sigma 1}$, mg_u i sg_u su srednja vrijednost i standardna devijacija gradijenta D, a ms_u i ss_u su srednja vrijednost i standardna devijacija intenziteta slike I. Spomenute srednje vrijednosti i standardne devijacije računaju se za ručno segmentirane presjeke, dok se za sve ostale presjeke te vrijednosti interpoliraju. Na taj način se informacije o rubu aorte dobivene iz ručno segmentiranih presjeka koriste da bi se što bolje segmentirali ostali presjeci.

Najbolja inicijalizacija kod ovakvog pristupa postiže se ako se ručno segmentiraju presjeci na kojima počinje nagla promjena oblika aorte. Tada će interpolacija dati inicijalne krivulje vrlo blizu rubu aorte za sve presjeke. Zbog problema segmentacije vanjskog ruba aorte, a zahvaljujući dobroj inicijalizaciji moguće je korištenje „krutog" deformabilnog modela (jake unutarnje sile koje sprečavaju veća savijanja). Zahvaljujući dobroj inicijalizacija blizu cilja (vanjskog ruba aorte) i krutom deformabilnom modelu (model se neće puno odmaknuti od dobrog početnog položaja) pristup uspješno savladava teškoće kod segmentaciji vanjskog ruba aorte. Metoda daje dobre rezultate čak i kod postoperativnih slika u kojima su prisutni izraženi artefakti zbog metalne proteza.

Nedostatak ove metode je upravo potreba za opsežnom inicijalizacijom deformabilnog modela, dok je njena prednost to što daje dobre rezultate i što je vrijeme izvođenja algoritma kratko zahvaljujući parametarskoj formi deformabilnog modela.

Zbog opširne inicijalizacije ova metoda segmentacije može se klasificirati kao poluautomatska. Metoda segmentacije prezentirana u ovom radu u poglavlju 5, imala je za cilj ostvarenje većeg stupnja automatizacije, tj. minimalnu inicijalizaciju deformabilnog modela. Rezultati gore navedene metode koji su ručno ispravljeni od strane radiologa uspoređeni su sa rezultatima metoda prezentiranih u odlomcima 7.3 i 7.4.

Poglavlje 5

Osnovni geometrijski deformabilni model

Cilj ovog istraživanja bio je konstruirati automatsku metodu segmentacije aneurizme abdominalne aorte iz CTA volumena, sa naglaskom na segmentaciju vanjskog ruba aorte. Takva automatska metoda treba pružiti veću ponovljivost rezultata i rasteretiti operatera od dugotrajnog i zamornog ručnog segmentiranja.

Za segmentaciju je odabran geometrijski deformabilni model i level-set metoda opisani u odlomku 3.3. Kako segmentacija vanjskog ruba aorte predstavlja veći problem, cilj je bio proizvesti metodu segmentacije koja će uspješno izvršiti segmentaciju vanjskog ruba aorte. Pokazalo se da tu osnovni geometrijski deformabilni model ne pokazuje dobre rezultate te je rješenje problema potraženo u modificiranju osnovnog geometrijskog deformabilnog modela. U poglavlju 7 opisane su četiri takve modifikacije odnosno pokušaja prevladavanja spomenutih problema. Za svaku od modifikacija, polazna točka bio je osnovni geometrijski deformabilni model opisan u [16].

Za svaku od istraženih modifikacija bilo je potrebno odrediti dimenzionalnost deformabilnog modela, tj. izabrati između 2-D varijante i 3-D varijante deformabilnog modela. Ukoliko se koristi 2-D deformabilni model onda se vrši pojedinačna segmentacija svakog presjeka s mogućnošću interakcije susjednih presjeka odnosno deformabilnih modela na njima. Ukoliko se koristi 3-D deformabilni model tada se vrši segmentacija cijele aorte. Kako je sama aorta trodimenzionalan objekt, prirodno je da se za njenu segmentaciju koristi 3-D deformabilni model te je za očekivati da će on, korištenjem i treće dimenzije dati točnije rezultate segmentacije. Npr. 2-D deformabilni model može se kretati samo u jednom presjeku. Segmentacijom sljedećeg presjeka oponaša se kretanje 3-D modela kroz presjeke, ali samo u jednom smjeru. 3-D deformabilni model može se kretati u bilo kojem smjeru tako da je moguće da se on kreće u oba smjera kroz presjeke. Mana 3-D deformabilnog modela je ta što on traži više računalnih operacija i memorijskih resursa prilikom izvođenja pa time treba više vremena za izvođenje od ekvivalentnog 2-D pristupa. To može biti prepreka za korištenje u stvarnom vremenu. Prednost korištenja 2-D deformabilnog modela je mogućnost bržeg izvođenja, a mana je to što ne koristi informacije iz treće dimenzije. Kod pogodnih oblika i položaj objekata koji se segmentiraju, taj nedostatak može se poništiti „umjetnim” tokom informacija između susjednih presjeka (interakcija među susjednim presjecima). Upravo aorta snimljena CT uređajem ima takav pogodan oblik i položaj. Aorta je približno cjevastog oblika čija se glavna os proteže okomito na CT presjeke. Na slici 5.1 ilustrirana je aorta u kojoj raste 3-D deformabilni model. Može se vidjeti da kada deformabilni model dođe do zida aorte glavnina njegovog kretanja odvija se jedino u smjeru vertikale (gore i dolje). Takvo ograničeno kretanje 3-D deformabilnog modela kod segmentacije aorte može se nadomjestiti pojedinačnom segmentacijom presjeka u smjerovima vertikale uz prenošenje određenih informacija između presjeka. Pojava ilustrirana slikom 5.1 iskorištena je i za jednu modifikaciju opisanu u poglavlju 6.

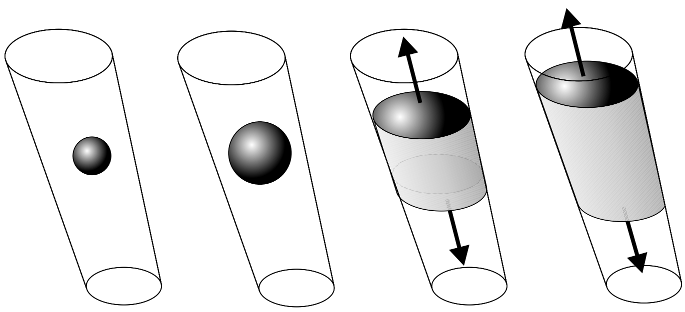

Slika 5.1: Ilustracija kretanja 3-D deformabilnog modela kroz cjevasti objekt

Izbor dimenzionalnosti deformabilnog modela kod segmentacije aneurizme abdominalne aorte svodi se na pitanje je li moguće koristiti 3-D deformabilni model. Ako nije moguće, koristi se 2-D model, a ako je moguće, potrebno je provjeriti da li prednosti korištenja 3-D deformabilnog modela nadmašuju njegove nedostatke. U ovom istraživanju sama formulacija nekih modifikacija osnovnog level-set algoritma sprječava upotrebu 3-D deformabilnog modela.

Također se pokazalo da je segmentacija unutarnjeg ruba aorte podjednako uspješna bilo s 2-D ili s 3-D deformabilnim modelom. Gore spomenute modifikacije posebno su prilagođene segmentaciji vanjskog ruba aorte, tako da se za segmentaciju unutarnjeg ruba ne koriste.

5.1 Osnovni level-set algoritam

Algoritam osnovnog level-set deformabilnog modela prikazan je algoritmom 1. Takav algoritam koriste manje više svi geometrijski deformabilni modeli, a razlike se najčešće očituju u 7. koraku algoritma 1, tj. u evolucijskoj funkciji. Slijedi opis koraka algoritma 1.

Algoritam 1 Algoritam osnovnog level-set deformabilnog modela.

```
1:  Zadaj početnu krivulju/površinu x
2:  Odredi uski pojas i početnu funkciju Φ.
3:  Izračunaj kriterij zaustavljanja temeljen na rubovima u slici.
4:  ponavljaj
5:     za i = 1 do N_iter izvrši
6:        Izračunaj koeficijente funkcije brzine koji ovise o Φ.
7:        Izvrši jednadžbu za mijenjanje funkcije Φ.
8:     završi za
9:     Nađi novu nultu razinu u uskom pojasu.
10:    Odredi novi uski pojas i odredi funkciju Φ u uskom pojasu.
11: dok Deformabilni model ne stane
```

1. Prije pokretanja samog algoritma potrebno je zadati početnu krivulju ili površinu. U ovom radu inicijalizacija deformabilnog modela radi se ručno.

2. U radu je korišten uski pojas (odlomak 3.3.2) zbog povećanja brzine algoritma. Širina uskog pojasa treba biti unaprijed zadana. Na temelju inicijalne krivulje/površine treba konstruirati funkciju Φ unutar uskog pojasa.

3. Često se dio evolucijske funkcije deformabilnog modela koji predstavlja vezu modela sa slikom ne mijenja tijekom izvođenja algoritma. To je logično jer se sama slika ne mijenja kroz algoritam. Stoga se taj dio evolucijske funkcije, poznat kao kriterij zaustavljanja, može izračunati u početnom dijelu algoritma.

4. Slijedi programska petlja u kojoj se iterativno proračunavaju nove vrijednosti funkcije Φ u uskom pojasu.

5. Sama jednadžba evolucije odvija se u unutarnjoj petlji. Broj izvršavanja unutarnje petlje unaprijed je zadan, a njegov odabir ovisi o širini uskog pojasa. Tijekom izvođenja unutarnje petlje nulta razina funkcije Φ ne bi trebala doći do ruba uskog pojasa.

6. Sama evolucijska jednadžba mijenja funkciju Φ pa je, prije ponovnog izvođenja evolucijske funkcije, u ovom koraku potrebno izračunati njene koeficijente koji ovise o Φ.
7. Sada se pomoću evolucijske funkcije određuju nove vrijednosti funkcije Φ u uskom pojasu. Primjer evolucijske jednadžbe dan je jednadžbom (3.54).
9. Nakon nekoliko iteracija unutarnje petlje potrebno je naći trenutnu nultu razinu koja se pomaknula uslijed promjene vrijednosti funkcije Φ.
10. Nakon što smo odredili nultu razinu možemo odrediti i novi uski pojas. To je potrebno jer stari uski pojas, uslijed pomicanja nulte razine, više ne odgovara te bi, kod sljedećeg izvršavanja unutarnje petlje, nulta razina mogla doći do ruba uskog pojasa. Potrebno je i konstruirati funkciju Φ temeljenu na trenutnoj nultoj razini. Način konstruiranja funkcije Φ korišten u ovom radu opisan je u odlomku 5.1.3.
11. Evolucija deformabilnog modela izvršava se dokle god se nulta razina, tj. krivulja $\mathbf{x}$ mijenja. Kada između dva izvršenja petlje nulta razina ostane ista algoritam prestaje s radom, a trenutna nulta razina postaje konačan rezultat. Moguće je uvjet zaustavljanja ublažiti tako da algoritam staje kada je promjena nulte razine dovoljno mala.

Ako se traži samo kontura aorte, odnosno samo njezine granice onda ovaj algoritam vraća točke nulte razine koje su već nađene u zadnjem prolazu točke 9. Ukoliko se traži cijela aorta onda algoritam vraća cijelu funkciju Φ koja je izračunata u zadnjem prolazu točke 10, ili vraća sve točke za koje vrijedi $\Phi(x) \leq 0$ što odgovara regiji aorte.

5.1.1 Računalna forma entiteta iz algoritma 1

Slijedi opis računalne reprezentacije entiteta algoritma 1 koja je korištena u ovom radu.

- Slike korištene u ovom radu su monokromatske a vrijednost svake točke predstavljena je s 12 bita. Takva slika je predstavljena dvodimenzionalnim poljem cijelih brojeva.
- Krivulja/površina nulte razine $\mathbf{x}$ pohranjuje se pomoću vektora pokazivača na konkretne točke slike.
- Vrijednosti funkcije Φ pohranjuju se u dvodimenzionalno polje brojeva s pomičnim zarezom čije dimenzije odgovaraju dimenzijama slike. Iako se vrijednosti funkcije Φ inicijaliziraju na cjelobrojne vrijednosti, tijekom izvršavanja petlje u točki 7 algoritma 1 te vrijednosti prestaju biti cjelobrojne.

- Uski pojas predstavljen je vektorom pokazivača na točke funkcije Φ koje se nalaze u uskom pojasu. Isti pokazatelji koriste se za referenciranje točaka na slici i koeficijenata ovisnih o slici.
- Za pohranu koeficijenata funkcije brzine koji ovise o podacima sa slike i računaju se jednokratno, korišteno je dvodimenzionalno polje brojeva s pomičnim zarezom koje veličinom odgovara slici.
- Koeficijenti koji ovise o funkciji Φ traže se pomoću vektora pokazivača uskog pojasa te se za svaki pokazivač uskog pojasa računa jedan koeficijent. Koeficijenti se pohranjuju u jednodimenzionalno polje brojeva s pomičnim zarezom tako da položaju pokazivača u vektoru uskog pojasa odgovara položaj koeficijenta u vektoru koeficijenata.

5.1.2 Inicijalizacija geometrijskog deformabilnog modela

U ovom radu korištena je ručna inicijalizacija deformabilnog modela. Korisnik treba ručno zadati početnu krivulju (2-D slučaj) ili početnu površinu (3-D slučaj). Kako je jedan od glavnih ciljeva rada bila što veća automatizacija, odnosno minimiziranje potrebe za korisnikovom interakcijom, za inicijalizaciju je odabrana kružnica odnosno sfera. I kružnica i sfera mogu se zadati s dvije točke: prva točka određuje centar, a druga radijus. Obadvije točke mogu se zadati na istom presjeku što također doprinosi jednostavnosti.

Kako geometrijski deformabilni model korišten u ovom radu uvijek ima negativnu konstantnu komponentu brzine v_0 (3.24), deformabilni model može se kretati samo prema van, tj. može se samo napuhavati. Stoga je potrebno da inicijalna krivulja ili površina cijela bude unutar objekta (aorte) koji se želi segmentirati. Iako je segmentacija objekta moguća i istim deformabilnim modelom koji je inicijaliziran izvan objekta, to nije primjenjivo za segmentaciju aorte budući okolina aorte nije homogena i puna je drugih sličnih tkiva koja bi ometala segmentaciju aorte. Stoga je potrebno prilikom inicijalizacije početnu krivulju ili aortu smjestiti unutar aorte.

Najjednostavnije je inicijalizaciju izvršiti u unutrašnjosti aorte jer se takva inicijalizacija može koristiti za segmentaciju unutarnjeg i vanjskog ruba aorte. Kod 2-D pristupa inicijalizacija je jasna, no kod 3-D pristupa treba smjestiti sferu pri čemu treba paziti da se cijela sfera, koja se proteže kroz više presjeka, nalazi unutar aorte. Sfera se inicijalizira postavljanjem kružnice na odabrani (početni) presjek tako da se zadaju dvije točke od kojih prva predstavlja centar kružnice, a druga određuje radijus kružnice. Radijus sfere jednak je radijusu zadane kružnice, dok centar kružnice odgovara centru sfere s time da je treća koordinata centra određena položajem presjeka na kojem je izvršena inicijalizacija. Sjecišta CT presjeka i sfere su kružnice te svaka od tih kružnica mora biti unutar aorte na tom presjeku. Najveća kružnica nalazi se na početnom presjeku dok se kružnice na susjednim presjecima smanjuju kako se udaljavamo od početnog presjeka. Kako su promjene promjera aorte rijetko znatne među susjednim presjecima, pravilno smještanje kružnice na početnom presjeku omogućit će dobar smještaj ostalih kružnica sfera, a s njima i cijele sfere. Maksimalni mogući radijus kružnice na početnom presjeku mogao bi prouzročiti da sfera nije cijela u aorti na susjednim presjecima pa nije poželjno zadavati maksimalni mogući radijus.

Postavlja se pitanje optimalne inicijalizacije s obzirom na veličinu inicijalne kružnice tj. sfere. Smještanjem maksimalne moguće kružnice u aortu je komplicirano jer korisnik treba precizno odrediti radijus i centar, a spomenuti su i problemi koje maksimalni radijus stvara u 3-D slučaju. Druga krajnost je odabir minimalnog radijusa koje je jednak nuli što kružnicu svodi na točku koju je potrebno zadati kod inicijalizacije. To dodatno pojednostavljuje inicijalizaciju. Moguće je odrediti mali konstantni radijus (npr. 3) te tražiti samo zadavanje centra takve male kružnice pri čemu treba voditi računa kod inicijalizacije da centar ne postavimo preblizu rubu aorte. Općenito je najsigurnije i najjednostavnije centar kružnice smjestiti u centar aorte na početnom presjeku. Glavni nedostatak minimizacije radijusa predstavlja konveksna zakrivljenost koja je za male kružnice vrlo velika, a za točku beskonačna. Takva zakrivljenost daje veliku komponentu brzine ovisnu o zakrivljenosti, koja navodi deformabilni model da se kreće prema unutra, tj. da se smanjuje. Velika zakrivljenost može nadjačati konstantnu komponentu brzine v_0 te se takav deformabilni model smanjuje u jednu točku dok ne iščezne. Taj problem može se riješiti privremenim isključivanjem komponente brzine koja ovisi o zakrivljenosti na nekoliko iteracija. Takva će kružnica brzo rasti, no ukoliko je centar kružnice blizu centra aorte nema opasnosti da deformabilni model dođe do ruba aorte. Nedostatak odabira male kružnice umjesto velike je u tome što maloj kružnici treba određen broj računskih operacija, odnosno vremena da dosegne veličinu veće kružnice. Kako je broj točaka za koje se vrši računanje u tom početnom periodu relativno malen, taj nedostatak nema velikog značaja i nadmašuje ga prednost jednostavnije inicijalizacije.

Zbog činjenice da je aorta jasno vidljiva na CT presjecima (posljedica angiografije) postoji mogućnost da se ovaj korak automatizira odnosno da se vrši automatsko prepoznavanje aorte i inicijalizacija deformabilnog modela.

5.1.3 Konstruiranje funkcije Φ

U točkama 2 i 10 algoritma 1 vrši se konstruiranje funkcije Φ iz zadane nulte razine. Funkcija Φ odabrana je da bude funkcija udaljenosti od krivulje $\mathbf{x}$ tj. nulte razine (3.21). Određivanje euklidske udaljenosti svake točke do najbliže točke na nultoj razini zahtijevalo bi veliki broj računalnih operacija, a udaljenosti bi se trebale određivati za svaku iteraciju. U [26] navedeno je nekoliko alternativnih načina računanja odnosno aproksimacije funkcije udaljenosti. U ovom radu korištena je pojednostavljena verzija *fast marching* [26] metoda prikazana algoritmom 2. Slijedi kratak opis algoritma 2.

Algoritam 2 Algoritam za konstruiranje novog uskog pojasa i funkcije Φ iz nove nulte razine.

1: Neka je $U_t = \{t\}$ skup svih točaka t u trenutnom uskom pojasu.
2: Neka je $U_n = \{t|\Phi(t) = 0\}$ skup svih točaka t koje čine novu nultu razinu.
3: Postavi nove vrijednosti funkcije $\Phi(t) = \text{sign}\,(\Phi(t)) \cdot \infty$ gdje je $t \in U_t \setminus U_n$.
4: **za** $d = 1$ do k **izvrši**
5:     Neka je A skup svih točaka $t \in I$ koje su susjedne barem jednoj točki iz U_n i za koje vrijedi $|\Phi(t)| = \infty$.
6:     Postavi nove vrijednost $\Phi(t) = \text{sign}\,(\Phi(t)) \cdot d$ za sve $t \in A$
7:     Neka je $U_n = U_n + A$.
8: **završi za**

1. Skup U_t je skup svih točaka t koje se nalaze u trenutnom uskom pojasu.

2. U trenutnom uskom pojasu nalazi se i nova nulta razina ($\Phi(t) = 0$) te se točke koje čine novu nultu razinu pridružuju skupu U_n. Skup U_n predstavlja skup točaka u novom uskom pojasu i po završetku algoritma 2 on će sadržavati sve točke novog uskog pojasa.

3. Sve vrijednosti funkcije Φ u svim točkama trenutnog uskog pojasa izuzev u točkama koje čine novu nultu razinu postavljaju se na $\pm\infty$ ovisno o svom trenutnom predznaku. Na ovaj način možemo jednostavno razlikovati točke koje su pridružene novom uskom pojasu U_n od onih koje to nisu. Točke pridružene U_n imat će već postavljene konačne vrijednosti funkcije Φ dok će u ostalim točkama biti $\Phi = \pm\infty$. U algoritmu 2 funkcija Φ mijenja vrijednosti ali se predznak ne mijenja pa se na ovaj način čuva predznak funkcije Φ tj. informacija da li je točka unutar ili izvan krivulje nulte razine. Nova vrijednost mogla bi biti postavljena na bilo koji broj koji je veći od dozvoljene širine uskog pojasa k jer vrijednosti funkcije Φ u novom uskom pojasu nikad neće biti veće od k. Zbog općenitosti

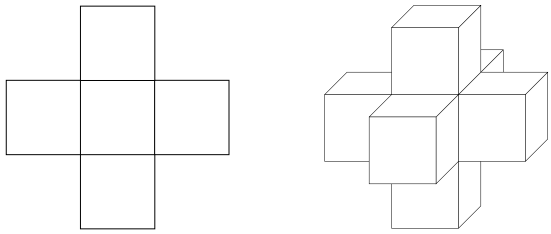

(a) (b)

Slika 5.2: Ilustracija položaja susjednih točaka koje koristi algoritam 2: (a) 2-D slučaj, (b) 3-D slučaj.

odabrana je posebna vrijednost ∞ koja je podržana u standardu IEEE 754 koji regulira kako moderna računala pohranjuju brojeve s pomičnim zarezom.

4. Petlja se izvršava onoliko puta kolika je zadana širina uskog pojasa k, a vrijednost varijable d ujedno je i trenutna udaljenost od nulte razine.

5. Skupu A dodaju se sve točke slike (I) koje su susjedne barem jednoj točki iz U_n i za koje je $|\Phi| = \infty$. U ovom radu susjedne točke nalaze su u okolini točke koju čine četiri točke za 2-D slučaj i u okolini koju čini 6 točaka za 3-D slučaj. Ilustracija konfiguracija takvih susjedstva prikazana su slikom 5.2.

6. Vrijednost funkcije Φ za točke iz susjedstva postavljaju se na trenutnu udaljenost d, ali zadržavaju svoj stari predznak jer se njihov relativan položaj u odnosu na nultu razinu (unutra ili vani) nije promijenio.

7. Skupu novog uskog pojasa U_n dodaje se skup njegovog susjedstva A.

8. Postupak se ponavlja za sljedeće razinu dok se ne dođe do zadane širine uskog pojasa k.

Algoritam 2 paralelno određuje novo usko susjedstvo i konstruira funkciju Φ u istom uskom pojasu. Taj algoritam koristi se u točki 10 algoritma 1. Isti algoritam mogao bi se koristiti i u točki 2 algoritma 1, no kako se radi o poznatim inicijalnim oblicima nulte razine (kružnica ili sfera) brže je funkciju Φ, odnosno udaljenosti konstruirati posebnom funkcijom čiji su ulazni parametri samo centar i radijus kružnice te širina uskog pojasa. Osim određivanja udaljenosti do nulte razine za sve točke uskog pojasa, takva funkcija treba postaviti vrijednost funkcije $\Phi = \pm\infty$ za sve točke slike koje se nalaze izvan uskog pojasa. Pozitivan predznak imaju točke izvan kružnice odnosno sfere, a negativan predznak točke u unutrašnjosti. Time je osigurano da i točke izvan trenutnog uskog pojasa U_t, koje ne dotiče točka 3 algoritma 2, imaju odgovarajuće vrijednosti $\pm\infty$.

5.1.4 Određivanje koeficijenata funkcije brzine

Prije svakog izračunavanja nove vrijednosti funkcije Φ u nekoj točki, potrebno je znati vrijednosti koeficijent funkcije brzine za danu točku. Funkcija brzine V iz (3.19) može imati različite oblike i imati različite komponente (npr. (3.24) (3.28)), no sve se te komponente mogu svrstati u tri kategorije.

- Prvu kategoriju čini najčešće samo jedan konstantni koeficijent koji određuje globalno kretanje deformabilnog modela. To je jedan od parametara modela i on mora biti unaprijed zadan.

- Drugu kategoriju čine koeficijenti koji ovise o informacijama sa same slike. Primjer takvog koeficijenta je kriterij zaustavljanja g u (3.24) ili funkcija brzine $\mathbf{V_{ext}}$ u (3.28). Kako se sama slika ne mijenja tijekom postupka segmentacije te koeficijente potrebno je izračunati samo jednom za sve točke slike (točka 3 algoritma 1). Nedostatak je što za pohranu tih koeficijenata treba polje veličine slike što povećava memorijske zahtjeve.

- Treću kategoriju čine koeficijenti koji ovise o samoj funkciji Φ. Ti koeficijenti predstavljaju unutarnje sile u deformabilnom modelu. Nakon svake promjene funkcije Φ, te koeficijente potrebno je ponovo izračunati za danu točku. Kako se funkcija Φ mijenja u točki 7 algoritma 1, u točki 6 računaju se ti koeficijenti. Ti koeficijenti računaju se za sve točke uskog pojasa. Primjer takvog koeficijenta je zakrivljenost. Kako su ti koeficijenti obično lokalnog karaktera, odnosno vrijednost koeficijenta za neku točku ovisi o vrijednostima funkcije Φ u susjednim točkama, postoji mogućnost da se koeficijenti ne računaju za sve točke uskog pojasa već samo za one točke u čijem se susjedstvu promijenila vrijednost funkcije Φ kao što je opisano u [26]. Time bi se uštedjelo nešto vremena, no s druge strane praćenje promjena funkcije Φ uvodi dodatno računalno opterećenje tako da isplativost praćenja ovisi o konkretnom slučaju.

Poglavlje 6

Ubrzavanje geometrijskog deformabilnog modela

U ovom poglavlju bit će opisane dvije modifikacije osnovnog geometrijskog deformabilnog modela kojom se nastojalo ubrzati segmentaciju. Te modifikacije predstavljaju originalan doprinos ovog rada.

6.1 Modifikacija I

Kako bi mogli osvježiti vrijednosti funkcije Φ u svakoj točki uskog pojasa potrebno je izvršiti određeni broj matematičkih operacija za određivanje prostornih derivacija, zakrivljenosti te na kraju iznosa te promjene. Broj točaka u uskom pojasu nije pretjerano velik u 2-D slučaju, no u 3-D slučaju broj točaka znatno raste. Stoga je poželjno smanjiti na minimum broj točaka uskog pojasa.

