

TESIS - IF 185401

ACTIVE CONTOUR BERBASIS LOCAL GAUSSIAN DENGAN NEW VARIATIONAL LEVEL SET UNTUK SEGMENTASI GLOBUS PALLIDUS

YOHANES SETIAWAN NRP. 05111850010025

Dosen Pembimbing I Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.

Dosen Pembimbing II Prof. Drs. Ec. Ir. Riyanarto Sarno, M.Sc., Ph.D.

Departemen Teknik Informatika Fakultas Teknologi Elektro dan Informatika Cerdas Institut Teknologi Sepuluh Nopember 2020

Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar Magister Komputer (M. Kom)

di

Institut Teknologi Sepuluh Nopember

Oleh:

YOHANES SETIAWAN NRP: 05111850010025

Tanggal Ujian: 13 Juli 2020 Periode Wisuda: September 2020

Disetujui oleh: **Pembimbing:**

1. Dr. Eng. Chastine Fatichah, S.Kom., M.Kom NIP: 19751220 200112 2 002

2. Prof. Drs. Ec. Ir. Riyanarto Sarno, M.Sc., Ph.D. NIP. 19590803 198601 1 001

Penguji:

1. Prof. Dr. Agus Zainal Arifin, S.Kom., M.Kom. NIP: 19720809 199512 1 001

2. Dr. Eng. Nanik Suciati, S.Kom., M.Kom. NIP: 19710428 199412 2 001

3. Dr. Eng. Darlis Herumurti, S.Kom., M.Kom. NIP: 19771217 200312 1 001

Chaitmit Hellnard

Kepala Departemen Teknik Informatika Fakultas Teknologi Elektro dan Informatika Cerdas

Or. Eng Chastine Fatichah, S.Kom., M.Kom NIP: 19751220 200112 2 002

Halaman ini sengaja dikosongkan

ACTIVE CONTOUR BERBASIS LOCAL GAUSSIAN DENGAN NEW VARIATIONAL LEVEL SET UNTUK SEGMENTASI GLOBUS PALLIDUS

Nama : Yohanes Setiawan

NRP : 05111850010025

Pembimbing : Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.

Prof. Ir. Riyanarto Sarno, M.Sc., Ph.D.

ABSTRAK

Segmentasi Globus Pallidus (GPi) pada citra MRI telah banyak dilakukan dengan metode berbasis atlas maupun deep learning. Namun, kedua metode tersebut mengharuskan memiliki atlas yang sesuai dan data training dalam jumlah besar yang sulit diperoleh. Salah satu metode segmentasi lainnya adalah Active Contour, yang melakukan segmentasi pada boundary obyek. Namun, Active Contour standar sulit mengatasi obyek memiliki kontras rendah disekitar obyek dan weak boundary seperti GPi.

Dalam penelitian ini diusulkan Active Contour berbasis *Local Gaussian* dengan *New Variational Level Set* sebagai metode usulan untuk perbaikan deteksi *boundary* pada segmentasi obyek GPi. Input dari penelitian ini adalah citra MRI dengan *slicing* Axial. Selanjutnya, metode usulan diuji dengan dua skenario uji coba. Skenario uji coba pertama menggunakan inisialisasi kontur secara manual, sedangkan skenario uji coba kedua menggunakan inisialisasi kontur secara otomatis dengan model *Shape Prior* dan model *Rectangle*. Output dari penelitian ini adalah citra hasil segmentasi obyek GPi.

Melalui hasil evaluasi uji coba yang telah dilakukan, dapat ditarik kesimpulan bahwa metode usulan terbukti mampu melakukan segmentasi Globus Pallidus yang memiliki kontras rendah dan *weak boundary* di citra MRI yang berkarakteristik *intensity inhomogeneity*. metode usulan meraih nilai terbesar dan terkecil rata-rata (Mean) pada nilai DSC dan ME dibandingkan metode lainnya. Pada skenario uji coba 1 dengan inisialisasi kontur secara manual, nilai Mean dari DSC dan ME pada metode usulan adalah 0.8335 dan 0.0050. Lalu pada skenario uji coba 2 dengan otomatisasi inisialisasi kontur model *Shape Prior*, nilai Mean dari DSC dan ME adalah 0.5523 dan 0.00843. Selanjutnya pada skenario uji coba 2 dengan model *Rectangle*, nilai Mean dari DSC dan ME adalah 0.6672 dan 0.0114.