6.1.1 Ideja za ubrzanje

Osnovna ideja modifikacije bila je dodatno smanjiti broj točaka za koje se vrše proračuni. Drugim riječima, pokušalo se dodatno smanjiti veličinu uskog pojasa. Kako je opisano u 3.3.2, uski pojas konstruira se na temelju krivulje nulte razine. Sama svrha uskog pojasa je da se evolucijom funkcije Φ pokreće krivulje nulte razine. No tijekom evolucije neke će točke nulte razine doći do ruba aorte prije nego ostale točke. Te će točke do kraja segmentacije stajati, a za njih i za točke uskog pojasa koje su njihova posljedica cijelo vrijeme vršit će se gore spomenuti

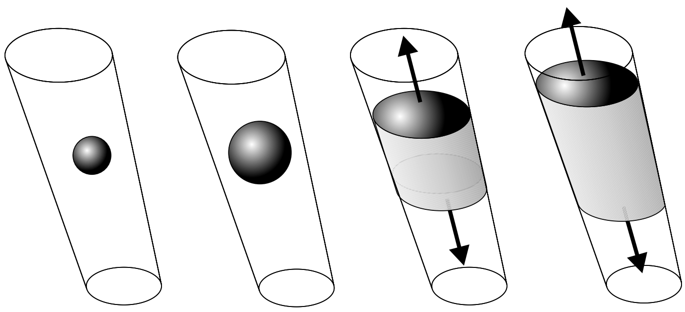

Slika 6.1: Ilustracija kretanja 3-D deformabilnog modela kroz aortu.

proračuni. Ukoliko bismo uveli praćenje točaka nulte razine kako bi odredili da li se one još uvijek kreću, mogli bi eliminirati iz daljnjih proračuna točke nulte razine koje su stale i sve njima susjedne točke koje bi ušle u uski pojas.

Eliminacija točaka koje su stale posebno bi bila efikasna u 3-D slučaju zbog specifičnog oblika i položaja aorte. Nakon inicijalizacije, evolucijom će deformabilni model prvo dosegnuti rub aorte. Nakon toga sve pokretne točke bit će na vrhu i na dnu površine deformabilnog modela. Kako prolaze iteracije broj točaka koje stoje se povećava dok broj točaka koje stoje ostaje približno stalan. S povećanjem broja statičnih točaka povećava se i ušteda vremena korištenjem ovakve modifikacije. Ilustracija opisane situacije prikazana je slikom 6.1.

6.1.2 Implementacija ubrzanja

Potrebno je implementirati mehanizam praćenje pokretljivosti točaka. Kako sam level-set algoritam nema mehanizam praćenja točaka nulte razine (što se smatra njegovom pozitivnom osobinom) već se te točke pronalaze traženjem točaka u kojima funkcija Φ prolazi kroz nulu, nije pogodno da se uvodi direktno praćenje točaka nulte razine.

Točka krivulje nulte razine označava se kao statična ukoliko se ne pomakne određeni broj iteracija n_s. U ovom radu korištena je vrijednost $n_s = 3$. Manja vrijednost n_s brže će označavat točke kao statične i eliminirati ih iz daljnjih proračuna, što će uzrokovati veće ubrzanje same segmentacije. Premala vrijednost n_s može imati za posljedicu označavanje točke kao statične premda bi se ona u jednoj od sljedećih iteracija pomaknula. Kasnije u odlomku bit će pokazano da netočno označavanje točke kao statične nema jako negativne posljedice na rezultat segmentacije.

U ovom radu se za praćenje pokretljivosti točaka nulte razine koristio sličan mehanizam kao i mehanizam evolucije geometrijskog deformabilnog modela. Umjesto praćenja kretanja

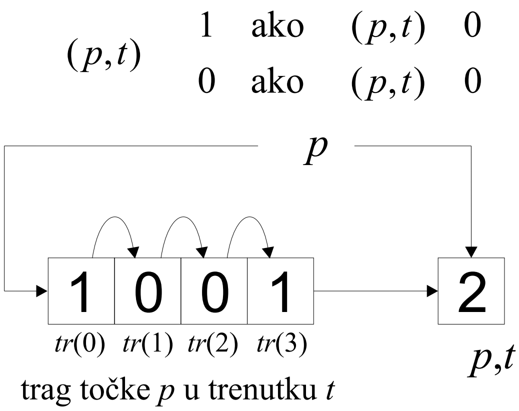

Slika 6.2: Primjer traga za praćenje kretanja nulte razine.

samih točaka krivulje, praćeno je koliko se nulta razina zadržava na jednoj točki slike, odnosno točki funkcije Φ. Ukoliko se na jednoj točki slike nulta razina zadržala kroz n_s uzastopnih iteracija, tada se ta točka, koja je ujedno i točka krivulje nulte razine, proglašava statičnom. Za praćenje kretanja korišteno je polje cijelih brojeva Ψ, veličine slike te je praćeno kretanje nulte razine kroz sve točke slike. Svaka element tog cjelobrojnog polja mora moći pohraniti barem vrijednost n_s. Takav način praćenja odabran je zbog jednostavnosti, a nedostatak mu je relativna velika potreba za memorijom. Smanjenje potrebne memorije može se ostvariti praćenjem kretanja samo u uskom pojasu, no to bi uvelo dodatnu složenost jer se uski pojas kreće kroz iteracije.

Kod odabranog mehanizma praćenja, vrijednost svake točke polja Ψ na kojoj se nalazi nulta razina u danoj iteracije (nakon određivanja nove nulte razine u točki 9 algoritma 1), povećava se za 1. Kada neka točka od Ψ dosegne vrijednost n_s ona se proglašava statičnom.

Kako se za sve evolucijske funkcije korištene u ovom radu, deformabilni model kreće samo u jednom smjeru (prema van) nema mogućnosti da se nulta razina vrati na točke kojima je već prošla. Ipak, općenitosti radi, u ovom radu dodana je i mogućnost ponovnog prolaza. To je učinjeno sa svojevrsnim tragom kretanja svake točke. Za svaku točku slike definiran je trag od n_s elemenata. Najmanja veličina svakog elementa traga iznosi jedan bit jer svaki element mora pohraniti vrijednosti 0 ili 1. Za sve točke slike elementi tragova pomiču se prema kraju (slika 6.2), a na početke tragova stavljaju se jedinice za točke trenutne nulte razine, a nule za sve ostale točke. Elementi tragova koji su uslijed pomicanja izašli iz krajeva, oduzimaju se od vrijednosti Ψ u odgovarajućoj točki. Na taj način vrijednost od Ψ se uvijek vraća na nulu ukoliko je kroz točku nulta razina samo prošla.

U predzadnjoj iteraciji segmentacije, uski pojas sačinjavat će mali broj točaka. U sljedećoj iteraciji sve će točke tog uskog pojasa stati, pa neće biti nove nulte razine, niti novog uskog pojasa. Kod osnovnog geometrijskog modela, završna nulta razina predstavljala bi i rezultat segmentacije. Kako uslijed ove modifikacije neće biti završne nulte razine potrebno je na drugi način odrediti rezultat segmentacije.

Već je rečeno da se točke koje se proglase statičnima isključuju iz daljnjih proračuna. Te točke predstavljaju elemente završne krivulje pa je samo potrebno upamtiti koje su točke proglašene statičnima. U tu svrhu koristi se polje pokazivača na statične točke koje se popunjava tijekom iteracija. Nakon posljednje iteracije, završna krivulja se rekonstruira pomoću tih pokazivača.

Za opisano ubrzavanje potrebno je dakle osvježavati polje Ψ i trag za sve točke slike. Potrebni koraci dani su u algoritmu 3, a oni se dodaju u algoritam 1 između točke 9 i točke 10.

Algoritam 3 Koraci za ubrzanje level-set algoritma.

1: Uvećaj vrijednosti polja Ψ za sve točke trenutne nulte razine.
2: Pomakni vrijednosti svih tragova prema njihovim krajevima.
3: Vrijednosti koje su izašle iz krajeva oduzmi od odgovarajućih vrijednosti polja Ψ.
4: Na početak tragova točaka trenutne nulte razine postavi 1, a svim ostalim točkama 0.

Opisana modifikacija level-set algoritma korištena je u svim pristupima segmentacije opisanim u poglavlju 7. Zbog jednostavnosti, u nastavku rada točke algoritma za ubrzavanje neće se posebno navoditi, već se uzima da su one uključene u određivanje nove nulte razine.

Slična metoda kojom se nastojalo ubrzati level-set algoritam, nazvana Hermesov algoritam, opisana je u [20]. U toj metodi računaju se iznosi promjena vrijednosti funkcije Φ za sve točke nulte razine i njima susjedne točke. Promjena vrijednosti funkcije Φ prvo se vrši za točku s najvećim iznosom promjene i za njoj susjedne točke. Postupak se ponavlja za sljedeću točku s najvećim iznosom promjena uz povremenu reinicijalizaciju funkcije Φ.

6.2 Modifikacija II

Druga modifikacija kojom se nastojalo ubrzati postupak segmentacije predstavlja korištenje decimacije. Ova modifikacije efikasna je samo kod 3-D segmentacije. Kod 2-D segmentacije ne postiže se znatnije ubrzanje zbog vremena koje se gubi na decimaciju i prilagodbe vezane za nju, koje postaje ekvivalentno uštedi uslijed ubrzanja.

Decimacija CT volumena provodi se uzduž x i y osi. Decimacija uzduž z osi nije pogodna jer je broj presjeka ionako manji od širine i duljine volumena, uslijed manje uzdužne rezolucije CT snimaka. Dimenzije decimiranog volumena tada su $\frac{s}{D} \times \frac{d}{D} \times v$, gdje su s - širina, d - dužina i v - visina. Decimacija ovdje ne podrazumijeva zadržavanje svake D-te točke već se vrijednosti točaka decimiranog volumena određuju interpolacijom uzduž x i y osi kako bi se izbjegao aliasing.

Inicijalizacija se tada vrši na presjecima pune veličine, ali se geometrijski deformabilni model pokreće na decimiranom volumenu. Inicijalna sfera tada mora imati proporcionalno smanjeni radijus. Nakon što segmentacija na decimiranom volumenu stane, trenutna funkcija Φ interpolacijom uzduž x i y osi proširuje se na punu veličinu CT snimke Φ_i. Zbog smanjene preciznosti segmentacije na decimiranom volumenu, moguće je da se nulta razina proširene funkcije Φ_i nađe s vanjske strane ruba aorte. Funkcija Φ_i se zbog toga uvećava za određenu veličinu ρ što je ekvivalentno smanjivanju krivulja nulte razine, odnosno deflaciji deformabilnog modela. Iznos veličine koja se dodaje u direktnoj je vezi s konstantom decimacije D, a u ovom radu vrijednost ρ jednaka je D. Zbog smanjene preciznosti pogreška u položaju točaka nulte razine interpolirane funkcije Φ može biti maksimalno D, što objašnjava izbor veličine ρ. Umjesto uvećavanja funkcije Φ_i za D, moguće je uvećati funkciju Φ za 1. Funkcija Φ_i koristi se kao inicijalizacija za segmentaciju ruba aorte u punoj veličini. Za očekivati je tada da će segmentacija na punoj razini trajati svega nekoliko iteracija jer je inicijalna nulta razina vrlo blizu vanjskog ruba aorte.

Problem kod korištenja decimacije je da se inicijalnoj sferi treba smanjiti radijusa D puta. Sfera sa smanjenim radijusom ima povećanu zakrivljenost koja je konveksna. Kako konveksna zakrivljenost u jednadžbi 3.25 zaustavlja evoluciju deformabilnog modela, potrebno je proporcionalno smanjiti vrijednost konstante ε tijekom segmentacije na decimiranom volumenu. U suprotnom evolucija deformabilnog modela stala bi u prvoj iteraciji algoritma geometrijskog deformabilnog modela.

Smanjenje broja točaka na kojima se vrše proračuni proporcionalno je D^2, a takva je onda i vremenska ušteda u svakoj iteraciji. Od ukupne uštede treba odbiti vrijeme potrebno za jednokratnu decimaciju i iteraciju.

Poglavlje 7

Prilagodbe osnovnog geometrijskog deformabilnog modela

U ovom poglavlju bit će opisan glavni doprinos ovog rada. Riječ je o prilagodbama osnovnog geometrijskog deformabilnog modela, čiji je cilj rješavanje problema koji se pojavljuju kod segmentacije vanjskog ruba abdominalne aorte. Bit će opisano četiri pristupa koji se po svojim osnovnim karakteristikama mogu podijeliti u tri skupine.

- Prvi i drugi pristup uvode dodatni zaustavni kriterij. U obadva pristupa prati se po jedna karakteristika deformabilnog modela i kada ta karakteristika zadovolji prethodno definirani uvjet, aktivira se dodatni uvjet zaustavljanja. Tim dodatnim uvjetima zaustavljanja pokušava se spriječiti deformabilni model da prođe kroz slabo izraženu granicu aorte i da prodru u susjedno tkivo. Sama priroda dodatnih zaustavnih kriterija povlači korištenje isključivo 2-D deformabilnog modela. Korišteni level-set algoritam za segmentaciju vanjskog ruba aorte isti je kao onaj dan algoritmom 1, s time da je u njega dodana provjera spomenutih karakteristika i jednokratno izvršavanje dodatnog uvjeta zaustavljanja kada se za to ostvare uvjeti.

- Drugi pristup nastoji riješiti isti problem uvođenjem predprocesiranja svakog presjek, kojim se nastoji rekonstruirati slabo izražene ili nepostojeće vanjske granice aorte. Rezultat tog predprocesiranja prosljeđuje se na segmentaciju deformabilnim modelom. Iako se predprocesiranje radi zasebno na svakom presjeku, ukupni rezultat predprocesiranja svih presjeka ima tri dimenzije pa je moguće korištenje 3-D deformabilnog modela. Korišteni level-set algoritma za segmentaciju vanjskog ruba aorte, u osnovi je isti je kao i onaj opisan algoritmom 1, a rješavanje problema slabo izraženih vanjskih granica odvije se zasebno izvan level-set algoritma.

- Za razliku od ostalih pristupa, ovaj pristup nije orijentiran na rubove regija već je orijentiran na same regije. Deformabilnim modelom nastoji se postići podjela slike na regije koja će maksimizirati sličnost točaka unutar istih regija i različitost točaka različitih regija slike. Koristi se i sličnost zakrivljenosti unutarnjeg i vanjskog ruba, promatrano na svakom presjeku. To uvjetuje korištenje 2-D deformabilnog modela koji pak omogućuje iskorištavanje sličnosti vanjskih rubova aorte na susjednim presjecima.

7.1 Pristup I

U ovom pristupu pokušalo se iskoristiti znanje o obliku vanjskog ruba aorte, kako bi se spriječilo da deformabilni model pređe preko slabije izraženih vanjskih rubova aorte. Uvjet zaustavljanja deformabilnog modela zasnovan je na rubovima regija. Prije segmentacije vanjskog ruba aorte potrebno je izvršiti segmentaciju unutarnjeg ruba aorte. Rezultati segmentacije unutarnjeg ruba aorte koriste se u segmentaciji vanjskog ruba aorte. Kako je već spomenuto, segmentacija unutarnjeg ruba aorte ne predstavlja veći problem i moguće ju je napraviti ili s 2-D ili s 3-D deformabilnim modelom. Ovdje je korišten 3-D deformabilni model za segmentaciju unutarnjeg ruba aorte.

7.1.1 Ideja za dodatni uvjet zaustavljanja

Zdrava abdominalna aorta na CT presjecima uvijek ima ovalan odnosno kružni, konveksan oblik te je njezin vanjski rub gladak u smislu da nema većih nazubljenosti. To je posljedica visokog tlaka krvi unutar aorte i fizikalnih svojstava same aorte. Kod aneurizme, utjecaj tlaka krvi ostaje isti, a mijenjaju se fizikalna svojstva zida abdominalne aorte. To ima za posljedicu promjenu oblika abdominalne aorte, tako da se općenito za abdominalnu aortu s aneurizmom ne može očekivati ovalan oblik i glatkoća. Uvidom u više CT snimaka uočeno je da je na velikoj većini presjeka s aneurizmom, abdominalna aorta ipak približno konveksna (ovalna) i glatka. Ta informacija nastoji se upotrijebiti za zaustavljanje prodora deformabilnog modela izvan granica aorte.

Dolje opisani algoritam koristi i činjenicu da je središte unutrašnjosti aorte (obuhvaćena unutarnjim rubom aorte) vrlo blizu središtu cijele aorte (obuhvaćena vanjskim rubom aorte) na

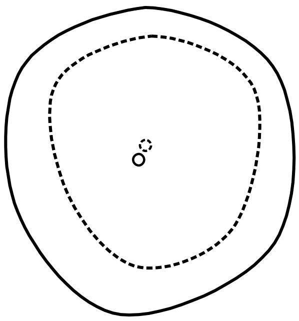

Slika 7.1: Centar unutarnjeg ruba aorte (crtkano) i centar vanjskog ruba aorte (puna linija) najčešće se nalaze blizu jedan drugome.

jednom presjeku kao što je ilustrirano na slici 7.1. Uvidom u veći broj CT snimaka pokazalo se da je to istina u većini slučajeva.

Glavna ideja ovog pristupa je da deformabilni model krene kao kružnica prema završnom obliku koji je sličan kružnici. Središte početne i završne kružnice trebala bi biti vrlo blizu. Ako je to istina tada se može pretpostaviti, nakon što određeni postotak točaka deformabilnog modela stane, da su i ostale točke blizu vanjskog ruba odnosno da će uskoro stati. Stoga se uvodi ograničenje koje će dozvoliti svim točkama deformabilnog modela koje se još kreću, da se mogu još pomaknuti najviše za određeni broj točaka u radijalnom smjeru (radijalnom u odnosu na središte krivulje nulte razine. Ukoliko te točke naiđu na dobro izraženi vanjski rub aorte, one će stati same, a ukoliko nema jasno izraženog vanjskog ruba aorte, zaustavit će ih dodatni uvjet zaustavljanja.

7.1.2 Algoritam za segmentaciju unutarnjeg ruba aorte

Za segmentaciju unutarnjeg ruba aorte korišten je algoritam 1 opisan u odlomku 5.1. Za evolucijsku funkciju deformabilnog modela u točki 7 algoritma 1 odabrana je funkcija dana jednadžbom (3.25). Za implementaciju algoritma korištena je njena diskretna forma za 3-D slučaj dana jednadžbom (7.1).

$$\Phi_{i,j,k}^{n+1} = \Phi_{i,j,k}^{n} + \Delta t \cdot g(\varepsilon\kappa + v_0)|\nabla\Phi_{i,j,k}^{n}|. \tag{7.1}$$

Ista evolucijska jednadžba korištena je i za segmentaciju vanjskog ruba aorte, ali u formi prilagođenoj za 2-D slučaj. Inicijalizacija 3-D deformabilnog modela vrši se postavljanjem sfere unutar aorte na prije opisani način.

7.1.3 Algoritam za segmentaciju vanjskog ruba aorte

Za segmentaciju vanjskog ruba aorte korišten je algoritma 4 što je modifikacija algoritma 1. Ovdje su dodane točke 11-15 u algoritam 1 te je izmijenjena točka 1.

Algoritam 4 Modificirani algoritam za segmentaciju vanjskog ruba aorte.

1: Odrediti početnu krivulju/površinu $\mathbf{x}$ iz rezultata segmentacije unutarnjeg ruba aorte.
2: Odredi uski pojas i početnu funkciju Φ.
3: Izračunaj kriterij zaustavljanja temeljen na rubovima u slici.
4: **ponavljaj**
5:     **za** i=1 do N_{iter} **izvrši**
6:         Izračunaj koeficijente funkcije brzine koji ovise o Φ.
7:         Izvrši jednadžbu za mijenjanje funkcije Φ.
8:     **završi za**
9:     Nađi novu nultu razinu u uskom pojasu.
10:     Odredi novi uski pojas i odredi funkciju Φ u uskom pojasu.
11:     Neka je n_{uk} ukupan broj točaka nulte razine.
12:     Neka je n_{stat} jednak broju točaka nulte razine koje se nisu pomaknule s iteracija.
13:     **ako** $n_{stat}/n_{uk} > M$ & nije zadan dodatni uvjet zaustavljanja **onda**
14:         Zadaj dodatni uvjet zaustavljanja.
15:     **završi ako**
16: **dok** Deformabilni model ne stane

Početni oblik i položaj deformabilnog modela nije potrebno ručno zadati veće se on određuje u točki 1 algoritma 4, iz rezultata segmentacije unutarnjeg ruba aorte. Za početni oblik deformabilnog modela odabrana je kružnica. Njezin centar je središnja točka (definirana kao centar mase) unutarnje granice aorte. Zahvaljujući segmentaciji unutarnjeg ruba aorte, poznate su sve točke koje se nalaze na unutarnjoj granici aorte te je jednostavno odrediti koordinate njihovog središta prema jednadžbi (7.2).

$$
\begin{aligned}
x_c &= \frac{1}{m}\sum_{i=1}^{m} x_i, \\
y_c &= \frac{1}{m}\sum_{i=1}^{m} y_i
\end{aligned}
\tag{7.2}
$$

Radijus kružnice odabran je pomoću srednjeg radijusa svih točaka unutarnjeg ruba aorte prema jednadžbi (7.3)

$$r = \frac{\alpha}{m} \sum_{i=1}^{m} \sqrt{(x_i - x_c)^2 + (y_i - y_c)^2}, \tag{7.3}$$

gdje je α konstanta, obično manja od 1, kojom se množi srednji radijus. Ta konstanta osigurava da se početna krivulja nalazi unutar vanjskog ruba aorte i u ovom radu korištena je vrijednost $\alpha = 0.7$. Iako bi i kružnica s radijusom jednakim srednjem radijusu unutarnjeg ruba trebala biti cijela unutar vanjskog ruba aorte, faktor α uvodi dodatnu sigurnost.

Ovakav odabir početne krivulje za segmentaciju vanjskog ruba aorte povezan je s uvjetom u točki 11 algoritma 4 kao što je objašnjeno u odlomku 7.1.4. Središte kružnice, iako određeno pomoću točaka unutarnjeg ruba, trebalo bi biti blizu središta vanjskog ruba aorte te središte kružnice predstavlja procjenu središta vanjskog ruba aorte.

U točki 11 računa se ukupan broj točaka nulte razine n_{uk}, a u točki 12 određuje se broj točaka n_{stat} nulte razine koje se nisu pomaknule određen broj iteracija.

Točka 13 provjerava da li je zadovoljen uvjet za zadavanje dodatnog uvjeta zaustavljanja i dali je on već zadan. Ako je uvjet zadovoljen, a dodatni uvjet zaustavljanja još nije zadan onda se pristupa zadavanju dodatnog uvjeta zaustavljanja. Dodatnu uvjet zaustavljanja, opisan u odlomku 7.1.4, zadaje se samo jednom tijekom segmentacije jednog presjeka.

Kod računanja osnovnog kriterija zaustavljanja u točki 3 algoritma 4 koristi se jednadžba (3.26) s tom razlikom da se umjesto vrijednosti točaka slike I, koristi vrijednost točaka slike nakon primjene praga I_p. Funkcija praga opisana je jednadžbom (7.4).

$$I_p(x) = \begin{cases} 1 & \text{ako je } I(x) \geq p, \\ 0 & \text{ako je } I(x) < p. \end{cases} \tag{7.4}$$

Prag je definiran tako da izdvoji regiju koje odgovaraju praznini između organa od svih ostalih regija. Vrijednost koju se odabire za prag moguće je odrediti iz histograma dijela CT presjeka na kojem se nalazi aorta. Na slici 4.5 može se vidjeti primjer histograma okolice aorte s označenim karakterističnim lokalnim minimumom. Kako su sve CT snimke korištene u ovom radu napravljene na istom CT uređaju ta vrijednost se nije značajno mijenjala među snimkama pa je ona unaprijed zadana, a njena vrijednost je $p = 1000$.

Primjena praga nužna je kako bi se uklonio utjecaj unutarnjeg ruba aorte, na kojem su vrijednosti gradijenta visoke. Taj visoki gradijent zaustavio bi deformabilni model na unutarnjem rubu aorte ukoliko bi se koristio gradijent slike. Stoga se za segmentaciju vanjskog ruba aorte, u ovom pristupu, koristi gradijent slike na koju je primijenjen prag. Gradijent tada ima visoku vrijednost na rubovima praznog prostora između organa, a jedan od organa je i aorta. Primjena praga ima nedostatak da dodatno uklanja i onako slabo izražene vanjske granice abdominalne aorte.

7.1.4 Dodatni uvjet zaustavljanja

Ukoliko je deformabilni model inicijaliziran na način opisan u prethodnom odlomku, tada bi središte početne kružnice trebalo biti blizu središta vanjskog ruba. Sam vanjski rub najčešće je sličan kružnici. Sada imamo situaciju gdje deformabilni model, koji inicijalno ima oblik kružnice, evoluiramo i nastojimo ga poklopiti s vanjskim rubom aorte koji je sličan kružnici, a centri tih dviju kružnica trebali bi biti relativno blizu. Ukoliko je to istina tada bi sve točke deformabilnog modela trebale stići do vanjskog ruba aorte približno istovremeno ili barem u uskom vremenskom prozoru. Jedine točke deformabilnog modela za koje to ne bi vrijedilo bile bi točke koje se nisu uspjele zaustaviti na slabo izraženom vanjskom rubu i koje su prodrle u susjedno tkivo. Za očekivati je da će se one, u prosjeku, duže kretati od ostalih točaka koje su došle i zaustavile se na vanjskom rubu aorte.

Točke koje su prešle u susjedno tkivo mogle bi se razlikovati od ostalih prema tome da li se još kreću dok su ostale točke stale. S druge strane, nakon što određeni postotak točaka deformabilnog modela stane, može se pretpostaviti da su i ostale točke blizu vanjskog ruba aorte, bio on dobro izražen ili ne. U točki 13 algoritma 4 mjeri se postotak točaka koje su već stale. U ovom radu korištena je vrijednost $s = 2$ što znači da je točka označena kao statična ukoliko se nije pomaknula kroz dvije uzastopne iteracije. Uzimanjem veće vrijednosti s postigla bi se dodatna točnost u označavanju statičnih točaka deformabilnog modela jer uvijek postoji mogućnost da se neka točka koja trenutno stoji, ponovo počne kretati kada se izmjeni situacija u njenom susjedstvu. No veća vrijednost s znači i duže čekanje na ocjenjivanje statičnosti, a o ocjeni statičnosti točaka ovisi razlikovanje točaka koje su prešle u susjedno tkivo. Kada uvjet u točki 13 bude zadovoljen, dodatni uvjet zaustavljanja određuje se na temelju trenutnog stanja nulte razine koje je sa svakom dodatnom iteracijom sve lošije. Potrebno je dakle, u što kraćem roku odrediti koje su točke stale.

U ovom radu odabrana je vrijednost $M = 0.6$ što znači da će dodatni uvjet zaustavljanja biti zadan kada 60% točaka nulte razine stane. Time je određena najveća širina rupe na vanjskom rubu aorte na koju će dodatni uvjet zaustavljanja moći utjecati i ona iznosi približno 40% opsega cijelog vanjskog ruba aorte. Mijenjanjem vrijednosti M mijenja se najveća dozvoljena širina

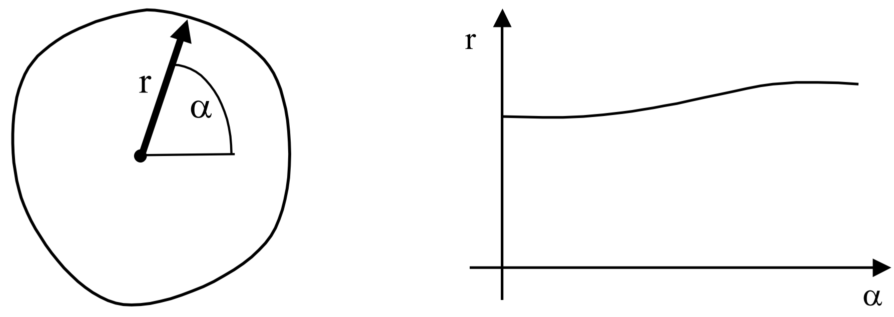

(a) (b)

Slika 7.2: Primjer (a) određivanja funkcije udaljenosti za točke nulte razine i (b) primjer dobivene funkcije udaljenosti.

rupe na vanjskom rubu, ali i trenutak aktivacije dodatnog uvjeta zaustavljanja.

Sam dodatni uvjet zaustavljanja predstavlja svojevrsnu branu, koja se dodaje na sliku i koja će sigurno zaustaviti deformabilni model u točkama u kojima je ona definirana. Ta brana konstruira se pomoću trenutne nulte razine kada je zadovoljen uvjet iz točke 13 algoritma 4. Spomenuta brana u osnovi predstavlja zaglađenu krivulju nulte razine.

Slijedi opis načina na koji se konstruira dodatni uvjet zaustavljanja. Kada je uvjet iz točke 13 algoritma 4 zadovoljen, određuje se središnja točka (centar mase) trenutne nulte razine prema jednadžbama (7.2). Na krivulji nulte razine odabire se 64 točke koje su na jednakim kutnim udaljenostima gledano iz središnje točke. Kut između dviju susjednih točaka tada iznosi $360°/64$. Za te točke određuje se udaljenost od središnje točke prema jednadžbi (7.5).

$$r_\alpha = \sqrt{(x_\alpha - x_c)^2 + (y_\alpha - y_c)^2} \tag{7.5}$$

Primjer dobivene funkcije udaljenosti r_α i načina njenog određivanja prikazani su na slici 7.2. Funkcija r_α transformira se pomoću diskretne Fourierove transformacije (DFT). Iz dobivenog diskretnog spektra eliminiraju se visoke frekvencije te se zadržavaju samo prve četiri frekvencijske komponente. Kako nam je za branu potrebna kontinuirana krivulja potrebno je izvršiti interpolaciju između 64 točke koje bi dobili iz ovakvog diskretnog spektra koji ima 64 komponente. Interpolaciju vršimo u frekvencijskoj domeni tako da dodajemo nulte frekvencijske komponente dok ne bude ukupno 256 komponenti te frekvencijske komponente pomnožimo s koeficijentom $256/64$. Diskretnom inverznom Fourierovom transformacijom dobivamo funkciju udaljenosti za točke brane r_b. Svaku vrijednost od r_b uvećamo za 2. Time nastojimo osigurati da sve točke nulte razine budu unutar brane. Ukoliko to nije slučaj točke izvan brane

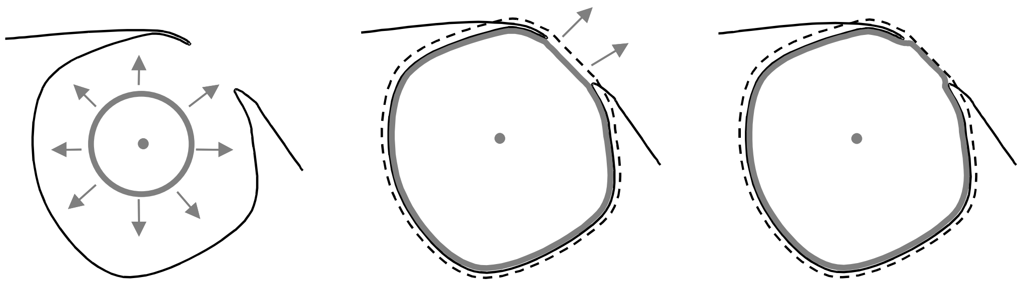

Slika 7.3: Primjer funkcioniranja dodatnog uvjeta zaustavljanja. (a) Početak segmentacije vanjskog ruba aorte koji ima rupu. Siva kružnica predstavlja krivulju nulte razine deformabilnog modela.(b) Trenutak kada su sve točke krivulje nulte razine došle do vanjskog ruba, osim na mjestu rupe. Idealno, u tom trenutku definira se dodatni zaustavni uvjet (brana) temeljen na trenutnoj krivulji nulte razine. (crtkana krivulja) (c) Trenutak kada su točke koje bi inače prošle kroz rupu na granici zaustavljene dodatnim uvjetom zaustavljanja.

će se nastaviti kretati. Dodavanjem veće vrijednosti, povećavala bi se i vjerojatnost da su sve točke nulte razine unutar brane, no veća brana će kasnije zaustaviti točke nulte razine koje su prešle u susjedno tkivo i smanjiti točnost segmentacije. Pomoću prethodno određene središnje točke (x_c, y_c) i nove funkcije udaljenosti r_b definirana je krivulja brane γ_b. U točkama te krivulje $x \in \gamma_b$ vrijednost gradijenta, koju koristi regularni kriterij zaustavljanja, postavlja se na beskonačnu vrijednost. Time je osigurano da će deformabilni model stati kada dođe do brane.

Primjer funkcioniranja dodatnog uvjeta zaustavljanja prikazan je na slici 7.3. Na slici je prikazana situacija u kojoj bi osnovni geometrijski deformabilni model prešao preko slabo izraženog ruba. Na slici 7.3(a), crnom linijom označen je vanjski rub aorte koji je na jednom dijelu prekinut. Taj prekid predstavlja rupu na granici aorte kroz koju bi deformabilni model prešao u okolno tkivo. Na istoj slici sivom bojom prikazana je kružnica koja predstavlja početni oblik nulte razine deformabilnog modela. Strelice označavaju smjer u kojem će se ta krivulja kretati. Na slici 7.3(b) prikazan je trenutak koji je idealan za određivanje dodatnog uvjeta zaustavljanja. Sve točke krivulje nulte razine su zaustavljene na vanjskoj granici aorte, osim točaka koje su došle do rupe u granici. Važno je da te točke još nisu prošle kroz rupu u granici ili barem nisu značajno prošle. Na temelju te krivulje nulte razine konstruira se brana na gore opisani način. nakon toga se nastavlja s evolucijom deformabilnog modela dok sve točke ne stanu. Trenutak kada su zaustavljene sve točke (bilo vanjskim rubom aorte ili branom) prikazan je na slici 7.3(c).

Točnost segmentacije upotrebom ovog pristupa osjetljiva je na istinitost svojih pretpostavki. Ukoliko pretpostavke nisu zadovoljene na nekom presjeku, moguće su situacije gdje će opisani dodatni uvjet zaustavljanja prouzročiti pogrešnu segmentaciju ili gdje neće dobro ispuniti svoju funkciju. Da li će tada doći do pogrešne segmentacije ili ne, ovisi o konkretnoj situaciji tj. slici pa to nije moguće predvidjeti. Sljedeći uvjeti trebaju biti zadovoljeni kako bi segmentacija opisanom metodom dala dobre rezultate:

- Potrebno je da središte mase unutarnjeg ruba aorte bude relativno blizu centru mase stvarnog vanjskog ruba aorte, što ne mora uvijek biti slučaj. Ukoliko to nije istina tada će uvjet iz točke 13 biti zadovoljen prerano ili prekasno što će rezultirati neodgovarajućim dodatnim uvjetom zaustavljanja, a s time i netočnom segmentacijom vanjskog ruba aorte.
- Potrebno je da vanjski rub aorte ima približno kružni oblik, inače se može desiti da opisani dodatni uvjet zaustavljanja neće imati povoljan učinak.

7.1.5 Rezultati i diskusija

Na slikama 7.4 i 7.5 prikazani su rezultati segmentacije gore opisanom metodom na dva presjeka. Slike 7.4(a) i 7.5(a) prikazuju presjeke na kojima je izvršena segmentacija. Na slikama 7.4(b) i 7.5(b) prikazani su gradijenti presjeka. Na obje slike može se uočiti visoki gradijent na unutarnjem rubu aorte. Takav visoki gradijent uspješno zaustavlja deformabilni model (slike 7.4(c) i 7.5(c), najsvjetlija krivulje predstavljaju unutarnji rub aorte). Slike 7.4(d) i 7.5(d) prikazuju rezultate segmentacije unutarnjeg ruba aorte na originalnim slikama presjeka. Na slikama 7.4(e) i 7.5(e) označeni su dijelovi vanjskog ruba aorte koji nisu dovoljno izraženi i nemaju dovoljno visoki gradijent. Stoga je posebno interesantno kako će metoda naći vanjski rub na tim dijelovima slike. Kako se može vidjeti na slikama 7.4(b) i 7.5(b), gradijent unutarnjeg ruba je vrlo visok te ako i ne zaklanja gradijent vanjskog ruba, svakako bi ometao segmentaciju vanjskog ruba. Zbog toga se koristi gradijent slike na koju je primijenjen prag. Rezultat primjene praga na slike presjeka prikazan je na slikama 7.4(f) i 7.5(f) te su na njima označene problematične regije. Na slikama 7.4(g) i 7.5(g) prikazan je gradijent slika 7.4(f) i 7.5(f) koji služi za određivanje osnovnog uvjeta zaustavljanja. Može se vidjeti da korištenje praga još više doprinosi nestanku vanjskog ruba aorte tamo gdje je on slabije izražen. Na slikama 7.4(h) i 7.5(h) prikazani su rezultati segmentacije vanjskog ruba abdominalne aorte. Može se primijetiti da je algoritam uspješno rekonstruirao vanjski rub aorte tamo gdje je on slabije izražen.

Parametri zajednički segmentaciji unutarnjeg i vanjskog ruba	
σ	0.9
δ	6
N_{iter}	4
Segmentacija unutarnjeg ruba	
v_0	-1
ε	0.9
Segmentacija vanjskog ruba	
v_0	-0.45
ε	0.9

Tablica 7.1: Vrijednosti upotrebljenih parametara.

Vrijednosti parametara korištene kod segmentacije dane su u tablici 7.1. Navedene vrijednosti parametara deformabilnog modela određene su eksperimentalno. Kod segmentacije vanjskog ruba korištena je druga vrijednosti za parametar v_0 od one korištene kod segmentacije unutarnjeg ruba aorte. Kod segmentacije vanjskog ruba aorte korištena je otprilike 2 puta manja vrijednost v_0, s ciljem da se promjeni karakter deformabilnog modela kako bi smanjili mogućnost prodora deformabilnog modela u susjedna tkiva. Karakter deformabilnog modela uz danu evolucijsku jednadžbu (7.1) određen je omjerom v_0 i ε tako da bi isti efekt bio postignut povećanjem parametra ε za dva puta i smanjenjem Δt za dva puta.

Metoda opisana u ovom odlomku uvodi nekoliko dodatnih parametara uz parametre samog geometrijskog deformabilnog modela:

1. Prag p čija je vrijednost uzeta je kao konstanta odabrana pomoću informacije proizašle iz samih CT snimaka, a njezin iznos je $p = 1000$. Sve snimke korištene u ovom radu napravljene su na istom CT uređaju te je za sve snimke vrijednost praga bila ista (vidi sliku 4.5). Za snimke načinjene drugim CT uređajem vrijednost praga morala bi se ponovno odrediti iz histograma snimaka. To bi trebalo učiniti samo jednom, a postoji i mogućnost automatskog određivanja odgovarajuće vrijednosti praga za svaku snimku.

2. Vrijednost s koja određuje koliko uzastopnih iteracija točka mora stajati da bi bila uvrštena u statične točke. Vrijednost ovog parametra odabrana je kompromisom jer veći broj iteracija daje dodatnu sigurnost u statičnost točke, ali veći broj iteracija znači i duže čekanje na potvrdu statičnosti. Korištena je vrijednost $s = 2$.

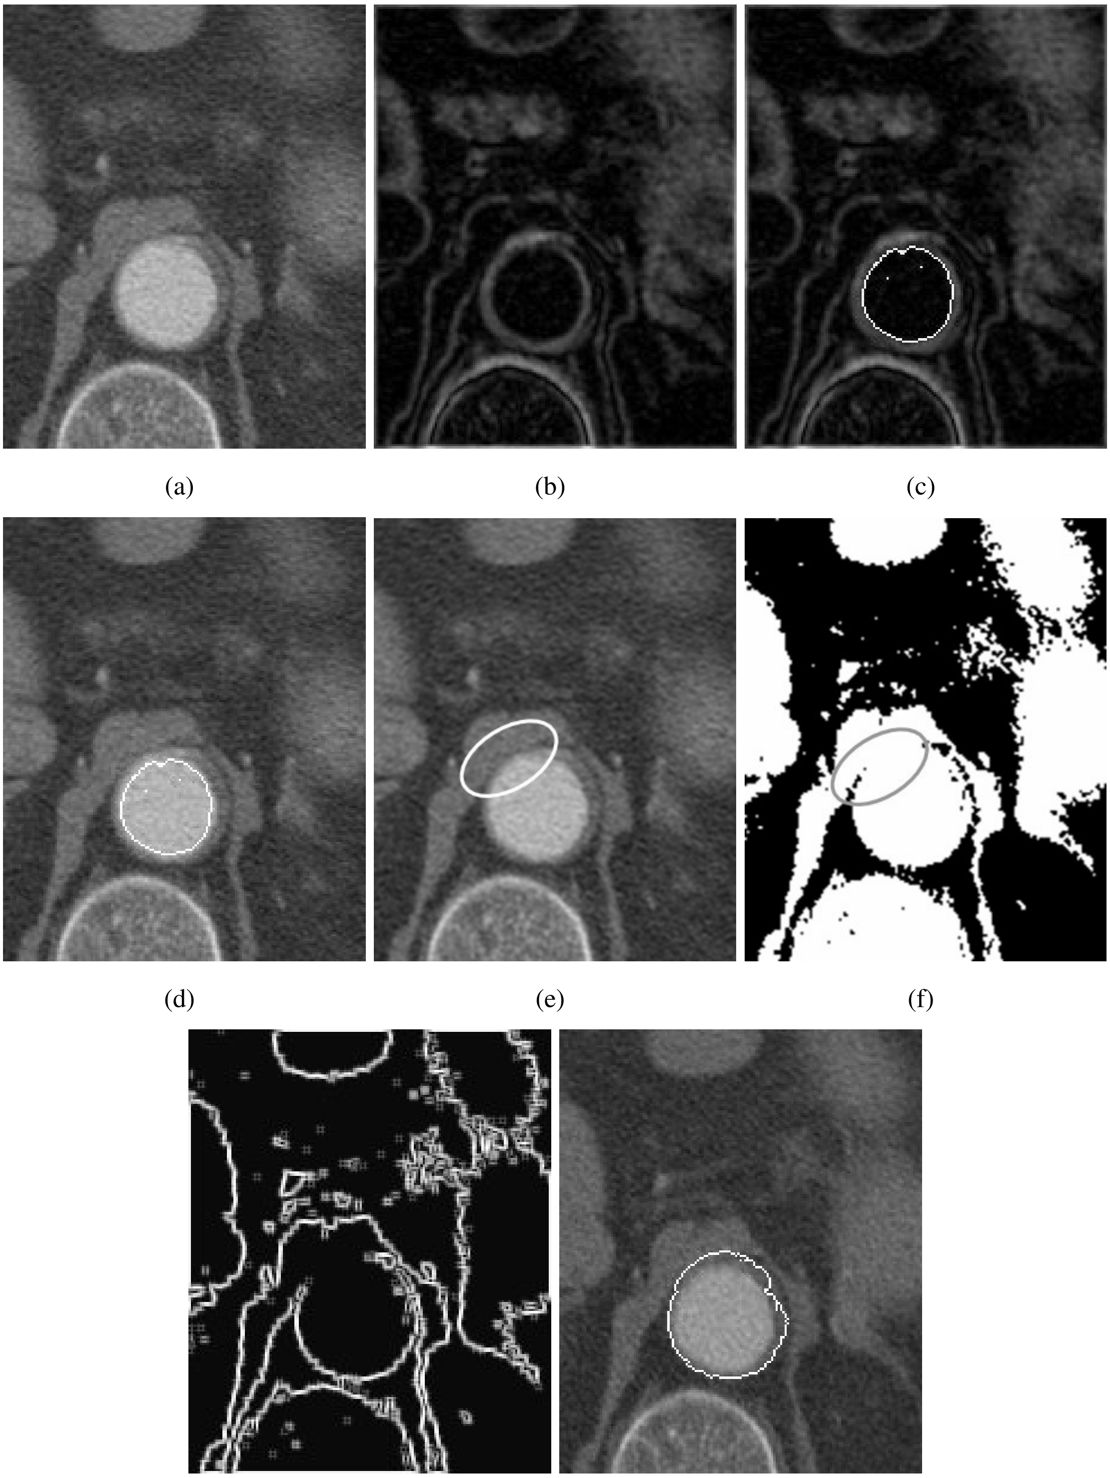

(a) (b) (c) (d) (e) (f) (g) (h)

Slika 7.4: Primjer 1. segmentacije aneurizme abdominalne aorte

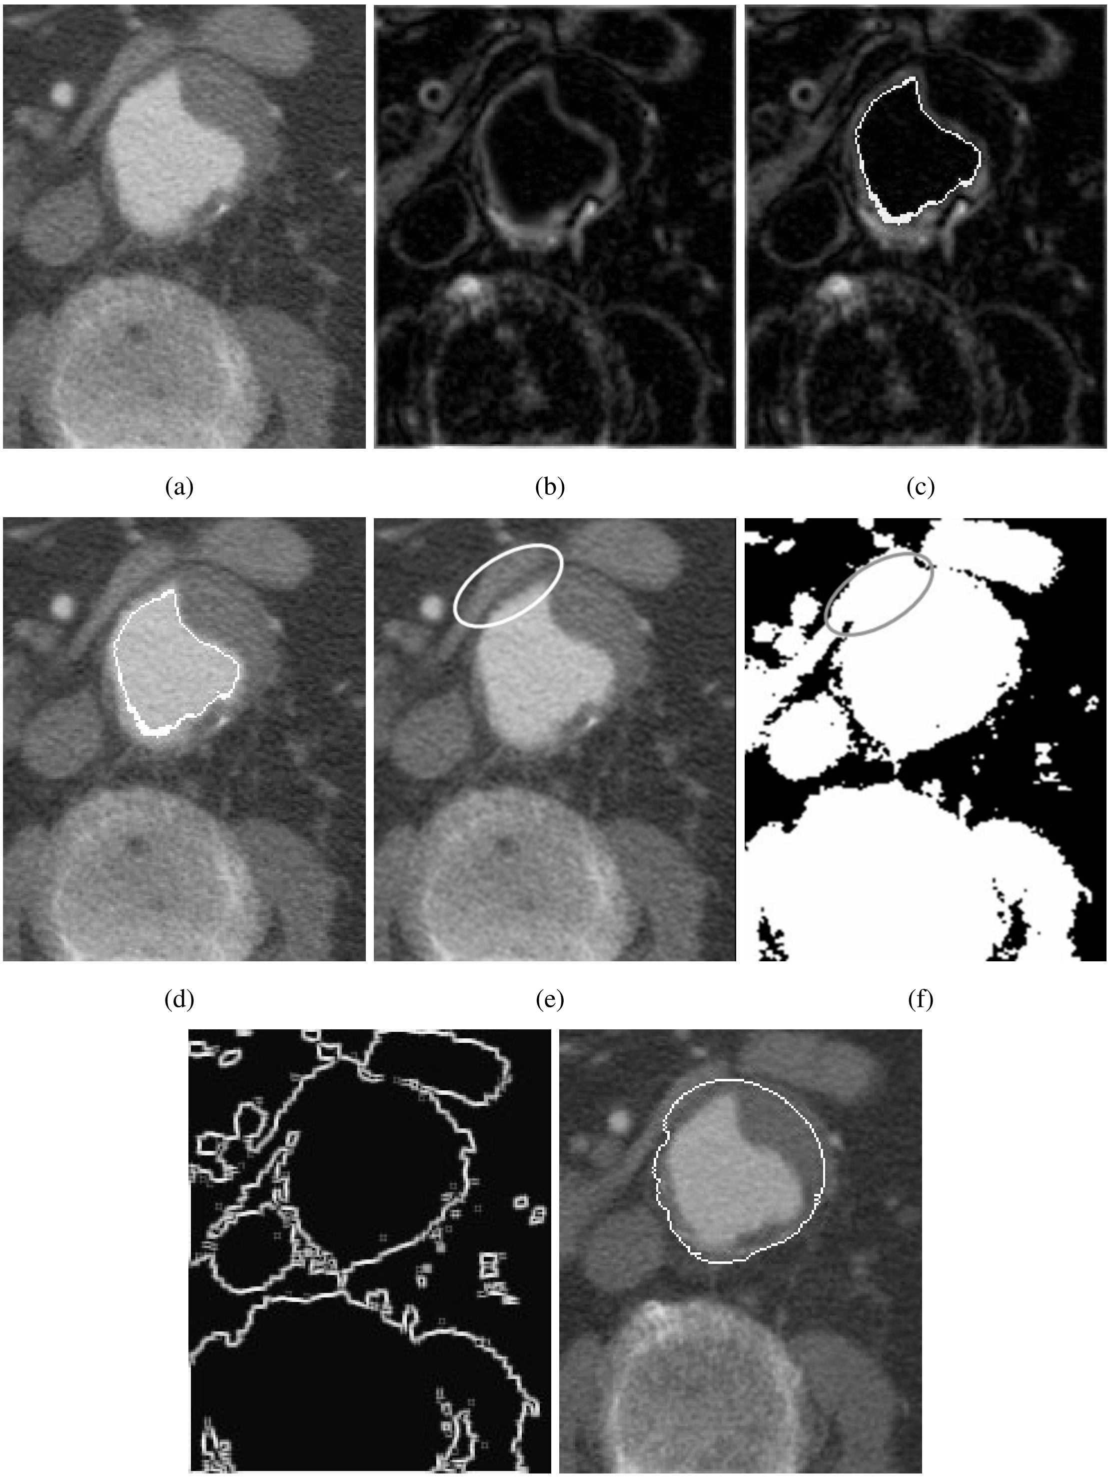

(a) (b) (c)

(d) (e) (f)

(g) (h)

Slika 7.5: Primjer 2. segmentacije aneurizme abdominalne aorte

3. Vrijednost M koja određuje trenutak zadavanja dodatnog kriterija zaustavljanja. Ova vrijednost izabrana je eksperimentalno, a o njezinoj vrijednosti uvelike ovisi efikasnost dodatnog kriterija zaustavljanja. Korištena je vrijednost $M = 0.6$.

4. Način na koji se odabiru točke čija će udaljenost od središta tvoriti funkciju udaljenosti r_α. U gore opisanoj metodi to se odnosi na broj točaka i način njihova odabira.

5. Način zaglađivanja krivulje kod konstruiranja dodatnog kriterija zaustavljanja. U gore opisanoj metodi to se odnosi na broj prvih frekvencijskih komponenti koje se zadržavaju.

6. Iznos za koji se povećavaju udaljenosti r_b. Vrijednost je određena eksperimentalno i predstavlja kompromis između premale vrijednosti, kada postoji mogućnost da segment brane bude unutar krivulje nulte razine, i prevelike vrijednosti, kada bi brana prekasno zaustavila deformabilni model.

Može se vidjeti da je broj dodatnih parametara znatan te da se neki od njih određuju eksperimentalno što smanjuje robusnost i nije pogodno za automatsku segmentaciju. Uspješnost same metode ovisi o tome da li su zadovoljene početne pretpostavke, što nije uvijek slučaj.

7.2 Pristup II

Ovaj pristup se razlikuje od pristupa opisanog u odlomku 7.1 po drugačijem dodatnom uvjetu zaustavljanja korištenom kod segmentacije vanjskog ruba aorte. Za segmentaciju unutarnjeg ruba aorte koristi se 3-D geometrijski deformabilni model identičan onom opisanom u odlomku 7.1.2. Za segmentaciju vanjskog ruba koristi se 2-D geometrijski deformabilni model, što je opet uvjetovano dodatnim kriterijem zaustavljanja. Segmentacija unutarnjeg i vanjskog ruba nisu toliko povezane kao u odlomku 7.1. U ovom pristupu je moguće iskoristiti rezultate segmentacije za određivanje početnih krivulja nultih razina, no nije nužno.

7.2.1 Ideja za dodatni uvjet zaustavljanja

Ideja je došla od promatranja npr. balona koji se napuhava u nekom kalupu koji ima manju rupu na sebi. Nakon nekog vremena balon će naleći na kalup, a na rupi će dio površine balona biti razapet između rubova rupe. Daljnjim napuhavanjem taj dio balona će se početi širiti izvan kalupa. Taj isti dio balona sada je veće površine, odnosno rastegnut je. Svi elementi površine balona koji su nalegli na kalup imat će približno istu rastegnutost, dok će elementi površine balona koji su izvan kalupa biti više rastegnuti. Rastegnutost površine ovdje je moguće koristiti za određivanje da li je određeni dio površine balona prošao kroz rupu na kalupu.

Promatrajmo segment krivulje nulte razine tijekom evolucije deformabilnog modela. Krivulja se sastoji od jednog ili više segmenata. Segment čine povezane točke nulte razine, a segmenti su ograničeni točkama nulte razine koje su već stale. Početna krivulja nulte razine ima samo jedan segment jer niti jedna točka još nije stala. Broj točaka koje se kreću u tom segmentu se povećava tijekom iteracija jer se deformabilni model kreće prema van, tj. povećava se. Taj broj će se povećavati sve dok krivulja ne stigne do granice aorte koja će zaustaviti neke točke deformabilnog modela. Zaustavljanjem točaka, počet će i smanjivanje broja točaka koje se kreću, kao i cijepanje početnog segmenta na više manjih. Ukoliko gledamo određeni dio krivulje, odnosno segment, broj njegovih točaka koje se kreću u početku povećava pa se onda smanjuje dok sve točke ne stanu. To je slučaj kada je vanjski rub aorte dobro izražen. Ukoliko postoji rupa na granici, doći će do ponovnog povećanja broja točaka koje se kreću. Promatranjem povećanja broja točaka koje se kreću mogle bi se razlikovati točke, odnosno segmenti krivulje, koji su došli do rupe u granici aorte.

Na povećanje broja točaka segmenta koje se kreću, može se gledati kao na rastezanje segmenta. Promatrati možemo samo točke koje se kreću jer se samo njihov broj može mijenjati. Broj točaka koje stoje se ne mijenja. Za segment koji je počeo s jednim brojem točaka, a trenutno ih ima duplo više, može se reći da se raširio za dva puta. Ilustracija rastezanja krivulje prikazana je slikom 7.6.

7.2.2 Algoritam za segmentaciju vanjskog ruba aorte

Algoritam koji se koristi u segmentaciji vanjskog ruba aorte prikaza je u algoritmu 5. I to je modifikacija algoritma 1, kojem su dodane točke 4 i 12-20, a točka 1 je izmijenjena.