.

Kata kunci: Segmentasi, Globus Pallidus, Active Contour, Local Gaussian, New Variational Level Set

Halaman ini sengaja dikosongkan

ACTIVE CONTOUR BASED ON LOCAL GAUSSIAN WITH NEW VARIATIONAL LEVEL SET

FOR GLOBUS PALLIDUS SEGMENTATION

Nama : Yohanes Setiawan

NRP : 05111850010025

Pembimbing : Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.

Prof. Ir. Riyanarto Sarno, M.Sc., Ph.D.

ABSTRACT

Globus Pallidus (GPi) segmentation on MRI images has been carried out with atlas-based and learning-based methods. However, both methods must have an appropriate atlas and large amounts of training datasets that are difficult to obtain. Another segmentation method is Active Contour, which performs segmentation on boundary objects. However, the standard Active Contour is difficult to overcome objects which have low contrast and weak boundary such as GPi as the object.

In this research, Active Contour based on *Local Gaussian* with New Variational Level Set is proposed as a proposed method to prevent false boundaries in segmenting GPi objects. The input of this research is the MRI image with Axial slicing. Furthermore, the proposed method is tested with two research scenarios. The first research scenario uses the contour initialization manually, while the second research scenario uses the contour initialization automatically with the model of Shape Prior and *Rectangle*. The output of this research is the image of segmentation results from each research scenario.

Through the evaluation results of the research scenario that have been carried out, it can be concluded that: qualitatively, the proposed method is proven to be able to segment Globus Pallidus with low contrast and weak boundary in intensity inhomogeneity of MRI images. Quantitatively, the proposed method achieves the largest and smallest values on the mean (Mean) respectively in the DSC and ME values. In the research scenario 1, the Mean values of DSC and ME are 0.8335 and 0.0050, respectively. In the research scenario 2 from Model of the Shape Prior, the Mean values of DSC and ME are 0.5523 and 0.00843, respectively. Furthermore, in the research scenario 2 from Model of *Rectangle*, the Mean values of DSC and ME are 0.6672 and 0.0114, respectively.

Keywords: Segmentation, Globus Pallidus, Active Contour, Local Gaussian, New Variational Level Set

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Puji syukur kepada Tuhan Yesus Kristus oleh karena berkat dan anugerah-Nya penulis dapat menyelesaikan tesis dengan judul "Active Contour Berbasis Local Gaussian dengan New Variational Level Set untuk Segmentasi Globus Pallidus". Penulis mengucapkan terima kasih atas doa dan dukungan kepada:

- 1. Ibu Dr. Eng. Chastine Fatichah, S.Kom., M.Kom. sebagai Dosen Pembimbing I yang telah membimbing penulis dalam menyusun tesis dalam dukungan semangat dan ilmu melalui progress mingguan.
- 2. Bapak Prof. Drs. Ec. Ir. Riyanarto Sarno, M.Sc., Ph.D. sebagai Dosen Pembimbing II yang telah membimbing penulis dalam penyusunan tesis dan memotivasi penulis untuk melakukan publikasi ilmiah berskala internasional.
- 3. Bapak Prof. Dr. Agus Zainal Arifin, S.Kom., M.Kom.; Ibu Dr. Eng. Nanik Suciati, S.Kom., M.Kom.; serta Bapak Dr. Eng. Darlis Herumurti, S.Kom., M.Kom. sebagai Dosen Penguji yang telah memberikan masukan yang berharga bagi tesis ini.
- 4. Papa saya, Gigih Daniel, dan mama saya, Antonia Wiryandari Mokalu, dan adik perempuan saya, Ribka Agustin, yang sudah memberi dukungan doa dan semangat bagi penulis untuk menyusun tesis.
- 5. Teman-teman S2 TC 2018 yang saya kasihi: Ais, *partner* dosen pembimbing sama yang selalu bersama-sama berproses dengan penulis dari proposal, jurnal di IJIES (INASS) hingga sidang tesis, dan Mbak Kelly yang sudah membantu dalam memberikan ilmu menulis jurnal berbahasa Inggris kepada penulis dengan baik, lalu Mas Adam yang membantu mengajarkan penulis untuk membuatkan citra *ground truth* kepada penulis melalui aplikasi edit foto, serta seluruh jajaran teman-teman S2 TC 2018 yang tidak bisa saya sebut secara satu persatu.