U točki 3 algoritma 5, isto kao i u 4 u odlomku 7.1.3, koristi se jednadžba (3.26) s tom razlikom da se umjesto vrijednosti točaka slike I, koristi vrijednost točaka slike nakon primjene praga I_p. Funkcija praga opisana je jednadžbom (7.4). Primjena funkcije praga nužna je kako bi se eliminirao utjecaj jakog gradijenta slike na unutarnjem rubu aorte, ali on onda još više pogoršava situaciju oko slabo izraženih vanjskih rubova aorte. Negativan utjecaj, odnosno pojava većih rupa u vanjskoj granici aorte uslijed primjene praga može se vidjeti na slikama 7.7(d), 7.8(d), 7.9(d) i 7.10(d).

Izmjena u točki 1 vezana je uz mogućnost automatske inicijalizacije deformabilnog modela za segmentaciju vanjskog ruba aorte pomoću rezultata segmentacije unutarnjeg ruba aorte.

Algoritam 5 Modificirani algoritam za segmentaciju vanjskog ruba aorte.

Odrediti početnu krivulju/površinu $\mathbf{x}$ iz rezultata segmentacije unutarnjeg ruba aorte ili iz ručne inicijalizacije.
Odredi uski pojas i početnu funkciju Φ.
Izračunaj kriterij zaustavljanja temeljen na rubovima u slici na koju je primijenjen prag p.
$n = 0$
ponavljaj
za i=1 to N_{iter} **izvrši**
Izračunaj koeficijente funkcije brzine koji ovise o Φ.
Izvrši jednadžbu za mijenjanje funkcije Φ.
završi za
Nađi novu nultu razinu u uskom pojasu.
Odredi novi uski pojas i odredi funkciju Φ u uskom pojasu.
Odredi pokretne segmente krivulje nulte razine i provedi prilagodbe kod cijepanja ili stapanja segmenata.
za svaki segment a krivulje nulte razine **izvrši**
Neka je $r_a^n = r_a^{n-1} \frac{N_a^n + S_a^n}{N_a^{n-1}}$
Neka je $s_a^n = \frac{N^n}{N^{n-1}}$
ako $s_a^n > s_p \quad \text{i} \quad r_a^n > r_p$ **onda**
Zaustavi daljnju evoluciju segmenta.
završi ako
završi za
$n = n + 1$
dok Deformabilni model ne stane

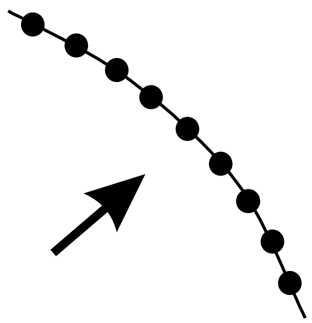

(a) Početni segment krivulje s oznakama točaka (puni kružići) i naznačenim smjerom rastezanja

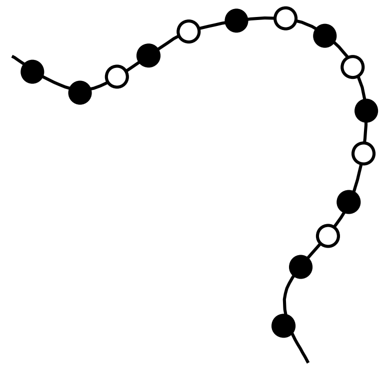

(b) Rastegnuti segment krivulje s oznakama starih (puni kružići) i novih (prazni kružići) točaka

Slika 7.6: Primjer rastezanja segmenta krivulje

Kako dolje opisani dodatni uvjet zaustavljanja nije toliko osjetljiv na inicijalizaciju, nije nužna tolika povezanost segmentacija unutarnjeg i vanjskog ruba. Ukoliko nema potrebe za segmentacijom unutarnjeg ruba, inicijalizacija deformabilnog modela može se izvršiti i ručnim zadavanjem početne krivulje, tj. kružnice. Jedini problem predstavlja činjenica da se za segmentaciju vanjskog ruba koristi 2-D deformabilni model na svakom presjeku, pa bi bilo potrebno napraviti ručnu inicijalizaciju za svaki presjek. To se rješava tako da se ručno inicijalizira deformabilni model samo na jednom presjeku, a za ostale presjeke se koristi inicijalizacija temeljena na rezultatu segmentacije na susjednom presjeku. Segmentacija tada kreće od početnog presjeka te se nastavlja na susjednim presjecima iznad i ispod njega pa zatim na njima susjedne presjeke itd.

Dodatni uvjet zaustavljanja u algoritmu 5 definiran je u točkama 13-19, i detaljnije je opisan u sljedećem odlomku. Točke 4 i 20 dodane su radi praćenja iteracija. Praćenje iteracija potrebno je za dodatni uvjet zaustavljanja, gdje se određeni koeficijenti (r^n, s^n, N^n i S^n) određuju na temelju istih koeficijenata, ali iz prethodne iteracije. Takav način praćenja nije praktičan jer on pohranjuje i čuva vrijednosti koeficijenata iz svih iteracija. Stoga je praćenje iteracija i računanje koeficijenata dodatnog uvjeta zaustavljanja samo navedeno na taj način u algoritmu 5 radi jednostavnosti, a algoritam segmentacije korištenom u ovom radu koristi drugi način opisan u sljedećem odlomku.

7.2.3 Dodatni uvjet zaustavljanja

Postavlja se pitanje kako pratiti rastezanje segmenta krivulje i kako nastaviti praćenje rastezanja nakon podjele segmenta u dva manja segmenta. Koeficijent rastegnutosti segmenta krivulje definiran je jednadžbom (7.6) i računa se u točki 14 algoritma 5.

$$r^n = r^{n-1}\frac{N^n + S^n}{N^{n-1}} \tag{7.6}$$

Ovdje r^n predstavlja faktor rastegnutosti segmenta u n-toj iteraciji, N^n predstavlja broj pokretnih točaka segmenta, a S^n broj točaka koje su stale u n-toj iteraciji. Početni koeficijent rastegnutosti ima vrijednost $r^0 = 1$.

Ovako definiran faktor rastegnutosti se stalno povećava ako se deformabilni model širi. Ukoliko želimo koristiti rastegnutost za detekciju prolaska kroz rupu na granici, tada zadajemo prag rastegnutosti r_p. Ukoliko koeficijent rastegnuti preraste zadani prag smatra se da je segment prošao kroz rupu u granici aorte te se taj segment zaustavlja. Premali prag zaustavit će segmente krivulje prije nego oni dođu do vanjskog ruba aorte. Preveliki prag neće pravovremeno zaustaviti segmente koji prođu kroz rupe u vanjskoj granici aorte. Ovako definirani koeficijent rastegnutosti ovisi o opsegu početne krivulje i o opsegu završne krivulje tj. o opsegu vanjskog ruba aorte. Ukoliko se oni znatno razlikuju, svi segmenti krivulje imat će visok koeficijent rastegnutosti. Ukoliko je razlika opsega mala, svi segmenti imat će malu rastegnutost. Stoga prag rastegnutosti ne bi funkcionirao u svim situacijama jer bi u određenim situacijama bio prevelik, a u drugima premalen.

Kako bi riješili ovaj problem korišten je koeficijent širenja segmenta s definiran jednadžbom (7.7), koji se računa u točki 15 algoritma 5.

$$s^n = \frac{N^n}{N^{n-1}} \tag{7.7}$$

Ukoliko se broj točaka segmenta koje se kreću poveća u jednoj iteraciji, tada je koeficijent širenja tog segmenta veći od 1. Ukoliko se broj pokretnih točaka smanji koeficijent širenja manji je od 1. Koeficijentom širenja nastoji se razlikovati segmente koji se bliže vanjskom rubu aorte te se smanjuje broj njihovih točaka koje se kreću i segmente koji su prošli kroz rupu u granici aorte te se povećava broj njihovih točaka koje se kreću. Segmente koji se približavaju vanjskom rubu aorte možemo prepoznati po tome da li je njihov faktor širenja manji od zadane vrijednosti praga s_p (obično je $s_p \leq 1$).

Kombinaciju koeficijenata širenja i rastegnutosti možemo iskoristiti za detekciju segmenata koji su ušli u rupe u granici aorte. Ukoliko je za neki segment zadovoljen uvjet da je

$$s^n > s_p \quad \text{i} \quad r^n > r_p, \tag{7.8}$$

tada smatramo da je taj segment prošao kroz rupu u granici aorte te ga zaustavljamo. Kako bi se mogle koristiti jednadžbe (7.6) i (7.8) potrebno je implementirati praćenje segmenata krivulje nulte razine u algoritmu segmentacije. Preciznije, potrebno je znati koje su točke krivulje proizašle iz kojeg segmenta, kako bi se mogla pratiti promjena broja pokretnih točaka u segmentima.

Kako bi uopće mogli pratiti segmente potreban je mehanizam za određivanje pokretnih i statičnih točaka. Kako se u ovom pristupu koristi ubrzanje level-set algoritma (opisano u poglavlju 6) koje već vrši određivanje pokretljivosti točaka, to se onda može koristiti za praćenje segmenata.

Za računanje koeficijenta r^n koristi se iterativne jednadžba (7.6) te je potrebno imati na raspolaganju njegovu vrijednost za svaki segment iz prošle iteracije. Također je potrebno znati i broj pokretnih točaka N za svaki segment iz prethodne iteracije, za računanje r^n i s^n. U tu svrhu nije potrebno pamtiti sve te parametre za sve iteracije, već samo za sadašnju i za prethodnu iteraciju. Jednom kada su stare vrijednosti iskorištene za računanje novih vrijednosti koeficijenata, te vrijednosti postaju stare vrijednosti za sljedeću iteraciju. Samo pohranjivanje koeficijenata uključeno je u praćenje segmenata, jer se segmenti mogu cijepati i spajati.

Za praćenje segmenata koristi se polje indeksa koje odgovara polju pokazivača uskog pojasa. Uski pojas je podijeljen na dijelove prema tome kojem segmentu nulte razine taj dio uskog pojasa pripada. Svakoj točki uskog pojasa pridjeljuje se indeks dijela uskog pojasa kojem pripada. Svakom segmentu pridjeljuju se i njegove vrijednosti koeficijenata r i s te broj pokretnih točaka N. Nakon jedne iteracije traži se nova nulta razina u cijelom uskom pojasu, koja se zatim dijeli na dijelove ovisno u kojem dijelu uskog pojasa se nalazi. Za svaki dio nulte razine računa se broj pokretnih i statičnih točaka. Zatim se grade segmenti koji čine skupove međusobno povezanih pokretnih točaka. Za te segmente računaju se parametri r i s. Ukoliko je došlo do cijepanja ili stapanja segmenata (u jednom dijelu uskog pojasa se pojavi više segmenata ili se jedan segment proteže kroz različite dijelove uskog pojasa), potrebno je, u točki 12 algoritma 5, za takve segmente odrediti vrijednosti koeficijenata iz prethodne iteracije (koje ne postoje jer u prethodnoj iteraciji tih segmenata nije bilo), a na temelju vrijednosti koeficijenata segmenata iz kojih su nastali.

Ukoliko je došlo do cijepanja jednog segmenta na dva dijela obadva nasljeđuju isti faktor rastezanja r iz prethodne iteracije $r^n_{c1} = r^n_{c2} = r^n_{12}$), od segmenta iz kojeg su nastali. Broj pokretnih točaka N starog segmenta iz prethodne iteracije N_{12}^{n-1} dijeli se u skladu s omjerom pokretnih točaka u novoj iteraciji (N_{c1}^{n-1} i N_{c2}^{n-1}) prema jednadžbi (7.9). S tim vrijednostima moguće je izračunati nove koeficijente r i s za novonastale segmente.

$$
\begin{aligned}
N_{c1}^{n-1} &= N_{12}^{n-1} \frac{N_{c1}^{n}}{N_{c1}^{n} + N_{c2}^{n}} \\
N_{c2}^{n-1} &= N_{12}^{n-1} \frac{N_{c2}^{n}}{N_{c1}^{n} + N_{c2}^{n}}
\end{aligned}
\tag{7.9}
$$

Ukoliko je došlo do stapanja dvaju segmenata, koeficijent rastezanja r_{12}^{n-1} iz prethodne iteracije računa u skladu s omjerom pokretnih točaka starih segmenata (N_{s1}^{n-1} i N_{s2}^{n-1}) prema formuli (7.10).

$$
r_{12}^{n-1} = \frac{r_{s1}^{n-1} \cdot N_{s1}^{n-1} + r_{s2}^{n-1} \cdot N_{s2}^{n-1}}{N_{s1}^{n-1} + N_{s2}^{n}} \tag{7.10}
$$

Broj pokretnih točaka iz prethodne iteracije novog segmenta N_{12}^{n-1} predstavlja ukupan broj pokretnih točaka starih segmenata prema jednadžbi (7.11).

$$
N_{12}^{n-1} = N_{s1}^{n-1} + N_{s2}^{n-1} \tag{7.11}
$$

7.2.4 Rezultati i diskusija

Rezultati segmentacije aorte opisanim pristupom prikazani su na slikama 7.7, 7.8, 7.9 i 7.10. Na slikama 7.7(a), 7.8(a), 7.9(a) i 7.10(a) prikazani su originalni CT presjeci. Na slikama 7.7(b), 7.8(b), 7.9(b) i 7.10(b) prikazani su gradijenti originalnih presjeka. Na slikama gradijenta može se uočiti visoki gradijent na unutarnjem rubu aorte, a može se i uočiti mjestimično slabiji gradijent na vanjskim rubovima aorte. Slike 7.7(c), 7.8(c), 7.9(c) i 7.10(c) prikazuju rezultate segmentacije unutarnjeg ruba aorte, koji su vrlo dobri upravo zbog visokog gradijenta na unutarnjem rubu aorte. Slike 7.7(d), 7.8(d), 7.9(d) i 7.10(d) prikazuju gradijent slika na koje je primijenjen prag. Taj gradijent trebao bi imati visoke vrijednosti na vanjskoj granici aorte, ali se mogu uočiti mjestimične rupe u vanjskoj granici aorte, koje su posljedica slabo izraženih vanjskih granica aorte, ali i primjene funkcije praga na slike. Slike 7.7(e), 7.8(e), 7.9(e) i 7.10(e) prikazuju rezultate segmentacije vanjskih rubova aorte.

Kod segmentacije vanjskog ruba na presjeku 7.7(a) bilo je potrebno prevladati samo jednu rupu u vanjskoj granici aorte vidljivu na slici 7.7(d). Dodatni uvjet zaustavljanja uspješno je

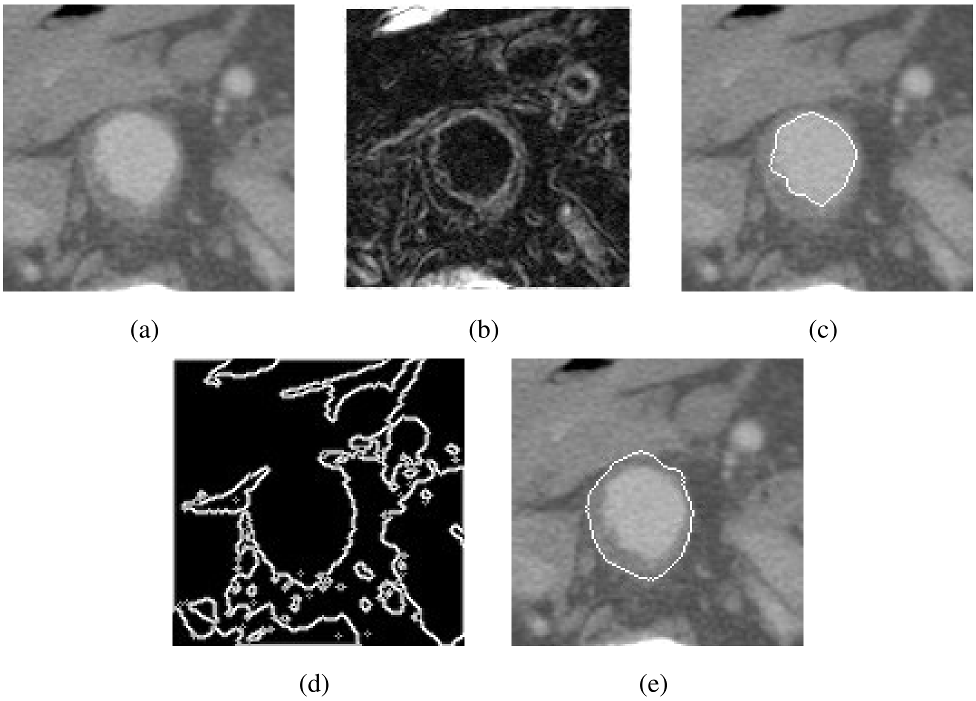

Slika 7.7: Primjer 1. segmentacije aneurizme abdominalne aorte

rekonstruirao vanjski rub kao što se vidi na slici 7.7(e). Kod segmentacije vanjskog ruba na presjeku 7.8(a) bilo je potrebno rekonstruirati vanjsku granicu na dvjema rupama (slika 7.8(d)), što je također uspješno savladano (slika 7.8(e)). Kod segmentacije vanjskog ruba na presjeku 7.9(a) bilo je potrebno rekonstruirati vanjsku granicu na tri rupe vidljive na slici 7.9(d). Rezultati segmentacije vanjskog ruba, prikazani na slici 7.9(e), nešto su lošiji u ovom slučaju. Na najdoljnjoj rupi u vanjskoj granici dodatni uvjet zaustavljanja nije pravovremeno djelovao te je deformabilni model malo prešao u područje kralježnice. Kod segmentacije vanjskog ruba na presjeku 7.10(a) bilo je potrebno rekonstruirati vanjsku granicu na jednoj rupi koja je relativno velika u odnosu na opseg vanjskog ruba aorte, kao što se može vidjeti na slici 7.10(d). Zahvaljujući dodatnom uvjetu zaustavljanja, rezultat segmentacije vanjskog ruba aorte na slici 7.10(e) izgleda zadovoljavajuće.

Kako je kod segmentacije unutarnjeg ruba aorte korišten isti algoritam segmentacije kao i u odlomku 7.1.2, korišteni su i isti parametri u tom algoritmu. Algoritam, korišten za segmentaciju vanjskog ruba aorte, identičan je onom opisanom u odlomku 7.1.3 izuzev dodatnog uvjeta zaustavljanja. Stoga su vrijednosti parametara samog level-set algoritma za segmentaciju vanjskog i unutarnjeg ruba aorte isti kao oni dani u tablici 7.1.

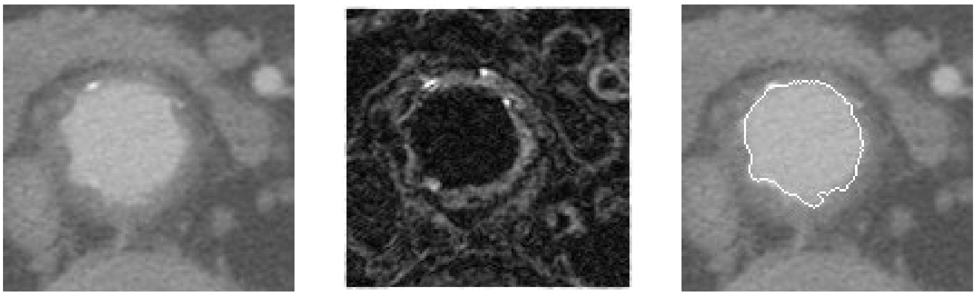

(a) (b) (c)

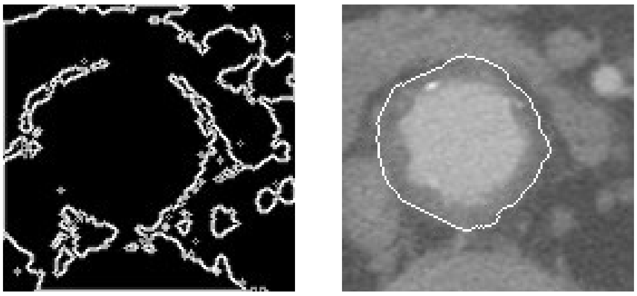

(d) (e)

Slika 7.8: Primjer 2. segmentacije aneurizme abdominalne aorte

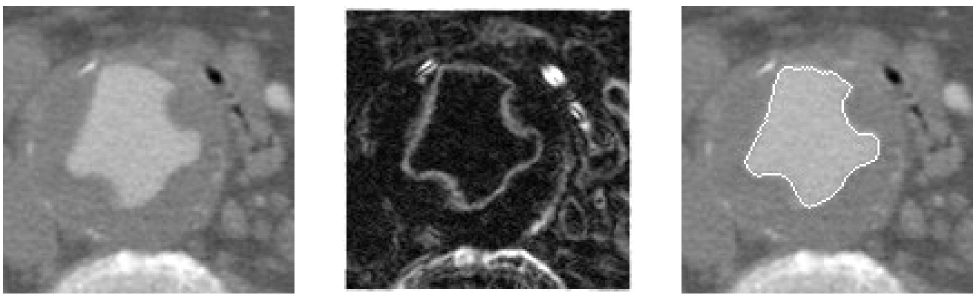

(a) (b) (c)

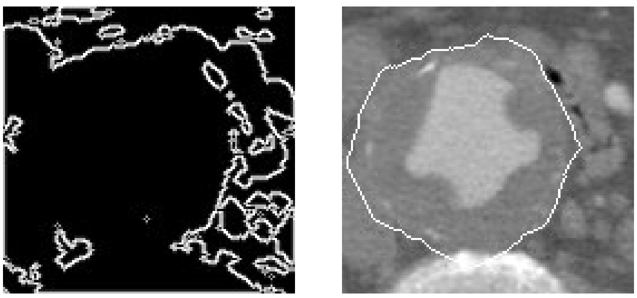

(d) (e)

Slika 7.9: Primjer 3. segmentacije aneurizme abdominalne aorte

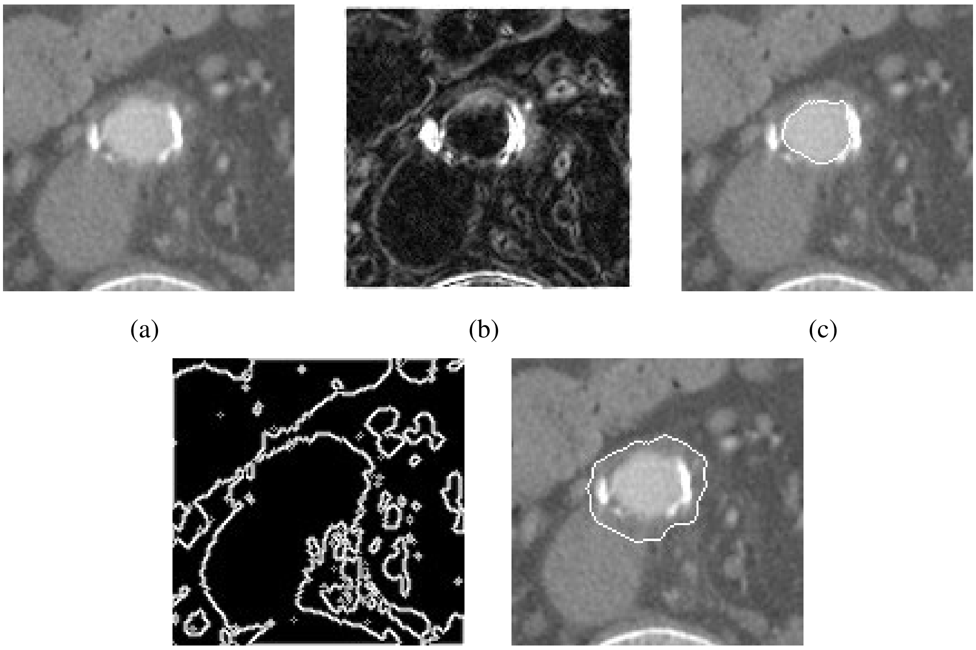

(a) (b) (c)

(d) (e)

Slika 7.10: Primjer 4. segmentacije aneurizme abdominalne aorte

Vrijednost praga p korištenog u segmentaciji vanjskog ruba aorte isto ima iznos $p = 1000$ i odabran je na način opisan u 7.1.5. Ostaje još samo definirati vrijednosti parametara vezanih uz novi dodatni uvjet zaustavljanja:

1. Vrijednost praga r_p koeficijenta rastegnutosti ima ključnu ulogu u funkcioniranju dodatnog uvjeta zaustavljanja. Njegova vrijednost određena je eksperimentalno te ona iznosi $r_p = 3$. Ta vrijednost odabrana je kao vrijednost koja je dala najbolje rezultate segmentacije na testiranom uzorku CT snimaka.

2. Vrijednost praga s_p koeficijenta širenja koristi se za razlikovanje segmenata koji se približavaju izraženom vanjskom rubu od onih segmenata koji se približavaju rupi u vanjskom rubu aorte. Ako se uzme u obzir ponašanje koeficijenta širenja opisano u 7.2.3 prirodan odabir za s_p je 1. Kada je $s_p < 1$ taj segment se bliži vanjskom rubu, a kada je $s_p \geq 1$ segment se približava rupi u vanjskoj granici aorte.

Ovdje opisani dodatni uvjet zaustavljanja nije toliko osjetljiv na inicijalizaciju deformabilnog modela za segmentaciju vanjskog ruba aorte, kao što je to slučaj s dodatnim uvjetom zaustavljanja u 7.1. Stoga se inicijalizacija može vršiti i ručno, odnosno nije potrebno vršiti segmentaciju unutarnjeg ruba aorte, ako unutarnji rub aorte nije interesantan. S druge strane, dobra inicijalizacija može pozitivno utjecati na točnost segmentacije vanjskog ruba. Ukoliko je inicijalna kružnica zadana blizu vanjskog ruba aorte, kada deformabilni model dođe do dijametralno suprotne točke vanjskog ruba, njegova rastegnutost r na tom dijelu može biti povećana te dodatni uvjet zaustavljanja može zaustaviti segment iako to nije potrebno. Postavljanje inicijalne kružnice blizu centralne točke aorte ručnom metodom je jednostavno i ne zahtjeva dodatne naprezanje operatera, a najčešće je i njegov prirodni odabir. Automatska inicijalizacija, bilo da se temelji na središtu unutarnjeg ruba aorte, ili na središtu vanjskog ruba aorte sa susjednog segmentiranog presjeka najčešće rezultiraju odgovarajuće smještenom inicijalnom kružnicom. Stoga navedena osjetljivost na inicijalizaciju ne dolazi do značajnijeg izražaja.

Veći problem predstavlja osjetljivost rezultata na prag r_p Pojednostavljeno, njegova vrijednost je omjer opsega završne krivulje vanjskog ruba aorte i opsega inicijalne kružnice. Dok je opseg inicijalne kružnice moguće kontrolirati, opseg vanjskog ruba aorte nije moguće unaprijed znati. Zato je vrijednost praga r_p određena eksperimentalno. Ukoliko je r_p premalen dodatni uvjet zaustavljanja će zaustavljati segmente prije nego je potrebno, a ukoliko je r_p prevelik zaustavljanje segmenata dešavat će se prekasno kada oni već duboko prodru u susjedno tkivo. Ovdje može pomoći automatska inicijalizacija na temelju unutarnjeg ruba aorte. Tada su radijus i središte kružnice određeni unutarnjom granicom aorte, odnosno položajem njenih točaka, njihovom središnjom točkom i opsegom. Omjer opseg unutarnjeg i vanjskog ruba aorte u području aneurizme, najčešće ne varira puno, tako da odabir opsega inicijalne kružnice za segmentaciju vanjskog ruba aorte temeljem opsega unutarnjeg ruba aorte može smanjiti osjetljivost metode na iznos r_p.