6. Teman-teman UKM Kristen Unair dan KA 2013 Unair: Danu, Yoan, Winson, Evan, Diandy, Chikita, Riry, Antony, Njin, Hansel, dan masih banyak lagi yang membantu penulis dalam dukungan doa dalam doa malam bersama ketika penulis akan melakukan ujian tesis.

7. Seluruh pihak yang terlibat dalam memberikan semangat kepada penulis untuk menyusun tesis ini dengan berani dan tepat.

Kiranya berkat dan kasih karunia Tuhan menghampiri setiap pihak yang sudah terlibat dalam memberi motivasi kepada penulis untuk menyelesaikan tesis. Penulis menyadari bahwa penelitian ini masih sangat jauh dari sempurna. Oleh karena itu, kritik dan saran sangat dibutuhkan oleh penulis agar bisa lebih baik lagi. Akhir kata, semoga penelitian yang tertuang dalam buku tesis ini bermanfaat bagi bidang medis sesuai cita-cita penulis dan dikembangkan lebih lanjut.

Surabaya, 23 Juli 2020

Yohanes Setiawan

DAFTAR ISI

ABSTRAK	III
ABSTRACT	V
KATA PENGANTAR	VII
DAFTAR ISI	IX
DAFTAR GAMBAR	XI
DAFTAR TABEL	XIII
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 PERUMUSAN MASALAH	5
1.3 TUJUAN PENELITIAN	5
1.4 Manfaat Penelitian	5
1.5 KONTRIBUSI PENELITIAN	5
1.6 Batasan Masalah	6
BAB 2 KAJIAN PUSTAKA DAN DASAR TEORI	7
2.1 Globus Pallidus	7
2.2 STATISTICAL DEFORMABLE MODEL	8
2.2.1 Labelling Data Training	8
2.2.2 Proses Alignment Data Training	9
2.3 ACTIVE CONTOUR	11
2.3.1 Model Active Contour Chan-Vese	12
2.3.2 Model Active Contour Region Scalable Fitting (RSF)	15
2.4 New Variational Level Set	18
2.5 Segmentasi Citra dengan <i>Local Gaussian</i>	19
2.6 METODE EVALUASI SEGMENTASI CITRA	21
BAB 3 METODE PENELITIAN	23
3.1 Studi Literatur	23
3.2 PERANCANGAN METODE YANG DIUSULKAN	24
3.2.1 Preprocessing Citra	25
3.2.2 Inisialisasi Kontur Awal Berbasis Training Phase	25

3.2.2.1 Peletakan Titik Object Boundary	26
3.2.2.2 Proscrustes Analysis	27
3.2.2.3 Mean Shape	27
3.2.3 Evolusi Kontur dengan Metode Usulan	28
3.3 IMPLEMENTASI METODE	29
3.4 Evaluasi Hasil	29
BAB 4 HASIL PENELITIAN DAN PEMBAHASAN	31
4.1 Hasil penelitian	31
4.1.1 Lingkungan Uji Coba	31
4.1.2 Data Uji Coba	31
4.1.3 Hasil Pre-processing	32
4.1.4 Hasil Skenario Uji Coba 1	33
4.1.5 Hasil Skenario Uji Coba 2	35
4.1.5.1 Hasil Peletakan Titik Data Model	35
4.1.5.2 Hasil Keluaran Inisialisasi Kontur Berbasis Training Pha	se36
4.1.5.3 Hasil Segmentasi Model Shape Prior	37
4.1.5.4 Hasil Segmentasi Model Rectangle	40
4.2 PEMBAHASAN HASIL PENELITIAN	43
4.2.1 Pembahasan secara Kualitatif	43
4.2.2 Pembahasan secara Kuantitatif	47
BAB 5 KESIMPULAN DAN SARAN	49
5.1 Kesimpulan	49
5.2 Saran	50
DAFTAR PUSTAKA	51
LAMPIRAN-LAMPIRAN	53

DAFTAR GAMBAR

Gambar 2.1 Citra MRI dengan <i>Globus Pallidus</i>	7
Gambar 2.2 Contoh Model Labelling Data Training	9
Gambar 2.3 Contoh Proses Alignment	. 11
Gambar 2.4 Hasil segmentasi citra dari New Variational Level Set	. 18
Gambar 3.1 Alur Metodologi Penelitian	. 23
Gambar 3.2 Flowchart Metode Penelitian	. 24
Gambar 3.3 Flowchart tahap preprocessing citra	. 25
Gambar 3.4 Flowchart tahap inisialisasi kontur awal berbasis training phase	. 25
Gambar 3.5 Flowchart peletakan titik object boundary	. 26
Gambar 3.6 Flowchart Proscrustes Analysis	. 27
Gambar 3.8. Flowchart Mean Shape	. 27
Gambar 3.9. Flowchart <i>tahap evolusi kontur</i>	. 28
Gambar 4.1 Citra Model	. 33
Gambar 4.2 Contoh inisialisasi kontur	. 33
Gambar 4.3 Contoh Hasil Uji Coba Skenario 1	. 34
Gambar 4.4. Contoh proses peletakan titik	. 36
Gambar 4.5. Contoh hasil model kontur awal shape prior	. 38
Gambar 4.6 Citra yang Tidak Cocok dengan Model Shape Prior	. 38
Gambar 4.7 Contoh Hasil Uji Coba Skenario 2 Model Shape Prior	. 39
Gambar 4.8 Contoh Hasil Uji Coba Skenario 2 Model Rectangle	. 40
Gambar 4.9 Grafik Fungsi Arctan	. 45

Halaman ini sengaja dikosongkan

DAFTAR TABEL

Tabel 4.1 Normalisasi Citra	. 32
Tabel 4.2 Hasil DSC dan ME Skenario Uji Coba 1	. 35
Tabel 4.3. Hasil Koordinat Model Inisialisasi Kontur	. 36
Tabel 4.4. Hasil DSC dan ME Skenario Uji Coba 2 (Model Shape Prior)	. 40
Tabel 4.5 Hasil DSC dan ME Skenario Uji Coba 2 (Model Rectangle)	. 42
Tabel 4.6 Contoh Gambar Hasil Segmentasi	. 42
Tabel 4.7 Contoh Posisi Inisialisasi Kontur	. 46

Halaman ini sengaja dikosongkan

BAB 1

PENDAHULUAN

Bab ini merupakan penjelasan mengenai beberapa hal dasar dalam pembuatan proposal penelitian. Hal-hal yang dimaksud meliputi latar belakang, perumusan masalah, tujuan penelitain, manfaat penelitian, kontribusi penelitian, serta batasan masalah.

1. 1. Latar Belakang

Neurodegeneratif merupakan sekumpulan penyakit yang merujuk pada kehilangan sel-sel neuron progresif tanpa penyebab (Al-Radaideh dkk, 2016). Penyakit-penyakit ini pada umumnya menyerang orang yang telah lanjut usia. Beberapa contoh dari penyakit neurodegeneratif adalah Alzheimer dan Parkinson. Parkinson terkenal sebagai penyakit neurodegeneratif paling umum setelah Alzheimer yang paling banyak menyerang wanita lanjut usia (Al-Radaideh and Rababah, 2016), dengan gejala umumnya berupa gemetar, kaku, dan keseimbangan diikuti oleh beberapa gangguan psikis. Namun, diagnosis Parkinson sulit dilakukan, yang harus mempertimbangkan riwayat kesehatan pasien dan pemeriksaan berlanjut (Cigdem dkk, 2018). Oleh karena itu, pengembangan diagnosis dengan menggunakan teknologi berbasis *neurodegenerative disorder imaging* dilakukan untuk melihat struktur otak dari pasien.

Magnetic Resonance Imaging (MRI) adalah teknologi neurodegenerative disorder imaging paling umum karena kualitas kontrasnya yang baik, resolusi tinggi, dan tidak memerlukan injeksi apapun ke dalam tubuh (Cigdem dkk, 2018). Selama lebih dari tiga dekade terakhir (Heim dkk, 2017), MRI telah digunakan untuk melakukan diagnosis Parkinson dan membedakan jenis dari Parkinson yang diderita oleh pasien. Salah satu teknik diagnosis Parkinson adalah dengan melihat struktur Globus Pallidus, yang terlibat stimulasi listrik pada daerah fungsional struktur otak bagian dalam penyakit Parkinson (González dkk, 2016). Globus Pallidus merupakan bagian dari subcortical brain atau basal ganglia nuclei (Iacono dkk, 2011) yang memiliki kontras rendah disekitarnya dan weak boundary didalam

otak, sehingga dibutuhkan teknologi untuk melakukan proses otomatisasi dalam segmentasi di MRI.