Nedostatak ove metode je što ona može zaustaviti prodiranje deformabilnog modela u okolno tkivo tek kada je takvo prodiranje detektirano. Na taj način nemoguće je posve izbjeći prodiranje u okolno tkivo koje se može vidjeti na slici 7.10(e), već se ono može samo zaustaviti. Ostaje i problem dvojnosti, odnosno mogućnosti da se pojave dva identična slučaja/presjeka, gledano iz perspektive dodatnog uvjeta zaustavljanja, ali da su to u stvari različiti slučajevi, od kojih jedan traži primjenu dodatnog uvjeta zaustavljanja, a drugi ne. To je najvjerojatnije posljedica ograničenja CT snimanja i CT uređaja, budući da iste probleme imaju i operateri kod ručne segmentacije.

7.3 Pristup III

U ovom pristupu, za razliku od prethodna dva, nema praćenja evolucije deformabilnog modela, kako bi se spriječilo prodiranje u okolno tkivo nakon što ono počne. Ovdje se prodiranje nastoji spriječiti prije nego što se ono desi, što bi trebalo dati bolje rezultate. Kako problem predstavljaju slabo izražene vanjske granice aorte, u ovom pristupu njih se pokušava rekonstruirati prije puštanja u pogon geometrijskog deformabilnog modela. Umjesto dodatnog uvjeta zaustavljanja iz prethodna dva pristupa, ovdje imamo predprocesiranje, tj. rekonstrukciju. Prilikom rekonstrukcije slabije izraženih vanjskih rubova aorte, iskorišteno je znanje o obliku aorte te znanje o distribuciji intenziteta CT snimaka koje su bile na raspolaganju.

Za segmentaciju unutarnjeg i vanjskog ruba korišten je 3-D geometrijski deformabilni model. Sama rekonstrukcija vanjskog ruba aorte obavlja se presjek po presjek, no ukupni rezultat rekonstrukcije svih presjeka predstavlja binarni volumen. U tom volumenu točke s vrijednošću 1 predstavljaju aortu, a točke sa vrijednošću 0 predstavljaju pozadinu. Taj volumen, odnosno gradijent zasnovan na njemu koristi se za određivanje uvjeta zaustavljanja kod segmentacije vanjskog ruba aorte.

7.3.1 Ideja za rekonstruiranje vanjskog ruba aorte

Rekonstrukcija se sastoji od nekoliko koraka. Za svaki od njih će biti iznesen razlog njegovog korištenja.

- U prethodna dva pristupa korištena je funkcija praga 7.4 koja je globalnog karaktera, odnosno na sve točke primjenjuje se isti prag p. U ovom pristupu koristi se lokalna funkcija praga u kojoj je vrijednost praga p određena konstantom i intenzitetom susjednih točaka. Korištenjem lokalnog praga eliminira se utjecaj varijacije svjetline na presjecima te se time nastoji smanjiti mogućnost maskiranja slabo izražene granice aorte.

- Upotreba lokalnog praga vjerojatno će ukloniti neke slabije izražene granice aorte, a u nekim slučajevima ta granica nije niti vidljiva. Kako bi još više smanjili vjerojatnost da vidljiva granica bude uklonjena primjenom praga, granicu nastojimo pojačati kombinacijom gradijenta slike i praga. Prag ovdje služi za eliminaciju svijetle unutrašnjosti aorte i visokog gradijenta kojeg ona proizvodi. Prag se primjenjuje i na gradijent, kako bi se otklonio gradijent prouzročen šumom. Preostali gradijent na slici trebao bi sadržavati i vanjsku granicu aorte i on se koristi kako bi se ojačala slabo izražena vanjska granica aorte.

- Primjenom gornjih koraka dobiva se binarna slika (svaka točka ima vrijednost 0 ili 1) gdje jedinice predstavljaju, najčešće više odvojenih regija među kojima bi trebala biti i aorte. Sve povezane regije koje sadrže manji broj točaka uklanjaju se zbog pretpostavke da su one posljedica šuma. Malim regijama koje imaju vrijednost 1, vrijednost se mijenja u 0. Malim regijama koje imaju vrijednost 0, vrijednost se mijenja u 1. Nakon ovog koraka ostaju samo veće regije među kojima je i aorta.

- Oblik aorte na jednom presjeku je kružnica ili elipsa. Kod aneurizme, aorta je izobličena, no najčešće zadržava oblik sličan kružnici. Taj oblik je približno konveksan, a konkavni dijelovi ruba aorte najčešće ne ulaze duboko u aortu. Kako bi to iskoristili definiran je uvjet koji bi oblik aneurizme abdominalne aorte trebao zadovoljavati, a pokazalo se da je to najčešće istina. Ukoliko definiramo središnju točku aorte, sve točke na njenom rubu mogu ravnom linijom biti povezane sa središtem, a linija mora u cijelosti biti unutar regije aorte. Ukoliko postoje točke na rubu regije za koju pretpostavljamo da je aorte, tada je najvjerojatnije riječ o rupi na slabo izraženoj granici. Uklanjanje regija koje pripadaju okolnom tkivu vrši se pomoću mape udaljenosti i njenog gradijenta, kako je opisano u odlomku 7.3.3.

- Kalcifikacije koje se ponekad javljaju kod aneurizme u zidu aorte, često se nalaze uz vanjski rub aorte. One imaju vrlo visoke vrijednosti intenziteta i jasno su vidljive na CT presjecima. Ako se kalcifikacija pojavi uz vanjski rub aorte koji je ujedno i slabije izražen, tada se kalcifikacija može iskoristiti za rekonstrukciju slabije izraženog vanjskog ruba aorte.

Svaki od ovih relativno jednostavnih koraka sam za sebe ne bi bio dovoljan za uspješnu rekonstrukciju vanjskog ruba aorte, no njihovim kombiniranjem vjerojatnost uspješnog rekonstruiranja postaje veća.

7.3.2 Algoritam za segmentaciju unutarnjeg i vanjskog ruba aorte

Za segmentaciju unutarnjeg i vanjskog ruba koristi se isti algoritam za 3-D geometrijski deformabilni model, koji je prikazan algoritmom 6. Jedina razlika u odnosu na algoritma 1 je u umetnutim točkama 1-4 koje izvršavaju rekonstrukciju vanjskog ruba aorte ukoliko se radi o segmentaciji vanjskog ruba aorte. Postupak rekonstrukcije vanjskog ruba aorte opisan je u sljedećem odlomku. On kao rezultat vraća binarni volumen I_b u kojem sve točke s vrijednošću 1 predstavljaju aortu, a sve točke s vrijednošću 0 predstavljaju pozadinu. Binarni volumen I_b se postavlja kao ulazni podatak za segmentaciju umjesto originalnog CT volumena, te se koristi u točki 7 algoritma 6.

Algoritam 6 Algoritam za segmentaciju unutarnjeg i vanjskog ruba aorte.

1: **ako** se segmentira vanjski rub aorte **onda**
2: Izvrši rekonstrukciju vanjskog ruba koja vraća binarni volumen I_b.
3: Neka je I_b ulazni podatak za segmentaciju.
4: **završi ako**
5: Zadaj početnu krivulju/površinu $\mathbf{x}$.
6: Odredi uski pojas i početnu funkciju Φ.
7: Izračunaj kriterij zaustavljanja temeljen na rubovima u volumenu.
8: **ponavljaj**
9: **za** $i = 1$ do N_{iter} **izvrši**
10: Izračunaj koeficijente funkcije brzine koji ovise o Φ.
11: Izvrši jednadžbu za mijenjanje funkcije Φ.
12: **završi za**
13: Nađi novu nultu razinu u uskom pojasu.
14: Odredi novi uski pojas i odredi funkciju Φ u uskom pojasu.
15: **dok** Deformabilni model ne stane

7.3.3 Postupak rekonstrukcije slabo izraženog vanjskog ruba aorte

Sama rekonstrukcija u osnovi je segmentacija jer je njezina funkcija izdvojiti regiju koja predstavlja aortu iz volumena CT snimke. No svrha rekonstrukcije ipak je rekonstrukcija vanjskog ruba aorte i cijeli postupak osmišljen je s tom namjerom, tako da sama rekonstrukcija ne bi dala zadovoljavajuće rezultate ako bi se koristila za segmentaciju aorte. Stoga na rezultate rekonstrukcije primjenjujemo 3-D deformabilni model koji svojim pozitivnim svojstvima poboljšava segmentaciju. Rekonstruiranje vanjskog ruba aorte vrši se na svakom presjeku posebno. Počinje se od presjeka na kojem je izvršena inicijalizacija te se nastavlja na susjedne presjeke pa na njima susjedne itd. Ovakav redoslijed potreban je radi toga što se kod rekonstrukcije na jednom presjeku koristi rezultat rekonstrukcije iz njemu susjednog i već obrađenog presjeka. Algoritmom 7 rekonstruira se slabije izražena vanjska granica aorte na jednom presjeku. Slijedi opis točaka algoritma 7:

1. Slika I predstavlja trenutni presjek.

Algoritam 7 Algoritam za rekonstrukciju slabije izraženog vanjskog ruba aorte.

1: Neka je I slika koja odgovara trenutnom presjeku.
2: Neka je I_{-1} skup točaka slike koje odgovaraju točkama aorte u susjednom, već procesiranom presjeku.
3: Neka je $E = \{p \in D_I | I(p) > t_3\}$ podskup slike I gdje sve točke imaju intenzitet veći od praznog prostora abdominalne šupljine.
4: Neka je $M = \{p \in D_I | I(p) < t_0, I(p) < [t_1 + (I_s(p) - t_1) \cdot k]$ i $G(p) > t_2\}$ podskup slike I gdje sve točke imaju nizak intenzitet i visok gradijent slike, $I_s(p)$ predstavlja srednju vrijednost intenziteta u okolici točke p.
5: Neka je $X = E \setminus M$ regija E iz koje su izuzete granice regija sadržane u M.
6: Ukloni male regije iz pozadine ($D_I \setminus X$) te ih dodaj u X.
7: Ukloni male regije iz X.
8: Neka je C skup piksela koji predstavljaju vanjske rubove kalcifikacija (vidi algoritam 8).
9: Neka je $Z = X \setminus C$.
10: Neka je $p_c \in I_{-1}, DM(p_c, Z) = \max(DM(p, Z))$ točka koja estimira središta aorte, gdje je $DM(p, Z)$ mapa udaljenosti.
11: Neka je $g_{DM}(p, p_c, Z) = grad(DM(p, Z)) \cdot (p - p_c)$.
12: Neka je $A = \{p \in Z \,| g_{DM}(p, p_c, Z) < 0\}$.
13: Odbaci sve spojene regije iz A osim jedne koja se najviše preklapa s I_{-1}.
14: Neka je $V = A \circ S$, rezultat rekonstrukcije dobiven primjenom morfološkog otvaranja skup A pomoću diska S kako bi izgladili granicu regije koja predstavlja aortu.

Algoritam 8 Algoritam za određivanje točaka kalcifikacija najbližih vanjskom rubu aorte.

1: Neka je $p_c \in I_{-1}, DM(p_c, X) = \max(DM(p, X))$ točka koja estimira središta aorte, gdje je $DM(p, X)$ mapa udaljenosti.
2: Neka je $Y = \{p \in D_I | I(p) \leq I_s(p) + m\}$ skup točaka slike iz kojeg bi trebale biti isključene točke kalcifikacija.
3: Neka je $g_{DM}(p, p_c, Y) = grad(DM(p, Y)) \cdot (p - p_c)$.
4: Neka je $C = p \in Y | DM(p, Y) = 1, g_{DM}(p, p_c, Y) > 0$

2. U algoritmu se koristi rezultat rekonstrukcije sa susjednog, već rekonstruiranog presjeka. Taj podatak koristit će se za odabir regije koja se najviše preklapa s točkama aorte iz prethodno segmentiranog presjeka. Skup I_{-1} sadrži točke koje pripadaju aorti u susjednom rekonstruiranom presjeku.

3. Skup E čine sve točke slike koje imaju intenzitet veći od praga t_3 koji je jednak vrijednosti spomenutog lokalnog minimuma histograma (slika 4.5). Na taj način slika je podijeljena na pozadinu i na regiju E unutar koje se nalazi abdominalna aorta. Binarna slika na kojoj su bijelom bojom označene točke čiji je intenzitet iznad praga, može se vidjeti na slici 7.11(b) dok je na slici 7.11(a) prikazan originalni CT presjek.

4. U skup M izdvajaju se sve točke koje zadovoljavaju tri uvjeta. Ti uvjeti imaju za cilj izdvojiti samo točke na vanjskom rubu aorte koje sama primjena praga t_3 ne može dovoljno dobro izdvojiti. Prvi uvjet je da je intenzitet točke slike manji od t_0 i njime se nastoji ukloniti utjecaj jakog gradijenta na unutarnjoj granici aorte. Drugi uvjet je $t_1 + (I_s(p) - t_1) \cdot k$. Takav oblik lokalnog praga trebao bi omogućiti bolje funkcioniranje kod lokalnog variranja intenziteta u slici: ako je sav intenzitet lokalno povećan veći je i prag, a ako je intenzitet lokalno smanjen smanjuje se i prag. Treći uvjet je $G(I) > t_2$. Ovim korakom željelo se izdvojiti samo točke vanjskog ruba aorte pomoću funkcije gradijenta. Istovremeno potrebno je ukloniti utjecaj visokog gradijenta slike na unutarnjem rubu aorte, što se postiže eliminacijom točaka koje imaju vrijednost veću od praga t_0. Vrijednost t_0 malo je veća od vrijednosti intenziteta u lokalnom minimumu histograma CT presjeka (vidi sliku 4.5). Takvim odabirom, uključene su točke abdominalne praznine i točke zida aorte koje se nalaze uz vanjski rub aorte. S njima je uključen vanjski rub aorte. Kako nisu uključene točke unutrašnjosti aorte i točke zida aorte uz unutarnji zida aorte, nije uključen ni visoki gradijent na unutarnjoj granici aorte.

   Lokalnim pragom $t_1 + (I_s(p) - t_1) \cdot k$ nastoje se izdvojiti samo točke na rubovima regija čija vrijednost je manja od lokalne vrijednosti praga bazirane na srednjoj vrijednosti susjedstva dane točke. Ukoliko je točka u abdominalnoj praznini uz samu granicu aorte, njena vrijednost će biti manja od srednje vrijednosti njenog susjedstva.

   Eliminacijom točaka s gradijentom manjim od t_2 želi se ukloniti gradijent niskog intenziteta koji je najvjerojatnije uzrokovan šumom. Skup M trebao bi sadržavati samo točke na vanjskom rubu aorte u kojima je gradijent veći od t_2.

5. Kako skup M sadrži točke vanjskog ruba aorte, a među njima i točke ruba koje nisu

detektirane pragom t_3, te točke se odstranjuju iz skupa E. Time bi se trebale smanjiti veličine rupa u vanjskoj granici aorte koje su stvorene upotrebom praga t_3 u prethodnom koraku. Rezultat je skup X. Točke skupa X prikazane su bijelom bojom na slici 7.11(c).

6. Točke pozadine čine crne povezane regije na slici 7.11(d). Te regije sačinjene su od različitih brojeva točaka, a točke manjih regija uklanjaju se iz pozadine i dodaju se u skup X. Pretpostavka je da su manje povezane regije prouzročene šumom.

7. Šum može prouzročiti male povezane regije i u skupu X, pa iz njega uklanjamo točke malih regija i dodajemo ih u pozadinu skupa X (slika 7.11(e)).

8. Skup C predstavlja točke vanjskih rubova kalcifikacija. Opis određivanja tih točaka dan je algoritmom 8.

9. Iz skupa X odstranjuju se točke iz skupa C. Za odabrani primjer, točke skupa Z prikazane su slikom 7.11(f). Za odabrani primjer i rupu u vanjskoj granici aorte, kalcifikacije nisu imale utjecaja. Na slici 7.12 dan je bolji primjer pozitivnog utjecaja kalcifikacija na rekonstrukciju vanjskog ruba aorte. Može se vidjeti da kalcifikacije koja se nalazi na sredini rupe u vanjskom rubu aorte dijeli tu rupu na dva dijela. Time se pospješuje sama rekonstrukcija koja koristi gradijent mape udaljenosti, a i level-set algoritam uspješno izlazi na kraj s manjim rupama u rubu aorte.

10. p_c je estimacija središta aorte. To je točka $p \in I_{-1}$ s najvećom udaljenosti $DM(p, Z)$. Mapa udaljenosti $DM(p, Z)$ prikazana je slikom 7.11(g) gdje veća svjetlina odgovara većoj udaljenosti.

11. Računa se gradijent udaljenosti mape DM za svaku točku $p \in D_I$ u smjeru vektora $p - p_c$.

12. Skup A sadrži sve točke za koje je $(p, p_c, Z) < 0$. Pozitivan gradijent pojavljuje se kod prolaza kroz rupu u granici aorte. Primjer točaka koje ulaze u skup A dan je slikom 7.11(h)

13. Iz skupa A odabire se jedna spojena regija koja se najviše preklapa s aortom iz susjednog presjeka, odnosno koja od svih spojenih regija ima najviše točaka u skupu I_{-1}.

14. Na dobivenu regiju V primjenjuje se morfološko otvaranje kako bi se zatvorile eventualne manje rupe u regiji i kako bi se izgladili rubovi regije. Pomoću skupa V radi se binarna slika I_b gdje točke iz skupa V imaju vrijednost 1. Konačna regija aorte odnosno binarna slika I_b prikazana je slikom 7.11(i).

Primjeri regija koje su sadržane u određenim skupovima algoritma rekonstrukcije prikazane su na slici 7.11. Dio algoritma 7 koji koristiti mapu udaljenosti i njezin gradijent (točke 10, 11 i 12) najzaslužniji su za uspješno funkcioniranje ove metode segmentacije. Tu je uključeno, donekle apstraktno znanje o obliku aorte pomoću kojeg je definiran uvjet koji mora zadovoljiti oblik regije aorte.

Slijedi opis točaka algoritma 8 koji određuje vanjske točke kalcifikacija:

1. Određuje se estimacija središta regije koja se poklapa s aortom iz susjednog presjeka.

2. U skup Y izdvajaju se točke čiji je intenzitet manji ili jednak pridruženoj srednjoj vrijednosti uvećanoj za m. Time su odbačene točke koje odgovaraju kalcifikacijama koje najčešće imaju formu manjeg broja povezanih točaka visokog intenziteta.

3. Računa se i gradijent funkcije udaljenosti $DM(p, Y)$ u smjeru vektora $p - p_c$.

4. Točke koje predstavljaju vanjske rubove kalcifikacija odabiru se kao točke koje zadovoljavaju uvjete $DM(p, Y) = 1$ i $g_{DM}(p, p_c, Y) > 0$. Ako je udaljenost iznosi 1 onda se radi o prvom susjednom sloju točaka oko kalcifikacije. Gradijent udaljenosti veći od nula znači da će se odabrati točke iz prvog susjednog sloja u kojima se udaljenost povećava u smjeru $p - p_c$. Ovako odabrane vanjske točke odgovaraju prvom sloju točaka uz rub kalcifikacija koje između sebe i točke središta p_c imaju barem jednu točku kalcifikacije.

Rezultat opisane rekonstrukcije je skup točaka koje čine regiju aorte na jednom presjeku. Regije svih presjeka čine skup svih točaka aorte u CT snimci. Pomoću tih točaka napravljen je binarni volumen I_b u kojem vrijednost 1 imaju točke aorte, a 0 sve ostale točke.

7.3.4 Rezultati i diskusija

Primjeri rezultati segmentacije pomoću opisane metode prikazani su na slikama 7.13, 7.14, 7.15 i 7.16. Na slikama 7.13(a), 7.14(a), 7.15(a) i 7.16(a) prikazani su originalni CT presjeci. Na slikama 7.13(b), 7.14(b), 7.15(b) i 7.16(b) prikazani su gradijenti originalnih presjeka korišteni u segmentaciji unutarnjeg ruba aorte Slike 7.13(c), 7.14(c), 7.15(c) i 7.16(c) prikazuju rezultate segmentacije unutarnjeg ruba aorte. Slike 7.13(d), 7.14(d), 7.15(d) i 7.16(d) prikazuju regije dobivene primjenama pragova i uklanjanja malih regija. One sadržavaju relativno velike rupe u vanjskoj granici aorte te bi dale približno jednake rezultate kao i slike dobivene primjenom praga u odlomku 7.2. Slike 7.13(e), 7.14(e), 7.15(e) i 7.16(e) prikazuju gradijent slika regija

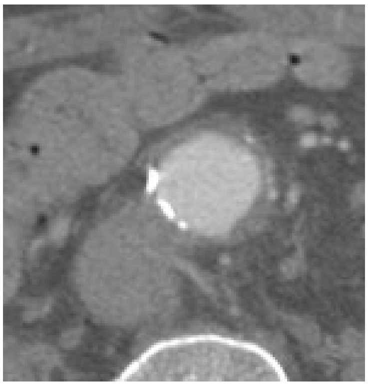

(a) CT presjek

(b) Primjena praga t_3

(c) Primjena praga & prag primijenjen na gradijent

(d) Uklonjene male povezane regije iz pozadine (crno)

(e) Uklonjene male povezane regije iz prvog plana (bijelo)

(f) Dodan utjecaj kalcifikacija

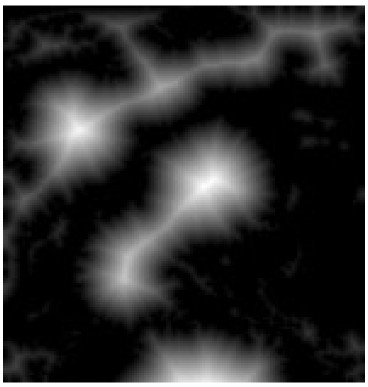

(g) mapa udaljenosti

(h) Točke u kojima je gradijent udaljenosti > 0

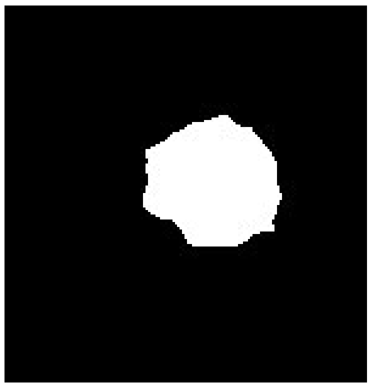

(i) Konačna regija aorte

Slika 7.11: Primjer funkcioniranja algoritma za rekonstrukciju slabo izraženih vanjskih rubova aorte

(a) Točke skupa X nakon uklanjanja malih regija

(b) Dodan utjecaj kalcifikacija

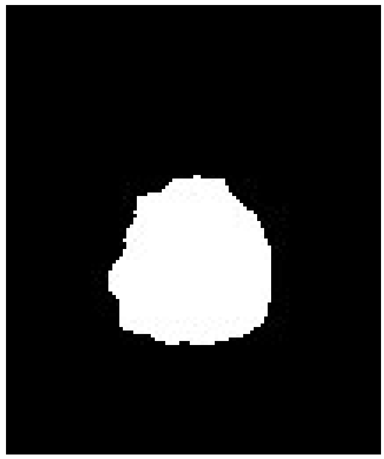

(c) Konačna regija aorte

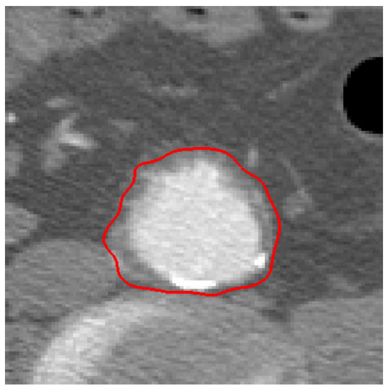

(d) Rezultat segmentacije vanjskog ruba aorte

Slika 7.12: Primjer pozitivnog utjecaja kalcifikacija na rekonstrukciju vanjskog ruba aorte

Parametri zajednički segmentaciji unutarnjeg i vanjskog ruba	
σ	0.8
δ	6
N_{iter}	4
Segmentacija unutarnjeg ruba	
v_0	-1
ε	1
Segmentacija vanjskog ruba	
v_0	-1
ε	0.6

Tablica 7.2: Vrijednosti upotrebljenih parametara.

aorte dobivenih gore opisanom rekonstrukcijom. Kako je korišten 3-D geometrijski deformabilni model, gradijent je računan u tri dimenzije (zato gradijent nije visok samo na rubovima vidljivima na slici, već su područja visokog gradijenta šira zbog utjecaja točaka ispod i iznad). Može se uočiti da su rupe u vanjskoj granici aorte zatvorene. Slike 7.13(f), 7.14(f), 7.15(f) i 7.16(f) prikazuju rezultate segmentacije vanjskih rubova aorte.

Rupe u vanjskom rubu aorte na slikama 7.13(d), 7.14(d), 7.15(d) i 7.16(d) variraju u broju i relativnoj veličini u odnosu na ukupnu dužinu vanjskog ruba. Sve vanjske rupe prikazane primjerima uspješno su zatvorene kao što se može vidjeti na slikama 7.13(e), 7.14(e), 7.15(e) i 7.16(e), odnosno na slikama rezultata segmentacije 7.13(f), 7.14(f), 7.15(f) i 7.16(f). Najvažniji korak algoritma rekonstrukcije vanjskih rubova aorte je korak koji na temelju gradijenta mape udaljenosti odstranjuje suvišne rubove, odnosno zatvara rupe u granici aorte. To se vidi i usporedbom podslika (d) i (e) slika 7.13, 7.14, 7.15 i 7.16. Na slici 7.17 prikazane su 3-D rekonstrukcije vanjskog ruba aorte iz rezultata segmentacije dobivenih opisanom metodom (slika 7.17(a)) i referentnih rezultata (slika 7.17(b)).

U postupku segmentacije korišten je 3-D geometrijski deformabilni model kod unutarnjeg i kod vanjskog ruba. Korištena je i decimacija kako je opisano u odlomku 6.2, čime je postignuto znatno ubrzanje segmentacije.

Korišteni parametri level-set algoritma dani su tablicom 7.2, a njihove vrijednosti određene su eksperimentalno kao i u prethodnim pristupima. Korišten je zaustavni kriterij dan jednadžbom (3.26). Kod segmentacije unutarnjeg ruba kriterij zaustavljanja bazira se na slici presjeka dok se kod segmentacije vanjskog ruba aorte, kriterij zaustavljanja temelji na binarnoj slici I_b

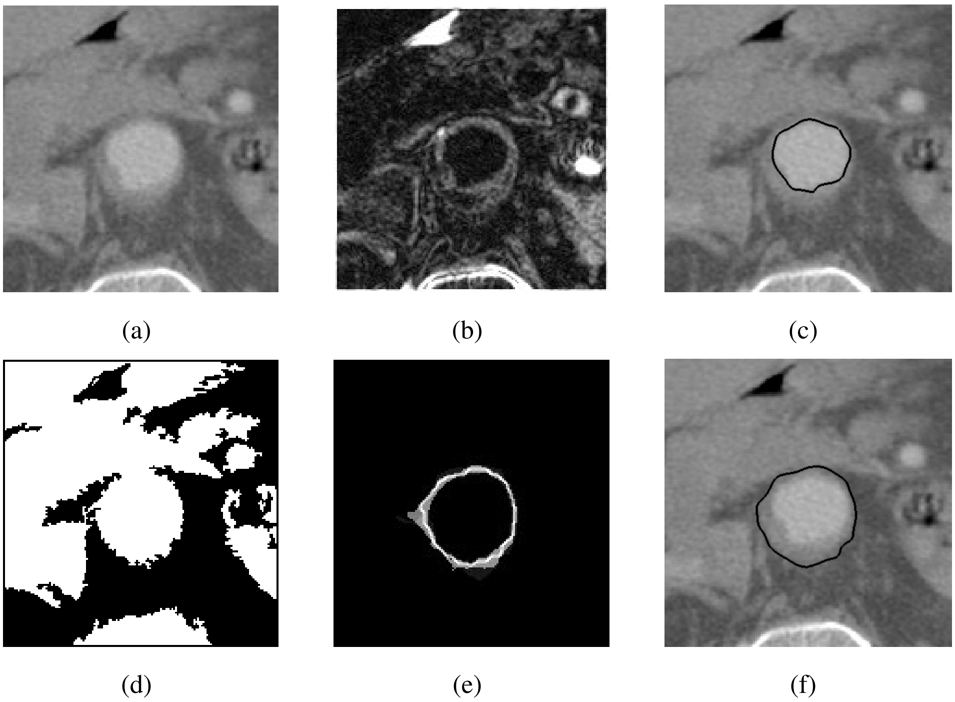

Slika 7.13: Primjer 1. segmentacije aneurizme abdominalne aorte

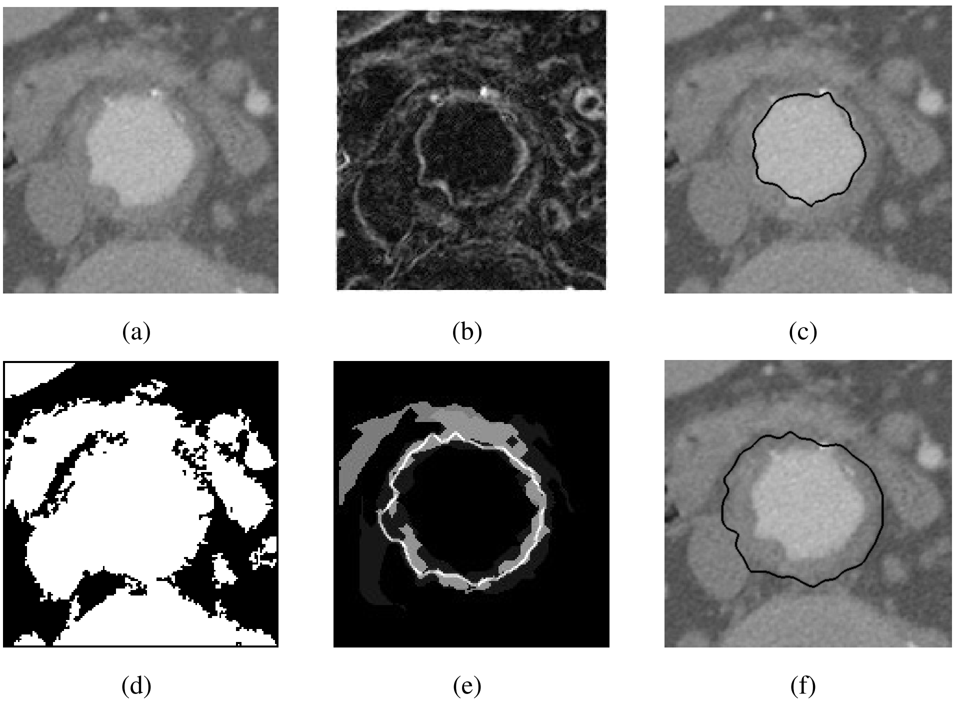

Slika 7.14: Primjer 2. segmentacije aneurizme abdominalne aorte

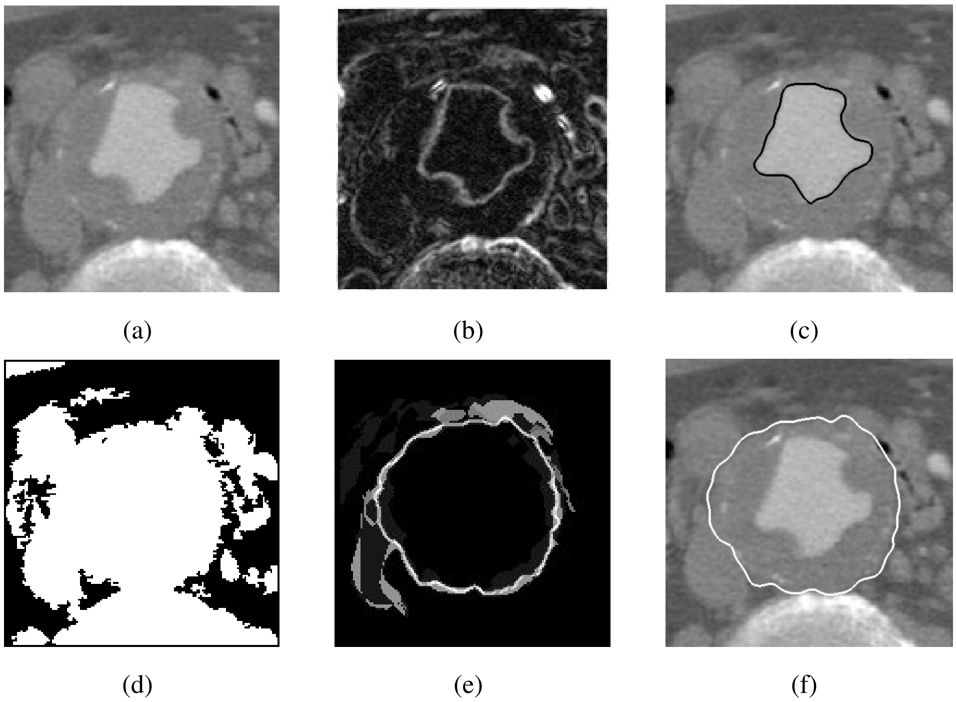

Slika 7.15: Primjer 3. segmentacije aneurizme abdominalne aorte

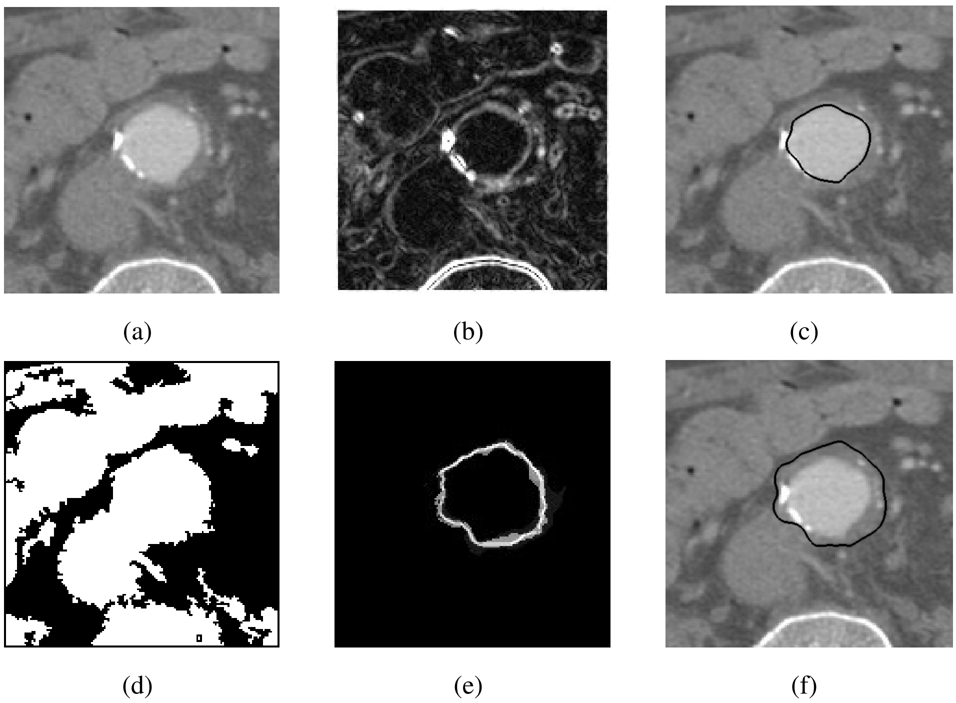

Slika 7.16: Primjer 4. segmentacije aneurizme abdominalne aorte

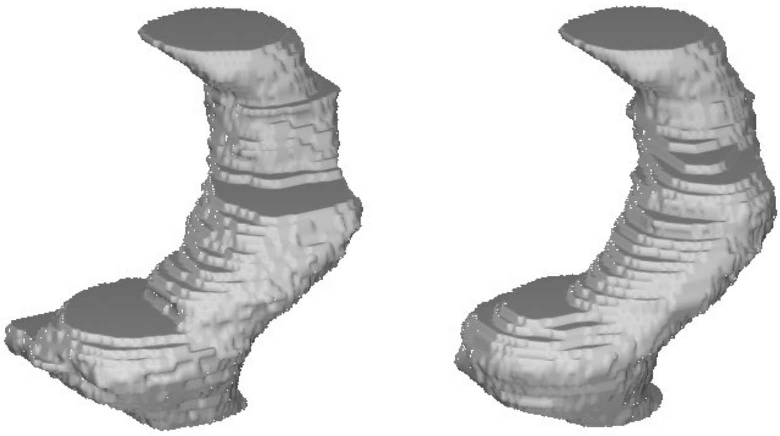

(a) (b)

Slika 7.17: 3-D rekonstrukcija rezultata opisane metode (a) i referentnih rezultata (b)

dobivenoj rekonstrukcijom vanjskog ruba.

Algoritam rekonstrukcije vanjskih rubova aorte donosi i nekoliko svojih parametara. Vrijednost praga t_3 određuje se automatski iz histograma danog presjeka i ona odgovara lokalnom minimumu koji razdvaja intenzitet abdominalne šupljine i zida aorte (vidi sliku 4.5). Za sve slike korištene u ovom radu ta se vrijednost kretala oko 1000 tako da je vrijednost praga mogla biti i ručno postavljena na 1000. Na ovaj način postignuta je veća robusnost algoritma prema promjeni intenziteta na slikama. Prag t_0 nešto je viši od t_3 jer je njegov cilj isključiti svijetlu unutrašnjost aorte i točke zida neposredno uz unutarnji rub aorte, odnosno zadržati točke abdominalne šupljine i točke zida neposredno uz vanjski rub aorte. Stoga je potrebno da vrijednost praga t_0 bude između t_3 i vrijednosti koja razgraničava intenzitete zida aorte i unutrašnjosti aorte koja je za slike korištene u ovom radu iznosila oko 1200. Stoga je t_0 računat kao $t_0 = 1.08 \cdot t_3$. Ovdje se pretpostavlja da se točkama zida aorte postepeno povećava intenzitet od vanjskog prema unutarnjem rubu aorte. Očekivani odabir koeficijenta kojim se množi t_3 bio bi onaj koji bi dao vrijednost praga t_0 na polovici između vrijednosti t_3 i gore spomenute vrijednosti koja razgraničava zid aorte i unutrašnjost aorte. Takav odabir, uz poznate približne vrijednosti pragova, trebao bi dati vrijednost praga $t_0 = 1100$. Kako nas interesira vanjski rub aorte, bitne su nam točke zida aorte koje se nalaze uz vanjski rub aorte pa je stoga prag t_3 množen s 1.08 što daje okvirnu vrijednost praga $t_0 = 1080$. Prag t_1 također treba razdvajati intenzitete regija abdominalne šupljine i zida aorte pa je on jednak $t_1 = t_3$. Prag t_2 kojim se nastoji ukloniti gradijent niskog intenziteta prouzročen šumom eksperimentalno je postavljen na vrijednost $t_2 = 30$ pa se onda za točke koje imaju vrijednost gradijenta manju od 30 pretpostavlja da predstavljaju šum. Za točke 6 i 7 algoritma 7 potrebno je unaprijed zadati maksimalan broj točaka koji spojena regija može imati da bi bila označena kao „mala regija” te je taj broj eksperimentalno postavljen na 20. Svaka spojena regija koja ima manje od 20 točaka tada se smatra malom i njene točke se onda prebacuju iz skupa X odnosno u skup X. U točki 14 algoritma 7 vrši se operacija morfološkog otvaranja pomoću maske u obliku kružnice S s radijusom 2. Takva maska može zatvoriti rupe i udubljenja čiji minimalni promjer iznosi dvije točke.

Rezultati segmentacije opisanog pristupa pokazali su se boljima od rezultata dvaju pristupa opisanih u odlomcima 7.1 i 7.2. Odabrano je 11 CT snimaka abdominalne aorte za koje su prethodno pribavljeni referentni, odnosno točni rezultati segmentacije. Ti referentni rezultati segmentacije dobiveni su ručnim ispravljanjem rezultata dobivenih poluautomatskom metodom segmentacije opisanom u [25]. Operater je rukom ispravio konture vanjskog ruba aorte na svakom presjeku na kojem se nalazi aneurizma abdominalne aorte u svih 11 snimaka.

Na svakoj CT snimci puštena je u rad metoda opisana u ovom odlomku te su i ti rezultati automatske segmentacije ručno ispravljeni. Time smo dobili drugi referentni rezultat za svaki presjek na kojem je aneurizma abdominalne aorte. Oba referentna rezultata smo usporedili s rezultatima ovdje opisane automatske metode.

Iako je liječnicima bitan volumen aneurizme, nije vršena usporedba ukupnih volumena, već je vršena usporedba površina aorte na svakom presjeku. Time se teži većoj točnosti jer ispravna segmentacija svih presjeka povlači za sobom i ispravan iznos ukupnog volumena aneurizme, dok obrat ne mora vrijediti. Usporedba je vršena pomoću broja pogrešno segmentiranih točaka. Tu razlikujemo dvije grupe točaka. Prvu grupu čine točke koje je naša metoda netočno uvrstila u regiju aorte (N_+), a kod referentnih rezultata te točke pripadaju pozadini. Drugu grupu čine točke koje je naša metoda pogrešno izbacila iz područja aorte (N_-), a u referentnim rezultatima te točke pripadaju aorti. Ukupan broj točaka obje grupe $P_u = N_+ + N_-$ predstavlja apsolutni iznos pogreške za jedan presjek. Također je izračunat i ukupan broj točaka aorte na svakom presjeku za referentne rezultate (N_{ref}) i za rezultat opisane metode (N_{met}). Broj točaka ekvivalentan je površini aorte na danom presjeku.

Na presjecima gdje je površina aorte veća možemo očekivati i veću apsolutnu pogrešku, a na presjecima gdje je površina aorte manja očekujemo manji broj pogrešno segmentiranih točaka. Stoga je za ocjenu točnosti odabrana relativna pogreška segmentacije P_r koja se računa prema jednadžbi (7.12).

$$P_r = \frac{N_+ + N_-}{N_{ref}} \tag{7.12}$$

Takva relativna pogreška izračunata je za svaki presjek na kojem se nalazi aneurizma u svih 11 CT snimaka. Za svaki presjek dobivene su dvije relativne pogreške, po jedna za svaki referentni rezultat. Za kontrolu su izračunate i relativne pogreške između dva referentna rezultata za svaki presjek. Kako su ovdje oba rezultata referentna, relativna pogreška računa se prema jednadžbi (7.13)

$$P_r = \frac{N_+ + N_-}{\frac{N_{ref1}+N_{ref2}}{2}}, \tag{7.13}$$

gdje su N_+ i N_- pogrešno segmentirane točke u jednom referentnom rezultatu, pri tome nije bitno o kojem se referentnom rezultatu radi, već da su obje grupe pogrešno segmentiranih točaka računate za isti referentni rezultat. Za ukupan broj točaka kojim se dijeli apsolutna pogreška uzima se srednja vrijednost broja točaka dvaju referentnih rezultata N_{ref1} i N_{ref2}. Za svakog od 11 pacijenata izračunata je srednja relativna pogreška kao srednja vrijednost relativnih pogrešaka svih obrađenih presjeka danog pacijenta. Za svakog pacijenta izračunata je i standardna devijacija relativne pogreške. Još jednu mjeru kvalitete segmentacije daje i koeficijent korelacije (r) površina aorte referentnog rezultata i rezultata opisane metode te je on izračunat za svakog pacijenta prema jednadžbi (7.14)

$$r = \frac{\frac{\sum N_{met}N_{ref}}{n} - (\overline{N_{met}})(\overline{N_{ref}})}{(S_{N_{met}})(S_{N_{ref}})} \tag{7.14}$$

gdje je n broj presjeka za koje se računa koeficijent korelacije, $S_{N_{met}}$ i $S_{N_{met}}$ su standardne devijacije površina aorte dobivenih opisanom metodom, odnosno referentnim rezultatima segmentacije, a $\overline{N_{met}}$ i $\overline{N_{ref}}$ su srednje vrijednosti površina aorte. Koeficijent korelacije nije direktno povezan s relativnom pogreškom, već on opisuje kako promjena površine aorte kroz presjeke rezultata opisane metode prati promjena površine aorte kroz presjeke referentnog rezultata. Pojednostavljeno, koeficijent korelacije blizak jedinici znači da ukoliko se pri prelasku na sljedeći presjek površina aorte poveća u referentnom rezultatu, tada se i površina aorte u rezultatima opisane metode mora povećati.

Sve tri statističke veličine računaju se dva puta za svakog pacijenta zbog dva referentna rezultata. One se još jednom računaju za usporedbu dvaju referentnih rezultata. Rezultati opisane usporedbe za svih 11 pacijenata prikazani su u tablici 7.3.

Ukupno je obrađeno 429 presjeka iz svih 11 CT snimaka. Opisane statističke veličine izračunate su za sve presjeke i navedene u tablici 7.4.

Koeficijenti korelacija površina aorte na presjecima za opisanu metodu iznose 0.93 i 0.91. To su relativno visoki koeficijenti korelacije što pokazuje da promjene iznosa površine aorte na

	opisana metoda & ručno ispravljena opisana metoda			opisana metoda & ručno ispravljena poluautomatska metoda			ručno ispravljena opisana metoda & ručno ispravljena poluautomatska metoda		
	korel.	sr. pog. [%]	std. dev. [%]	korel.	sr. pog. [%]	std. dev. [%]	korel.	sr. pog. [%]	std. dev. [%]
1	0.99	6.91	2.82	0.99	19.01	5.34	0.99	17.96	6.56
2	0.90	12.32	13.75	0.78	21.66	14.20	0.95	15.50	6.46
3	0.73	33.50	16.82	0.74	38.40	11.33	0.99	13.46	5.80
4	0.62	20.71	24.37	0.60	28.66	22.92	0.99	12.36	10.81
5	0.62	16.25	14.14	0.58	17.82	12.19	0.98	9.12	3.22
6	0.87	9.34	10.09	0.87	18.22	13.75	0.99	12.83	8.50
7	0.98	10.20	6.67	0.99	14.46	5.66	0.99	12.58	6.21
8	0.84	13.61	12.83	0.90	17.00	10.42	0.96	14.30	8.53
9	0.98	11.42	8.83	0.99	12.58	6.15	0.99	18.86	8.77
10	0.79	8.17	2.98	0.73	20.74	4.18	0.70	23.98	4.37
11	0.99	3.90	4.33	0.93	19.31	7.74	0.93	16.77	6.24

Tablica 7.3: Rezultati usporedbe za sve pacijente

grupe rezultata uspoređene kroz presjeke	koeficijent korelacije	srednja relativna pogreška [%]	standardna devijacija pogreške [%]
opisana metoda & ručno ispravljena poluautomatska metoda	0.93	12.35	13.92
opisana metoda & ručno ispravljena poluautomatska metoda	0.91	19.75	13.29
ručno ispravljena opisana metoda & ručno ispravljena poluautomatska metoda	0.99	14.71	8.18

Tablica 7.4: Rezultati usporedbe za sve presjeke

svim presjecima dobiveni opisanom metodom dobro prate promjene iznosa površina aorte dobivenih iz referentnih rezultata. Koeficijent korelacije površina aorte dviju referentnih rezultata gotovo je idealan i iznosi 0.99, što je i očekivano.

Srednje relativne pogreške opisane metode u odnosu na dva referentna rezultata iznose 12.35% i 19.75%. To su relativno velike pogreške, no interesantno je da srednja relativna pogreška između dva referentna rezultata iznosi 14.71% što je približno jednako dvjema srednjim relativnim pogreškama opisane metode. Jedno moguće objašnjenje ovakve razlike među referentnim rezultatima je način na koji su ti referentni rezultati dobiveni. Oba referentna rezultata dobivena su ručnim ispravljanjem rezultata automatske i poluautomatske segmentacije od strane dvaju različitih operatera. Poznat je problem ponovljivosti rezultata ručne segmentacije kod istog operatera, a kod dva različita operatera razlike rezultata postaju još veće. Neki od uzroka tih razlika su zamor, subjektivnost i utjecaj iskustva pri odlučivanju. Još jedan faktor koji može prouzročiti različite rezultate ručnog ispravljanja je činjenica da će dvije metode segmentacije same dati drugačije rezultate koji onda čine različite polazne točke ručnog ispravljanja. Različita polazišta i subjektivnost operatera mogu prouzročiti različite rezultate ručnog ispravljanja. To može biti uzrok dobivenoj manjoj pogrešci kada se rezultati opisane metode uspoređuju s ručno ispravljenim rezultatima te iste metode. Ručno ispravljeni rezultati poluautomatske metode imali su drugačiju polaznu točku, pa je kod usporedbe s opisanom metodom dobivena veća greška.

Takav iznos relativne pogreške među referentnim rezultatima može značiti da je barem dio relativnih pogrešaka opisane metode proizašao iz same metode validacije rezultata. Problem validacije se često pojavljuje kod segmentacije medicinskih slika. Standardne devijacije pogreški opisane metode su približno jednake i iznose 13.92% i 13.29%. Standardna devijacija pogreške među referentnim rezultatima je manja i iznosi 8.18%.

Opisana metoda segmentacije aorte, odnosno metoda rekonstrukcije vanjskog ruba aorte, pokušaj je rješavanja problema rupa na vanjskoj granici aorte izvan samog algoritma geometrijskog deformabilnog modela, za razliku od prethodna dva pristupa. Time je omogućeno korištenje 3-D deformabilnog modela, koji protokom informacija i kroz treću dimenziju omogućuje bolju segmentaciju. Jedan od pragova korištenih u algoritmu rekonstrukcije određuje se automatski

7.4 Pristup IV

U ovom pristupu nastojalo se iskoristiti geometrijski deformabilni model baziran na regijama, a ne na rubovima kao u prethodna tri pristupa. Iako su level-set algoritmi bazirani na rubovima i regijama dualni, odnosno ekvivalentni, njihove modifikacije to nisu. Konstruiranju ovog pristupa pristupilo se s nadom da će rješavanje problema segmentacije vanjskog ruba aorte na ovaj način, drugačijim pristupom dati bolje rezultate. Sve prilagodbe za rješavanje problema slabo izraženih vanjskih rubova aorte ovdje su uključene direktno u funkciju brzine level-set algoritma, tako da se ovdje ne radi o dodatnim uvjetima zaustavljanja koji djeluju izvan samog level-set algoritma. Time se postiže kompaktnost i jednostavnost algoritma za segmentaciju. I ovdje se rješenje problema slabo izražene vanjske granice aorte traži u korištenju znanja o obliku vanjske granice i o međusobnom odnosu unutarnje i vanjske granice aorte.

Unutarnja granica aorte se segmentira 2-D geometrijskim deformabilnim modelom baziranim na rubovima. Kako za segmentaciju vanjskog ruba aorte koristimo 2-D geometrijski deformabilni model temeljen na regijama, a ne na rubovima, algoritam segmentacije ne traži rubove regija već same regije. Tada umjesto segmentacije vanjskog ruba aorte imamo segmentaciju zida aorte. Iz rezultata segmentacije regija jednostavno je dobiti granice tih regija. Modifikacije korištene kod segmentacije zida aorte zahtijevaju rezultate segmentacije unutarnjeg ruba aorte koja treba biti obavljena prethodno.

7.4.1 Ideja za segmentaciju zida aorte

Glavna ideja ove metode inspirirana je metodama segmentacija opisanim u [7], [19] i [29]. U tim radovima korištena je ideja da se maksimizira sličnost točaka unutar krivulje deformabilnog modela, dok se istovremeno minimizira sličnost točaka unutar krivulje i točaka izvan krivulje. Primjeri na kojima su isprobane te metode segmentacije imali su homogenu unutrašnjost objekta koji se segmentira i homogenu pozadinu. U slučaju CT snimaka abdominalne aorte pozadina aorte (sve točke slike koje ne čine aortu) nije homogena, a uz to je i dobrim djelom jako slična samoj aorti. Stoga je za segmentaciju aorte moguće koristiti samo maksimiziranje sličnosti točaka unutar krivulje nulte razine.

Ako koristimo sličnost točaka unutrašnjosti krivulje tada unutar krivulje ne smije biti svjetla unutrašnjost aorte koja se previše razlikuje od zida aorte, već samo točke koje se nalaze u samom zidu aorte.

U funkciji brzine geometrijskog deformabilnog modela koristi se zakrivljenost krivulje isto kao i u funkciji brzine u (3.25). Jedina razlika je što je vrijednost zakrivljenosti ograničena na pozitivne vrijednosti, odnosno negativne vrijednosti zakrivljenosti (konkavnost) postavljaju se na nulu. Samo korištenje sličnosti regija ne uklanja problem prodiranja deformabilnog modela u okolno tkivo koje ima sličan intenzitet. Sve modifikacije ove metode nastoje to spriječiti no negativna zakrivljenost potiče ekspanziju deformabilnog modela pa bi ona imala negativan utjecaj na točnost segmentacije. Koristi se jedino pozitivna (konveksna) zakrivljenost koja usporava ekspanziju deformabilnog modela.

Kako se za aneurizmu abdominalne aorte ne može odrediti standardni oblik tako ne postoji oblik aorte kojem bi ona trebala sličiti i koju sličnost bi mogli maksimizirati. Ako se segmentacija vrši na svakom presjeku posebno, pokazalo se da postoji znatna sličnost oblika aorte na jednom presjeku prema obliku aorte na njemu susjednom presjeku. Sličan zaključak iznesen je u i [9]. Stoga u ovom pristupu nastojimo iskoristiti sličnost oblika aorte na danom presjeku prema obliku aorte na već segmentiranom susjednom presjeku.

Pokazalo se, isto tako, da je najčešće vanjski rub aorte sličan unutarnjem rubu aorte. Tu sličnost nastojimo iskoristiti putem sličnosti zakrivljenosti unutarnjeg i vanjskog ruba aorte i maksimiziranja te sličnosti. Iako se u osnovi segmentiraju regije, nulta razina geometrijskog deformabilnog modela predstavlja rubove regija na koje možemo primijeniti uvjet sličnost zakrivljenosti.

Ako se koristimo već segmentiranom aortom na susjednom presjeku kod segmentacije aorte na danom presjeku, tada u segmentaciju unosimo i pogrešku segmentacije iz prethodnog presjeka. Kako napredujemo kroz presjeke u jednom smjeru, takve se greške akumuliraju. Tada je za očekivati da će presjek koji je najudaljeniji od inicijalnog presjeka imati najlošiju točnost segmentacije (isto se pokazalo i u [9]). Da bi zaobišli ovaj problem, u ovom radu koristi se nekoliko pravilno raspoređenih inicijalnih presjeka, uključujući prvi i zadnji, koji kod segmentacije ne koriste utjecaj susjednih presjeka. Sljedeći korak je segmentacija presjeka točno na sredini između dva već segmentirana presjeka. Sada se mogu iskoristiti rezultati segmentacije oba već segmentirana presjeka za navođenje segmentacije na danom presjeku. Postupak se dalje nastavlja i svaki sljedeći presjek imat će dva već segmentirana susjedna presjeka koja će utjecat na njegovu segmentaciju. Ovdje spomenuti već segmentirani susjedni presjeci neće uvijek biti neposredno susjedni, već najbliži segmentirani presjek u jednom smjeru. Na ovaj način smanjuje se utjecaj akumulacije pogreške jer sada imamo smanjenu maksimalnu udaljenost od inicijalnog presjeka koja ne može biti veća od polovice udaljenosti između dva inicijalna presjeka. Akumulacija pogreške suzbija se i tako što se za segmentaciju jednog presjeka koristi utjecaj dva susjedna presjeka, a ne samo jednog. Na taj način se utjecaj eventualne greške u jednom susjednom presjeku umanjuje utjecajem drugog presjeka.

U obzir treba uzeti i kalcifikacije koje se mogu pojaviti unutar zida aorte. One imaju visoki intenzitet koji znatno odstupa od intenziteta zida aorte te nikako nisu slične točkama zida aorte, ali su ipak njegov sastavni dio. Stoga je bilo potrebno implementirati mehanizam koji sprječava komponentu funkcije brzine baziranu na sličnosti regija da zaobiđe kalcifikacije.

7.4.2 Algoritam za segmentaciju unutarnjeg ruba aorte

Kod segmentacije unutarnjeg ruba pokušalo se koristiti 2-D level-set algoritam baziran na regijama, no pokazalo se da je on manje pouzdan od 2-D level-set algoritma baziranog na rubovima. Sličnost jedne točke i regije unutar krivulje deformabilnog modela određuje se pomoću srednje vrijednosti intenziteta točaka unutar krivulje i njihove standardne devijacije kao što je detaljnije opisano u odlomku 7.4.3. Ponekad kalcifikacije stvaraju artefakte u svojoj okolini koji dotiču unutrašnjost aorte. Radi se o regiji većeg intenziteta u neposrednoj okolici kalcifikacija kojoj se intenzitet postepeno smanjuje prema kraju regije. Sam rub tih artefakata ima intenzitet vrlo sličan svojoj okolini te bi te točke zadovoljile uvjet sličnosti regije. Jednom uvrštene u unutrašnjost krivulje deformabilnog modela te točke mijenjaju srednju vrijednost intenziteta i povećavaju standardnu devijaciju čime oslabljuju selektivnost uvjeta sličnosti i otvaraja se put za novi niz manje sličnih točaka. Rezultat je toliko smanjena selektivnost, da uvjet sličnosti ne može razlučiti unutrašnjost aorte i zid aorte, što dovodi do pogrešne segmentacije.

Stoga se kod segmentacije unutarnjeg ruba aorte koristi 2-D geometrijski deformabilni model baziran na rubovima koji je pokazao dobre rezultate u prethodnim pristupima problemu. Algoritam deformabilnog modela identičan je onom opisanom algoritmom 1. Uvjet zaustavljanja isti je kao i (3.26), ali mu je dodan faktor težine w da bi se postigao zadovoljavajući efekt zaustavljanja kao što je prikazano jednadžbom (7.15).

$$g = e^{-w|\nabla G_\sigma * I|} \tag{7.15}$$

Ovaj oblik uvjeta zaustavljanja pokazao se boljim od oblika (3.27).

Ručno je potrebno inicijalizirati prvi presjek zadavanjem središta kružnice radijusa 1. Za ostale presjeke središte kružnice traži se automatski pomoću algoritma 9.

Algoritam 9 Algoritam za automatsku inicijalizaciju geometrijskog deformabilnog modela za segmentaciju unutarnjeg ruba aorte.

1: Neka je I slika koja odgovara trenutnom presjeku.
2: Neka je A_- skup točaka slike I koje odgovaraju točkama unutrašnjosti aorte u prethodnom susjednom, već segmentiranom presjeku. Ako ne postoji prethodni segmentirani presjek tada je $A_- = \emptyset$.
3: Neka je A_+ skup točaka slike I koje odgovaraju točkama unutrašnjosti aorte u sljedećem susjednom, već segmentiranom presjeku. Ako ne postoji sljedeći segmentirani presjek tada je $A_+ = \emptyset$.
4: Neka je $A_\pm = A_+ \cup A_-$.
5: Neka je $B = \{p \in D_I | I(p) > t\}$ skup točaka slike koje bi trebale uključivati unutrašnjost aorte ali ne i zid aorte.
6: Neka je $DM(p, B)$ mapa udaljenosti.
7: Neka je $p_c \in A_\pm, DM(p_c, B) = \max(DM(p, B))$ središte inicijalne kružnice za trenutni presjek
8: Neka je radijus inicijalne kružnice $r = 1$.

Slijedi opis točaka algoritma 9:

1. Slika I predstavlja trenutni presjek.

2. Skup A_- sačinjavaju točke trenutnog presjeka koje odgovaraju točkama unutrašnjosti aorte u prethodnom susjednom, već segmentiranom presjeku. Ovdje, prethodni susjedni presjek znači najbliži prethodni presjek u nizu. Ukoliko nema niti jednog segmentiranog presjeka prije trenutnog presjeka, tada je A_- prazan skup.

3. Skup A_+ sačinjavaju točke trenutnog presjeka koje odgovaraju točkama unutrašnjosti aorte u sljedećem susjednom, već segmentiranom presjeku. Ovdje, slijedeći susjedni presjek znači najbliži slijedeći presjek u nizu. Ukoliko nema niti jednog segmentiranog presjeka poslije trenutnog presjeka, tada je A_+ prazan skup.

4. Skup $A_\pm$ je unija prethodna dva skupa.

5. Skup B čine točke trenutnog presjeka koje imaju vrijednost intenziteta veću od praga t. Svrha praga t je da izdvoji samo točke unutrašnjosti aorte, a da odbaci zid aorte i okolicu aorte.

6. $DM(p_c, B)$ je mapa udaljenosti skupa B.

7. Među točkama skupa $A_\pm$ trži se točka s najvećom udaljenosti DM i ta točka postaje središte inicijalne kružnice.

8. Radijus inicijalne kružnice postavljen je na $r = 1$ radi jednostavnosti.

Redoslijed segmentacije presjeka i motivacija za njegov odabir opisani su u sljedećem odlomku. Ukratko, prvo se segmentira nekoliko jednoliko udaljenih presjeka. Nakon toga svi ostali presjeci imaju jedan segmentirani presjek prije i poslije sebe. Ti presjeci koriste se u točkama 2 i 3 algoritma 9.

Rezultati segmentacije unutarnjeg ruba aorte susjednih presjeka koje se koristi za segmentaciju trenutnog presjeka nije potrebno posebno pohranjivati jer se rezultati segmentacije i onako pohranjuju za sve presjeke.

7.4.3 Algoritam za segmentaciju zida aorte

Algoritam koji se koristi za segmentaciju zida aorte prikazan je algoritmom 10. On je identičan algoritmu 1 sa sljedećim iznimkama. Inicijalizaciju za segmentaciju zida aorte vrši se pomoću rezultata segmentacije unutrašnjosti aorte. Iz algoritma 1 izbačena točka 3 u kojoj se računaju uvjeti zaustavljanja bazirani na slici. Kako sada uvjet zaustavljanja zasnovan na podacima sa slike ovisi o vrijednostima točaka unutar krivulje deformabilnog modela, ti uvjeti moraju se računati svaki puta kada se krivulja deformabilnog modela pomakne, odnosno u svakoj iteraciji petlje u točki 3. Računanje svih uvjeta zaustavljanja sada se vrši u točki 5 algoritma 10.

Inicijalizacija deformabilnog modela vrši se pomoću rezultata segmentacije unutarnjeg ruba, odnosno pomoću funkcije Φ čija nulta razina opisuje unutarnji rub aorte. Kako je ta funkcija

Algoritam 10 Algoritam za segmentaciju zida aorte.

Konstruiraj inicijalnu krivulju pomoću rezultata segmentacije unutrašnjosti aorte.
Odredi uski pojas i početnu funkciju Φ.
ponavljaj
  za $i = 1$ do N_{iter} **izvrši**
    Izračunaj koeficijente funkcije brzine.
    Izvrši jednadžbu za mijenjanje funkcije Φ.
  završi za
  Nađi novu nultu razinu u uskom pojasu.
  Odredi novi uski pojas i odredi funkciju Φ u uskom pojasu.
dok Deformabilni model ne stane

Φ bila računata samo u svom uskom pojasu, a inicijalna krivulja za segmentaciju zida aorte ne mora se nalaziti unutar tog uskog pojasa, potrebno je uobičajenim načinom konstruirati novu funkciju Φ_u na čitavoj domeni slike/presjeka D_I. Inicijalna krivulja, odnosno točke inicijalne nulte razine P_{v0} dobivaju se jednadžbom (7.16).

$$P_{v0} = \{p \in D_I \mid (|\Phi_u - 2| - 1) = 0\} \tag{7.16}$$

Na ovaj način nultom razinom postaju razine funkcije Φ_u koje su imale vrijednosti 1 i 3, dok razina sa vrijednosti 2 ulazi u unutrašnjost inicijalne krivulje. Dobivena inicijalna krivulja, odnosno inicijalna regija koju krivulja zatvara, čini prsten oko unutrašnjosti aorte koji je širok 3 točke i koji dodiruje unutarnji rub aorte. Širina inicijalne regije je relativno mala jer je potrebno da cjela inicijalna regija bude unutar zida aorte. Iz istog razloga potrebno je da inicijalna regija bude što bliže unutarnjoj granici aorte. Jednom kada je određena inicijalna nulta razina oko nje, u njenom uskom pojasu, izgrađuje se inicijalna funkcija Φ na uobičajeni način.

Evolucijska funkcija algoritma 10 ima oblik prikazan jednadžbom (3.54) a funkcija brzine V u točki p ima oblik prikazan jednadžbom (7.17).

$$V(p) = v_0 + \alpha_1\kappa_+(p) + \alpha_2\kappa_{s+}(p) + \alpha_3\lambda(p) + \alpha_4 V_{\Phi_\pm}(p) \tag{7.17}$$

Sve komponente funkcije brzine, osim prve, množe se sa konstantnim koeficijentima α_n. Slijedi opis komponenata funkcije brzine:

- Komponenta v_0 predstavlja konstantni dio funkcije brzine. U ovoj metodi koristi se vrijednost v_0 manja od nule kako bi se deformabilni model mogao širiti.

- Druga komponenta funkcije brzine $\kappa_+(p)$ predstavlja od prije poznatu zakrivljenost funkcije Φ, ali sada uzimamo samo njene pozitivne vrijednosti, dok se negativne vrijednosti postavljaju na 0. Pozitivna (konveksna) zakrivljenost pomiče deformabilni model prema unutra, nastojeći smanjiti konkavnost. Negativna (konkavna) zakrivljenost pomiče deformabilni model prema van nastojeći smanjiti konkavnost. Kako nastojimo spriječiti deformabilni model da prodre kroz rupe u granici aorte, svaki uzrok kretanja prema van nastoji se minimizirati pa stoga odbacujemo negativne vrijednosti zakrivljenosti κ.

- Treća komponenta zadužena je za postizanje sličnosti zakrivljenosti unutarnjeg (već segmentiranog) ruba aorte i vanjskog ruba aorte. Zakrivljenost unutarnjeg ruba određuje se pomoću rezultata segmentacije unutrašnjosti aorte.

  Kako se kod segmentacije unutarnjeg ruba aorte zakrivljenost κ računala samo u uskom pojasu potrebno je izračunati zakrivljenost κ_u funkcije Φ_u, koja se proteže preko cijelog presjeka. Takva zakrivljenost koristi se za određivanje komponente κ_{s+} funkcije brzine, prema jednadžbi (7.18).

$$\kappa_{s+} = \begin{cases} \kappa - \kappa_u & \text{ako je} \quad \kappa - \kappa_u \geq 0 \\ 0 & \text{ako je} \quad \kappa - \kappa_u < 0 \end{cases} \tag{7.18}$$

  Ovdje je κ zakrivljenost točaka trenutne krivulje nulte razine. Ovakva komponenta brzine κ_{s+} potiče krivulju nulte razine da poprimi oblik sličan obliku unutrašnjeg ruba aorte, ali samo svojim pozitivnim vrijednostima koje ne potiču širenje deformabilnog modela.

  Krivulja nulte razine sastoji se od dvije krivulje koje zatvaraju trenutni regiju zida aorte. Komponenta κ_{s+} vrši utjecaj na veću od tih krivulja, odnosno na krivulju koja predstavlja vanjski rub aorte, koja pretežno ima pozitivnu (konveksnu) zakrivljenost. Unutarnja krivulja koja dodiuje unutarnji rub aorte ima zakrivljenost jednaku unutarnjem rubu aorte, ali suprotnog predznaka. Kako je zakrivljenost unutarnjeg ruba aorte pretežno pozitivna (konveksan), zakrivljenost κ unutarnje krivulje tada je negativna (konkavna). S takvim vrijednostima κ i κ_u izraz $\kappa - \kappa_u$ uvijek je manji od nule, a tada je $\kappa_{s+} = 0$. Stoga κ_{s+} nema utjecaja na unutarnju krivulju koja odgovara unutarnjem rubu aorte, već samo na vanjsku krivulju koja odgovara vanjskom rubu aorte, odnosno utječe samo na segmentaciju vanjskog ruba aorte kao što smo i željeli.

- Četvrta komponenta λ, funkcije brzine predstavlja vezu s podacima na slici. Ova komponenta je najznačajnija za određivanje ponašanja deformabilnog modela i njegovu uspješnost u segmentaciji. Sve ostale komponente, izuzev konstantne brzine v_0 imaju pomoćni karakter, odnosno one služe poboljšavanju funkcioniranja komponente λ. Komponenta brzine λ određuje se prema jednadžbi (7.19)

$$\lambda(p) = \frac{|I(p) - S_{\Phi_z}|}{\sigma_{\Phi_z}} \tag{7.19}$$

gdje je $I(p)$ Intenzitet slike u točki p, a S_{Φ_z} predstavlja srednju vrijednost intenziteta točaka koje se nalaze unutar krivulje nulte razine ($\Phi < 0$), odnosno unutar trenutne estimacije zida aorte. σ_{Φ_z} predstavlja standardnu devijaciju intenziteta točaka unutar krivulje nulte razine. Na ovaj način, sličnost točke prema regiji određuje se na temelju intenziteta dane točke i intenziteta svih točaka unutar regije. Što je manja sličnost točke i regije, to je veća razlika u brojniku jednadžbe (7.19). Dijeljenjem sa standardnom devijacijom postiže se prilagodba na distribuciju intenziteta točaka unutar regije koja nije unaprijed poznata. Ovako konstruirana komponenta λ funkcije brzine ima uvijek pozitivan predznak, a iznos joj ovisi o sličnosti točke i regije i to je veći, što je razlika točke i regije veća. Vrijednosti komponente λ veće od nule, zaustavljaju širenje deformabilnog modela koji se tako neće proširiti na točke koje su suviše različite od točaka unutar regije. Time se održava homogenost regije unutar krivulje nulte razine.

Točke unutar regije, ograničene krivuljom nulte razine, pomoću kojih se računaju srednja vrijednost i standardan devijacija, odabiru se kao točke gdje je $\Phi < 0$. Tako se odabiru sve točke unutar krivulje nulte razine, ali ne i točke krivulje nulte razine iako je i ona dio te regije. To je napravljeno kako bi se spriječilo polagano narušavanje homogenosti regije unutar krivulje nulte razine. Komponenta λ propustit će točke čiji se intenzitet malo razlikuje od srednjeg intenziteta regije. Te točke tada ulaze u regiju zida aorte i prvo dospijevaju u nultu razinu funkcije Φ. Te točke bi tada promijenile srednju vrijednost i povećale standardnu devijaciju, čime bi se omogućilo još različitijim točkama da uđu u regiju zida aorte. Na taj se način selektivnost komponente λ polako smanjuje te ona ne uspijeva zaustaviti deformabilni model da ne prijeđe preko granice homogene regije. Kako bi umanjili taj efekt srednja vrijednost i standardna devijacija intenziteta točaka računa se u svim točkama regije zida aorte osim na njenoj granici tj. na nultoj razini funkcije Φ. Na taj način točke koje uđu u regiju neće odmah mijenjati karakteristiku regije i smanjivati selektivnost komponente λ.

Komponenta λ trebala bi zaustavljati širenje regije zida aorte na točke koje nisu slične točkama koje već čine tu regiju. Iznimku čine točke koje čine kalcifikacije, koje imaju intenzitet znatno viši od intenziteta točaka zida aorte. Komponenta λ te točke trebala bi propuštati u regiju zida aorte niti bi one trebale ulaziti u računanje srednje vrijednosti i standardne devijacije intenziteta. Stoga je potrebno odrediti koje točke presjeka pripadaju kalcifikacijama kako bi se one mogle posebno obraditi. Način na koji se određuje skup K točaka koje čine kalcifikacije opisan je jednadžbom (7.20)

$$K = \{p \in D_I | I(p) > S_{\Phi_{un}}, \Phi_u(p) > 0\}, \tag{7.20}$$

gdje je $S_{\Phi_{un}}$ srednja vrijednost intenziteta unutrašnjosti aorte. Prvi uvjet zahtjeva da intenzitet točaka bude veći od $S_{\Phi_{un}}$, a kako kalcifikacije imaju intenzitet koji je redovito veći od intenziteta unutrašnjosti aorte, točke kalcifikacija zadovoljavaju ovaj uvjet. Osim točaka kalcifikacije, prvi uvjet zadovoljit će i neke točke unutrašnjosti aorte, što može predstavljati problem ukoliko se te točke nalaze uz unutarnji rub aorte. Tada λ neće moći zaustaviti prodor regije zida aorte u unutrašnjost aorte. Zbog takvih slučajeva drugi uvjet u jednadžbi (7.20) eliminira točke unutrašnjosti aorte koje sve imaju vrijednost funkcije $\Phi_u \leq 0$. Skup K sadrži točke koje odgovaraju kalcifikacijama pa te točke ne uključujemo u računanje srednje vrijednosti S_{Φ_z} i standardne devijacije intenziteta σ_{Φ_z}. Vrijednost komponente brzine λ postavlja se na nulu u točkama kalcifikacije kako bi one mogle biti uključene u regiju zida aorte. Određivanje točaka kalcifikacija potrebno je napraviti jedanput za svaki presjek i to nakon segmentacije unutarnjeg zida aorte.

- Peta komponenta brzine $V_{\Phi_\pm}$ unosi u funkciju brzine utjecaj rezultata segmentacije zida aorte iz susjednih presjeka.

  U jednostavnijem slučaju segmentacija zida aorte na inicijalnom presjeku bila bi provedena bez utjecaja prethodno segmentiranog presjeka. Za svaki sljedeći presjek u nizu koristio bi se rezultat segmentacije zida aorte iz prethodnog susjednog presjeka. Segmentacija se od inicijalnog presjeka može nastaviti paralelno u dva smjera: ispod i iznad njega. Problem ovog pristupa predstavlja akumulacija pogreške, jer korištenje ovakve komponente brzine pretpostavlja da je rezultat segmentacije zida aorte u prethodnom presjeku ispravan. Ukoliko to nije slučaj, a ništa ne garantira točnost, greška se iz prethodnog presjeka, ma koliko mala, ovim putem prenosi u postupak segmentacije zida aorte u slijedećem presjeku. Na taj način se greška akumulira kroz presjeke i za očekivati je da će pogreška segmentacije biti sve veća kako se udaljavamo od inicijalnog presjeka kao što se pokazalo i u [9].

Kako bi doskočili ovom problemu koristi se redoslijed segmentacije presjeka koji nije sekvencijalan, u kojem se cijeli volumen prelazi nekoliko puta. Prvo se segmentira svaki n_0-ti presjek počevši od prvog presjeka. Segmentira se i zadnji presjek. Ovdje je $n_0 = 2^a$, a a se odabire prema jednadžbi (7.21)

$$a = \text{floor}(\log_2 n_p) - 2, \tag{7.21}$$

gdje je n_p ukupna broj presjeka u jednoj CT snimci. Funkcija floor vraća cijeli dio racionalnog broja. Kako se aneurizma abdominalne aorte najčešće proteže na 10-30 presjeka, n_0 najčešće iznosi 4. Ovi presjeci segmentiraju se bez utjecaja susjednih presjeka koje donosi komponenta brzine $V_{\Phi_\pm}$.

Zatim se kreće u drugi prolaz, u kojem se segmentira svaki n_1-ti presjek počevši od prvog. Razmak između presjeka sada iznosi $n_1 = 2^{a-1}$, a segmentiraju se samo presjeci koji nisu već segmentirani. Presjeci u drugom prolazu sada imaju po jedan segmentirani presjek iznad i ispod sebe pa njih koristimo za određivanje komponente brzine $V_{\Phi_\pm}$ prema sljedećoj jednadžbi.

$$V_{\Phi_\pm} = \frac{d_+ \cdot \Phi_+ + d_- \cdot \Phi_-}{d_+ + d_-} \tag{7.22}$$

Ovdje su Φ_+ i Φ_- završne funkcije Φ iz najbližeg sljedećeg i najbližeg prethodnog, već segmentiranog presjeka, dok su d_+ i d_- odgovarajuće udaljenosti tih presjeka od trenutnog presjeka. Najčešće su te dvije udaljenosti jednake, ali iznimka su presjeci blizu prvog i zadnjeg presjeka. Ovakva komponenta brzine $V_{\Phi_\pm}$ čini novu funkciju Φ koja predstavlja „srednji" oblik zida aorte u odnosu na oblik regija zida aorte iz dva susjedna segmentirana presjeka. Komponenta brzine $V_{\Phi_\pm}$ tada provlači krivulju nulte razine deformabilnog modela ka nultoj razini „srednjeg" oblika.

U trećem prolazu ponovo se segmentiraju presjeci segmentirani u prvom prolazu zato što sada i oni imaju susjedne presjeke segmentirane u drugom prolazu, koji se mogu iskoristiti u postupku segmentacije. Komponenta brzine $V_{\Phi_\pm}$ određuje se prema jednadžbi (7.22), a iznimke su prvi i zadnji presjek koji nemaju prethodnog, odnosno sljedećeg segmentiranog presjeka. Za te presjeke vrijednosti Φ_- i d_-, odnosno Φ_+ i d_+ u jednadžbi (7.22) postavljaju se na nulu. Ovim prolazom se nastoje ukloniti eventualne greške u segmentaciji presjeka iz prvog prolaza, pomoću rezultata segmentacije presjeka iz drugog prolaza.

Parametri zajednički segmentaciji unutarnjeg i vanjskog ruba	
δ	6
N_{iter}	4
Segmentacija unutarnjeg ruba	
σ	0.8
v_0	-1
ε	0.2
w	0.015
Segmentacija zida aorte	
v_0	-1
α_1	0.4
α_2	0.05
α_3	0.32
α_4	0.02

Tablica 7.5: Vrijednosti upotrebljenih parametara.

Dalje se na isti način segmentiraju presjeci u sljedećim prolazima s manjim udaljenostima među presjecima $n_2 = 2^{a-2}, n_3 = 2^{a-3}, \ldots n_a = 2^0$. U svakom prolazu se već segmentirani presjeci preskaču.

7.4.4 Rezultati i diskusija

Primjeri rezultati segmentacije pomoću opisane metode prikazani su na slikama 7.18, 7.19, 7.20, 7.21, 7.22 i 7.23. Na slikama 7.18(a), 7.19(a), 7.20(a), 7.21(a), 7.22(a) i 7.23(a) prikazani su originalni CT presjeci. Na slikama 7.18(b), 7.19(b), 7.20(b), 7.21(b), 7.22(b) i 7.23(b) prikazani su unutarnji rubovi aorte dobiveni segmentacijom unutrašnjosti aorte. Na slikama 7.18(b), 7.19(c), 7.20(c), 7.21(c), 7.22(c) i 7.23(c) prikazani su samo vanjski rubovi aorte iako opisana metoda segmentira cijeli zid aorte.

Korišteni parametri level-set algoritma dani su tablicom 7.5, a njihove vrijednosti određene su eksperimentalno kao i u prethodnim pristupima. Promatranjem parametara α može se uočiti da se najveća težina daje utjecaju zakrivljenosti (α_1) i kriteriju homogenosti (α_3). Po tome je ovaj pristup sličan osnovnom level-set algoritmu čija funkcija brzine ima konstantnu brzinu, brzinu ovisnu o zakrivljenosti i brzinu ovisnu o podacima sa slike. Utjecaj zakrivljenosti unutarnjeg ruba aorte (α_2) i utjecaj rezultata segmentacije zida aorte iz prethodnog presjeka (α_4)

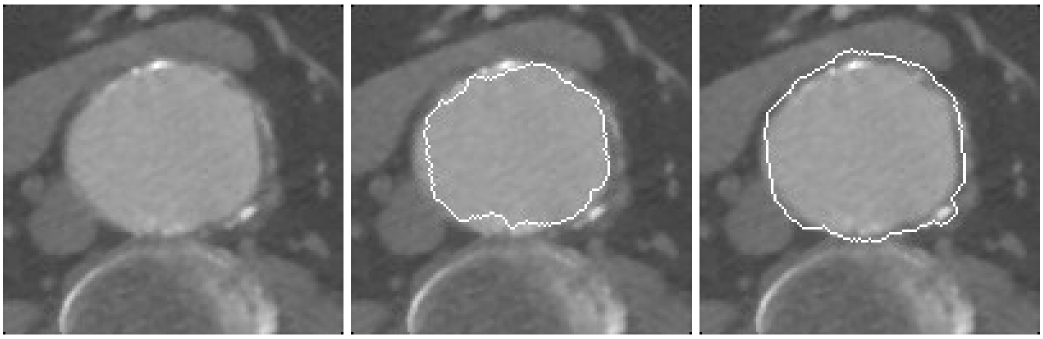

(a) (b) (c)

Slika 7.18: Primjer 1. segmentacije aneurizme abdominalne aorte

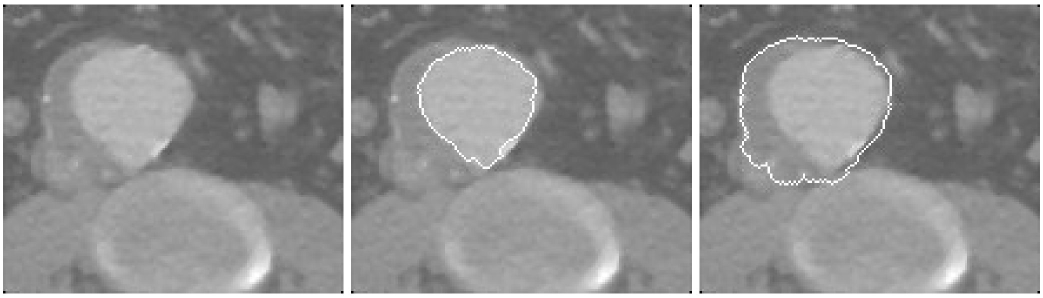

(a) (b) (c)

Slika 7.19: Primjer 2. segmentacije aneurizme abdominalne aorte

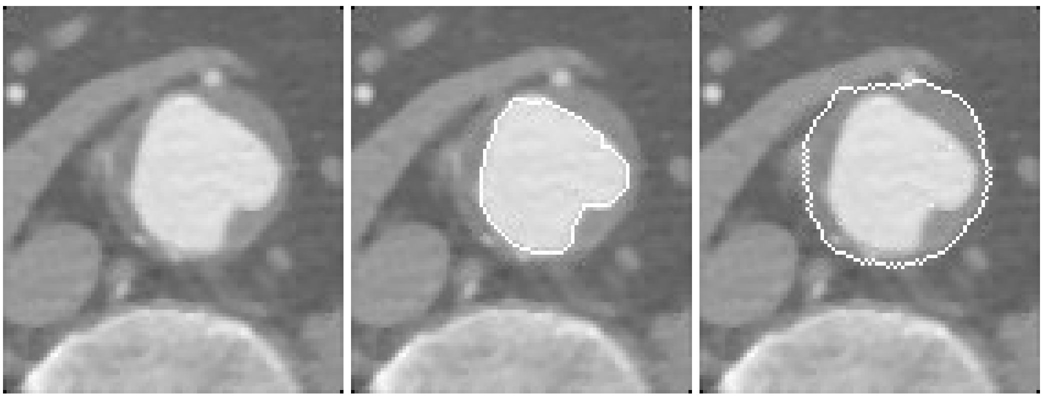

(a) (b) (c)

Slika 7.20: Primjer 3. segmentacije aneurizme abdominalne aorte

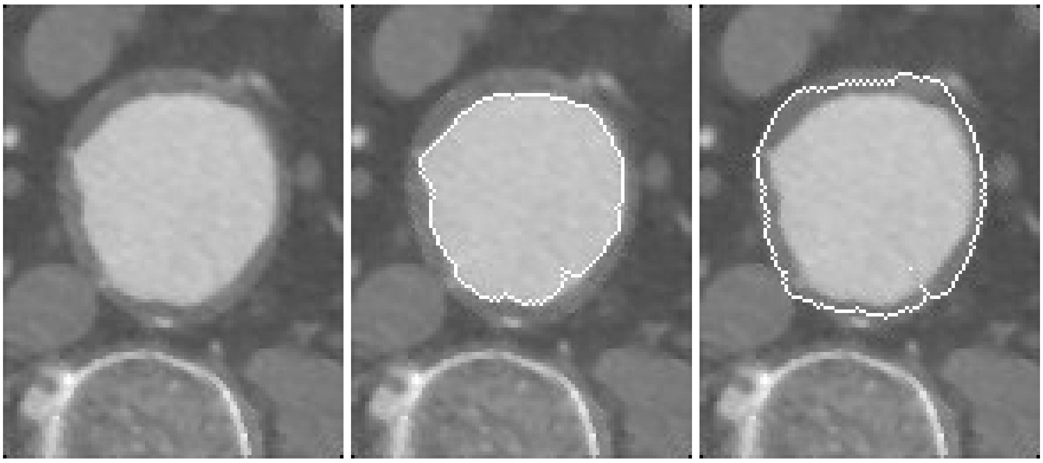

(a) (b) (c)

Slika 7.21: Primjer 4. segmentacije aneurizme abdominalne aorte

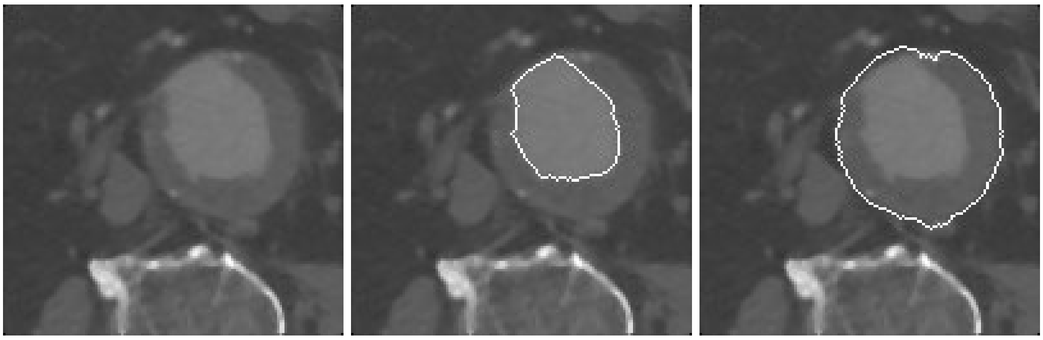

(a) (b) (c)

Slika 7.22: Primjer 5. segmentacije aneurizme abdominalne aorte

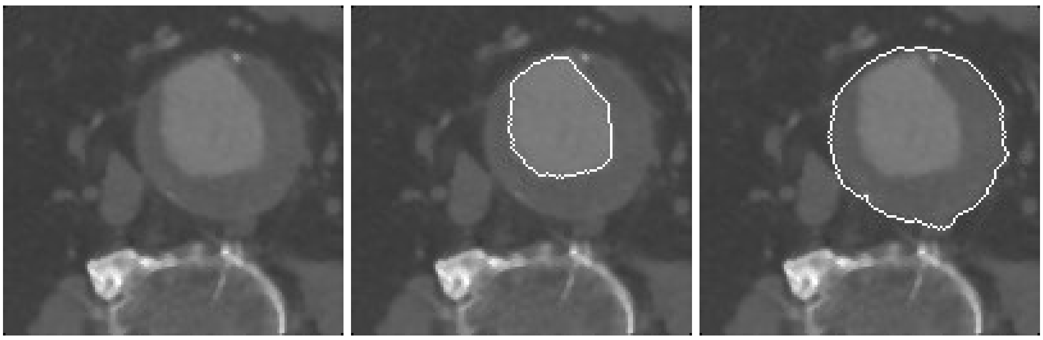

(a) (b) (c)

Slika 7.23: Primjer 6. segmentacije aneurizme abdominalne aorte

imaju manju težinu. Sličnost zakrivljenosti unutarnjeg i vanjskog ruba aorte uglavnom postoji no to nije pravilo. Iako pomoću te sličnosti zakrivljenosti nastojimo poboljšati rezultate segmentacije, ne sijemo se previše oslanjati na nju, tako da je težina α_2 manja od α_1 i α_3. Znatna sličnost oblika vanjskih rubova aorte na susjednim presjecima gotovo uvijek postoji, no uvijek postoji i mogućnost pogrešne segmentacije susjednog presjeka, čime bi na sljedeći presjek djelomično prenijeli tu grešku. Stoga je i težinski faktor α_4 manji.

Metoda je primijenjena na segmentaciju vanjskog ruba aorte na 12 CT snimaka. Od tih 12 CT snimaka, 11 je korišteno u testiranju metode iz poglavlja 7.3. Kako ručno ispravljeni rezultati segmentacije opisanom metodom nisu bili dostupni, izvršena je usporedba s rezultatima segmentacije poluautomatskom metodom segmentacije opisanom u [25], koji se smatraju referentnim rezultatima. Usporedba rezultata segmentacije napravljena je na način opisan u odlomku 7.3.4. Prikupljene su tri statističke veličine za rezultate ovdje opisane metode: srednja relativna pogreška za svakog pacijenta, standardna devijacija relativnih pogrešaka za svakog pacijenta te koeficijent korelacije za svakog pacijenta. Ti podaci prikazani su u tablici 7.6. Iste statističke veličine izračunate za sve segmentirane presjeke zajedno i prikazane u tablici 7.7. Radi usporedbe, u tablici 7.7 navedeni su i odgovarajući rezultati metode iz odlomka 7.3.

Iako ovdje opisana metoda daje bolje rezultate segmentacije od pristupa opisanih u odlomcima 7.1 i 7.2, iz tablica 7.6 i 7.7 može se vidjeti da su ti rezultati lošiji od rezultata pristupa iz poglavlja 7.3.

Najznačajnija komponenta ovdje opisane metode ($\lambda(p)$) temelji se na intenzitetu točaka presjeka i njihovom odnosu prema intenzitetu točaka koje su već ušle u unutrašnjost regije zida aorte. Takav pristup je lokalnog karaktera, a informacija koju koristi (intenzitet točaka) je niske složenosti. Najznačajnija komponenta pristupa iz poglavlja 7.3 koristi informaciju o obliku regije aorte, odnosno unaprijed definirani uvjet koji mora zadovoljiti oblik aorte. Takva informacija ima viši stupanj apstrakcije i bolje utjelovljuje znanje koje posjedujemo o aorti. Vjerojatno u tome leži ključ većeg uspjeha pristupa opisanog u poglavlju 7.3.

Jedan dio pogreške ovdje opisane metode vjerojatno je posljedica problema same validacije rezultata, kako je opisano u odlomku 7.3.4.

	opisana metoda & ručno ispravljena poluautomatska metoda		
	korel.	sr. pog. [%]	std. dev. [%]
1	0.90	29.71	13.31
2	0.81	36.61	13.43
3	0.68	27.52	13.99
4	0.75	35.47	16.57
5	0.53	44.19	26.02
6	0.86	36.32	18.36
7	0.56	36.49	20.67
8	0.95	33.50	19.14
9	0.45	43.26	17.35
10	0.37	44.68	23.99
11	0.91	19.36	11.55
12	0.30	21.28	7.00

Tablica 7.6: Rezultati usporedbe za sve pacijente

	koeficijent korelacije	srednja relativna pogreška [%]	standardna devijacija pogreške [%]
opisana metoda & ručno ispravljena poluautomatska metoda	0.86	35.39	19.68
metoda iz odlomka 7.3 & ručno ispravljena poluautomatska metoda	0.91	19.75	13.29

Tablica 7.7: Rezultati usporedbe za sve presjeke

Poglavlje 8

Zaključak

Ovaj rad bavi se problemom segmentacije medicinskih slika. Konkretno, radi se o segmentaciji aneurizme abdominalne aorte iz niza CT slika. Kako aorta ima dvije površine: unutarnju i vanjsku, rezultat segmentacije može biti bilo unutarnja, vanjska ili obje granice aorte. Automatska segmentacija aneurizme abdominalne aorte, a pogotovo segmentacija njenog vanjskog ruba još uvijek nije adekvatno riješena i postojeća literatura koja se bavi tim problemom vrlo je rijetka. Pokazao se da segmentacija vanjskog ruba aorte predstavlja složeni problem koji je posljedica samog načina akvizicije slika. Najveći problem predstavljaju mjestimično slabo izražene vanjske granice aorte zbog čega i obučeni liječnici imaju problema u interpretaciji CT slika. Velika pažnja u ovom radu posvećena je rješavanju upravo tog problema.

Unaprijed je odlučeno je da će se segmentacija raditi pomoću deformabilnog modela zbog velike popularnosti i uspješne primjene u segmentaciji slika, a pogotovo u segmentaciji medicinskih slika. Odabran je geometrijski (*level-set*) deformabilni model zbog svojih prednosti pred parametarskim deformabilnim modelima.

U radu su predstavljena četiri različita pristupa segmentacije aneurizme abdominalne aorte, kojima je zajedničko korištenje geometrijskih deformabilnih modela. U pristupima su korištene 2-D i 3-D varijante geometrijskog deformabilnog modela. Prva dva pristupa karakterizira nastojanje što ranijeg detektiranje prodora deformabilnog modela kroz rupu u vanjskom rubu aorte i zaustavljanja tog segmenta deformabilnog modela kada je prodor detektiran. Prva dva pristupa razlikuju se u načinu detekcije i u načinu zaustavljanja deformabilnog modela. Glavni nedostatak tih pristupa je što oni mogu djelovati tek naknadno kada se prodor već desio. Treći pristup karakterizira poseban postupak rekonstrukcije slabo izraženih vanjskih granica aorte, koji se primjenjuje prije primjene deformabilnog modela. U postupak rekonstrukcije uključeno je znanje o obliku regije aorte te je to ključ najvećeg uspjeha trećeg pristupa. Četvrti pristup karakterizira level-set algoritam zasnovan na sličnosti regija, te prilagodbe za prevladavanje problema slabo izraženih vanjskih rubova aorte, koje su ukomponirane u sami algoritam deformabilnog modela. Takvim kompaktnim, a onda i jednostavnijim pristupom nastojalo se riješiti problem segmentacije vanjskog ruba aorte.

Različiti pristupi dali su različite rezultate. Treći pristup pokazao se znatno uspješnijim od prva dva te je on testiran na 11 CT snimaka stvarnih pacijenata. Ti rezultati segmentacija uspoređeni su sa referentnim rezultatima. Napravljena je programska aplikacija koja se primjenjuje na radiološkom odjelu Sveučilišne bolnice u Grazu, u Austriji. Četvrti pristup dao je bolje rezultate od prvog i drugog pristupa, no lošije od trećeg pristupa.

Razlog većeg uspjeha trećeg pristupa može se potražiti u glavnom koraku rekonstrukcije slabo izraženih vanjskih granica aorte koji uz korištenje lokalnih informacija sa slike, koristi i informaciju o obliku regije aorte.

Tijekom testiranja trećeg pristupa na CT snimkama stvarnih pacijenata pokazalo se da, kao i ovdje opisane metode, i liječnici imaju poteškoća u određivanju vanjske granice abdominalne aorte, zbog nedostataka u postupku akvizicije slika, odnosno ograničenja CT uređaja. Liječnici nastoje prevladati taj problem pomoću znanja o obliku i fizikalnim svojstvima aorte, ali i okolnih tkiva i organa, dok se u ovom radu koncentriralo na samu aortu i nastojalo se iskoristiti znanje o njenom obliku. Gledano na ovaj način, poboljšanje uspješnosti automatske segmentacije može se očekivati ako se ne modelira samo aorta već i organi u njenoj okolici. Modeliranje okoline abdominalne aorte značilo bi modeliranje cijele abdominalne šupljine ili samo njenog jednog dijela. Zbog broja organa i svih mogućih varijacija njihovih odnosa to bi bez sumnje bio vrlo složen problem.

Publikacije

[p1] S. Loncaric, M. Subasic, and E. Sorantin. 3-D deformable model for abdominal aortic aneurysm segmentation from ct images. In *Proceeings of the First Int'l Workshop on Image and Signal Processing and Analysis*, pages 139–144, Pula, Croatia, 2000.

[p2] S. Loncaric, M. Subasic, and E. Sorantin. 3-D deformable model for aortic aneurysm segmentation from ct images. In *Proceedings of World Congress on Medical Physics and Biomedical Engineering*, Chicago, USA, 2000.

[p3] E. Sorantin, E. Balogh, A. Vilanova Bartrolí, K. Palágyi, L. G. Nyúl, S. Lončarić, M. Subašić, and D. Kovačević. *3D Image Processing: Techniques and Clinical Applications*, chapter Virtual Dissection of the Colon. Springer Verlag. Springer Verlag, 2002.

[p4] M. Subasic, S. Loncaric, and E. Sorantin. 3-D image analysis of abdominal aortic aneurysm. In *Proceedings of Medical Informatics Europe 2000*, pages 1195–1200, Hanover, Germany, 2000.

[p5] M. Subasic, S. Loncaric, and E. Sorantin. 3-D deformable model segmentation of abdominal aortic aneurysm. In *Proceedings of SPIE Medical Imaging*, San Diego, USA, 2001.

[p6] M. Subasic, S. Loncaric, and E. Sorantin. Shape-specific adaptations for level-set deformable model-based segmentation. In *Proceedings of Computer Vision Winter Workshop*, pages 104–113, Bled, Slovenia, 2001.

[p7] M. Subasic, S. Loncaric, and E. Sorantin. 3-D image analysis of abdominal aortic aneurysm. In *Proceedings of SPIE Medical Imaging*, pages 1681–1689, San Diego, USA, 2002.

[p8] Marko Subasic, Domagoj Kovacevic, Sven Loncaric, and Erich Sorantin. Segmentation of abdominal aortic aneurysm using deformable models. In *Proceedings of East West Vision*, pages 61–66, Graz, Austria, 2002.

Bibliografija

[1] Gilles Aubert and Laure Blanc-Féraude. An elementary proof of the equivalence between 2D and 3D classical snakes and geodesic active contours. Technical Report 3340, Institut National de Recherche en Informatique et en Automatique, 1998.

[2] C. Baillard, C. Barillot, and P. Bouthemy. Robust adaptive segmentation of 3D medical images with level sets. Technical Report 1369, Institut National de Recherche en Informatique et en Automatique, 2000.

[3] V. Caselles, F. Catte, T. Coll, and F. Dibos. A geometric model for active contours. *Numerische Mathematik*, (66):1–31, 1993.

[4] Vincent Caselles, Ron Kimmel, and Guillermo Sapiro. Geodesic active contours. In *ICCV*, pages 694–699, 1995.

[5] T. Chan, B. Sandberg, and L. Vese. Active contours without edges for vector-valued images. *Visual Communication Image Representation*, 11(2):130–140, 2000.

[6] Tony F. Chan and Luminita A. Vese. Image segmentation using level sets and the picewise-constant mumford-shah model. Technical Report 00-14, University of California, 2000.

[7] Tony F. Chan and Luminita A. Vese. Active contours without edges. In *IEEE Transactions on Image Processing*, volume 10, pages 266–277, 2001.

[8] M. de Bruijne, W. Niessen, J. Maintz, and M. Viergever. Semi-automatic aortic endograft localisation for post-operative evaluation of endovascular aneurysm treatment. In *SPIE Medical Imaging*, volume 4322, pages 395–406, 2001.

[9] Marleen de Bruijne, Bram van Ginneken, Wiro J. Niessen, and J.B. Antoine Maintz nad Max A. Viergever. Active shape models exploiting slice-to-slice correlation in segmenta-

tion of 3D cta aaa images. Technical report, Image Sciences Institute, University Medical Center Utrecht, 2001.

[10] M Kass, A Witkin, and D Terzopolous. Snakes: Active contour models. In *In Proc. First International Conference on Computer Vision*, pages 259–268. IEEE Computer Society Press, 1987.

[11] Michael Leventon, Eric Grimson, and Olivier Faugeras. Statistical shape influence in geodesic active contours. In *Computer Vision and Pattern Recognition (CVPR)*, pages 316–323, 2000.

[12] Derek Mageea, Andrew Bulpitt, and Elizabeth Berry. Level set methods for the 3D segmentation of CT images of abdominal aortic aneurysms. In *Proc. of Medical Image Understanding and Analysis*, 2001.

[13] Ravi Malladi and James A. Sethian. Level set methods for curvature flow, image enhancement, and shape recovery in medical images. In *Proceedings of Conference on Visualization and Mathematicss*, pages 329–345, Berlin, Germany, 1995.

[14] Ravi Malladi and James A. Sethian. An O(N log N) algorithm for shape modeling. In *Proceedings of the National Academy of Sciences*, volume 93, pages 9389–9392, 1996.

[15] Ravi Malladi and James A. Sethian. A real-time algorithm for medical shape recovery. In *ICCV*, pages 304–310, 1998.

[16] Ravi Malladi, James A. Sethian, and Baba C. Vemuri. Shape modeling with front propagation: A level set approach. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17(2):158–175, 1995.

[17] Stanley Osher and James A. Sethian. Fronts propagating with curvature-dependent speed: Algorithms based on Hamilton-Jacobi formulations. *Journal of Computational Physics*, 79:12–49, 1988.

[18] Nikos Paragios and Rachid Deriche. A PDE-based level-set approach for detection and tracking of moving objects. Technical Report 3173, Institut National de Recherche en Informatique et en Automatique, 1997.

[19] Nikos Paragios and Rachid Deriche. Geodesic active region for texture segmentation. Technical Report 3440, Institut National de Recherche en Informatique et en Automatique, 1998.

[20] Nikos Paragios and Rachid Deriche. A PDE-based level-set approach for detection and tracking of moving objects. In *ICCV*, pages 1139–1145, 1998.

[21] Nikos Paragios and Rachid Deriche. Geodesic active regions for supervised texture segmentation. In *ICCV (2)*, pages 926–932, 1999.

[22] Nikos Paragios and Rachid Deriche. Geodesic active regions for supervised texture segmentation. In *Proceedings of Computer Vision and Pattern Recognition*, pages 23–24, Fort Collins, Colorado, USA, 1999.

[23] A. Pogorelov. *Geometry*. Mir Publishers, Moscow, 1987.

[24] Richard A. Robb. *Three-Dimensional Biomedical Imaging: Principles and Practice*. Wiley-Liss, 1994.

[25] E. Sorantin S. Loncaric, D. Kovacevic. Semi-automatic active contour approach to segmentation of computed tomography volumes. In *Proceedings of SPIE Medical Imaging*, volume 3979, 2000.

[26] J. A. Sethian. *Level Set Methods and Fast Marching Methods: Evolving Interfaces in Computational Geometry, Fluid Mechanics, Computer Vision, and Materials Science*. Cambridge University Press, 1999.

[27] Chris Spatz. *Basic Statistics: Tales of Distributions*. Brooks/Cole, 6th edition, 1997.

[28] Baris Sumengen, B. S. Manjunath, and Charles Kenney. Image segmentation using curve evolution. In *Asilomar Conference on Signals, Systems and Computers*, Monterey, CA, USA, 2001.

[29] Baris Sumengen, B. S. Manjunath, and Charles Kenney. Image segmentation using curve evolution and region stability. In *Proceedings of International Conference on Pattern Recognition (ICPR) 2002*, 2002.

[30] Baris Sumengen, B. S. Manjunath, and Charles Kenney. Image segmentation using curve evolution and flow fields. In *International Conference on Image Processing (ICIP)*, Rochester, NY, USA, 2002.

[31] J. Suri, K. Liu, S. Singh, S. Laxminarayana, and L. Reden. Shape recovery algorithms using level sets in 2-D/3-D medical imagery: A state-of-the-art review. *IEEE Trans. in Information Technology in Biomedicine (ITB)*, 2001.

[32] D. Terzopoulos. On matching deformable models to images: Direct and iterative solutions. In *Topical Meeting on Machine Vision, Technical Digest Series*, volume 12, pages 160–167, Washington, DC, 1987. Optical Society of America.

[33] O. Wink, W.J. Niessen, and M.A. Viergever. Fast delineation and visualization of vessels in 3-D angiographic images. *IEEE Transactions on Medical Imaging*, 19(4):337–346, 2000.

[34] Chenyang Xu, Dzung L. Pham, and Jerry L. Prince. *Handbook of Medical Imaging - Volume 2: Medical Image Processing and Analysis*, chapter Image Segmentation Using Deformable Models, pages 129–174. SPIE Press, 2000.

Sažetak

Istraživačko područje rada je digitalna analiza medicinskih slika. Rad se bavi segmentacijom CT slika aneurizme abdominalne aorte. Motivacija za istraživanje je potreba za automatskom segmentacijom aneurizme abdominalne aorte, koja bi oslobodila liječnike dugotrajne i zamorne ručne segmentacije. Segmentirati se može unutarnji i vanjski rub aorte. Pokazalo se da je segmentacija vanjskog ruba aorte puno veći problem od segmentacije unutarnjeg ruba, pa je glavno težište rada stavljeno na segmentaciju vanjskog ruba aorte. U prvom dijelu rada dan je kratak uvod u segmentaciju slika i deformabilne modele. Iznesena je osnovna teorija geometrijskih deformabilnih modela. U drugom dijelu rada opisana su četiri pristupa segmentacije aneurizme abdominalne aorte, kojima je zajedničko korištenje geometrijskog deformabilnog modela. Svaki od pristupa na drugačiji način nastoji riješiti specifične probleme segmentacije vanjskog ruba aorte. Razvijene metode segmentacije isprobane su na nekoliko CT snimaka koje su se sastojale od nekoliko desetaka presjeka. Dva pristupa koja su pokazala najbolje rezultate testirana su na 11, odnosno 12 CT snimaka stvarnih pacijenata. Rezultati segmentiranja ta dva pristupa uspoređeni su sa referentnim rezultatima koji su dobiveni ručnom segmentacijom.

Ključne riječi: digitalna obrada slike, digitalna analiza slike, digitalna obrada medicinskih slika, segmentacija, deformabilni modeli, level-set metoda, aneurizma abdominalne aorte

Abstract

The field of research of this thesis is in medical image analysis. The topic of the thesis is the segmentation of CT images of the abdominal aortic aneurysm. The research is motivated by the need for an automatic segmentation of the abdominal aortic aneurysm, that would relive physicians of tedious and time-consuming manual segmentation. Both the inner and the outer aortic border can be segmented. The segmentation of the outer aortic border presents a more difficult task than the inner aortic border segmentation. In first part of the thesis an introduction to image segmentation techniques and especially deformable model was presented. The theory of geometric deformable models is explained in more details. The second part of the thesis presents four approaches to the segmentation of abdominal aortic aneurysm. All approaches try to solve the problems of the outer aortic border segmentation in a different way, but they all use geometric deformable model as primary segmentation technique. Developed methods were tested on several CT scans. Two methods that gave best results were applied to 11 CT scans of real patients. The results were compared to reference segmentation results, obtained by manual segmentation.

Keywords: digital image processing, digital image analysis, medical image analysis, image segmentation, deformable models, level sets, abdominal aortic aneurysm

Životopis

Rođen sam 13. travnja 1976. godine u Zagrebu. U Zagrebu sam završio osnovnu školu, a 1994. godine maturirao sam na V gimnaziji. Iste godine upisujem dodiplomski studij na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu. Studij sam završio na smjeru Industrijska elektronika, a diplomski rad napravio sam na Zavodu za elektroničke sustave i obradbu informacija. Diplomski rad bio je iz područja trodimenzionalne vizualizacije, a obranio sam ga 1999. godine sa odličnim uspjehom. Iste godine zapošljavam se na Fakultetu elektrotehnike i računarstva kao znanstveni novak i upisujem znanstveni poslijediplomski studij na FER-u, smjer Elektronika.

Područje istraživanja i interesa mi je digitalna obrada i analiza slike, a uže područje je obrada i analiza medicinskih slika. Koautor sam nekoliko članaka iz tog područja koji su objavljeni na međunarodnim konferencijama.