Teknologi segmentasi yang membagi citra/gambar menjadi beberapa *region* berkembang pesat pada masa kini. Proses segmentasi membantu pengelompokan citra medis untuk menentukan objek anatomi yang diinginkan (Bankman, 2009) sehingga nampak lebih jelas dengan dipisahkan dari *background*-nya. Segmentasi *Globus Pallidus* juga banyak dikembangkan. Metode yang telah dikembangkan dengan menggunakan atlas otak (*atlas-based segmentation*) (Iacono dkk, 2011; Liu dkk, 2019) dan berbasis *deep learning* (Dolz dkk, 2018), baik segmentasi *Globus Pallidus* saja maupun seluruh bagian *subcortical brain* (termasuk didalamnya *Globus Pallidus*). Kendala dari metode ini ialah pembuatan atlas secara manual yang harus dilakukan oleh pakar yang bisa memakan waktu yang cukup lama. Sementara itu, penggunaan *deep learning* memerlukan data *training* dalam jumlah besar yang sulit dicari. Disamping itu, komputasi *deep learning* sangat tinggi sehingga dibutuhkan komputer khusus untuk melakukan eksekusi program.

Teknik segmentasi lainnya adalah Active Contour. Active Contour menggunakan konsep energi untuk melakukan proses evolusi *contour* (kontur) terhadap *region of interest* (ROI)-nya yang diinisialisasikan (Hemalatha dkk, 2018). Secara konvensional, Active Contour dapat dikelompokkan menjadi dua, yakni *edge-based model* dan *region-based model* (Shan dkk, 2018). *Edge-based model* atau Snakes menggunakan *edge*/tepi pada citra dalam proses evolusi kontur sehingga sangat sensitif pada *noise*. Sementara *region-based model* atau Level Set memandu evolusi kontur berdasarkan bagian dalam dan luar *region* dengan suatu *region descriptor* yang sangat memperbaiki *edge-based model* dalam menangani obyek dengan batas (*boundary*) yang lemah.

Salah satu dari Active Contour dengan model Level Set yang populer ialah Chan-Vese Model (Chan dan Vese, 2001). Chan-Vese Model menggunakan evolusi kurva tanpa melibatkan *gradient*, sehingga model dapat melakukan segmentasi pada citra dengan batas garis yang lemah secara *smooth*. Chan-Vese mengembangkan fungsi energi yang terkait dengan segmentasi Mumford-Shah, dan fungsi Level Set digunakan untuk merepresentasikan kurva. Akan tetapi, model Chan-Vase menggunakan informasi global dan tidak dapat membagi *region* citra

yang mengandung *intensity inhomogeneity* (ketidakhomogenan intensitas). Apabila suatu obyek pada citra MRI yang memiliki karakteristik citra dengan ketidakhomogenan intensitas disegmentasi dengan model Chan-Vese, maka dapat terjadi *oversegmentation*, yang dapat menyebabkan *background* terdeteksi sebagai obyek yang disegmentasi.

Ketidakhomogenan intensitas merupakan masalah umum yang terjadi pada citra MRI. Hal ini disebabkan oleh ketidaksempurnaan pada proses akuisisi citra, yang menyebabkan terjadinya variasi intensitas pada jaringan/obyak yang sama (Uros dkk, 2007). Segmentasi pada citra demikian sangat sulit dilakukan oleh komputer yang memiliki asumsi intensitas yang seragam (*intensity homogeneity/uniform*) (Zhang *dkk*, 2016). Oleh karena itu, pada segmentasi citra MRI pada umumnya dilakukan *bias field correction* sebagai *preprocessing* sebelum tahap segmentasi.

Penyelesaian masalah dari ketidakhomogenan intensitas pada metode Chan-Vese diusulkan oleh (Li *dkk*, 2008). Model Active Contour ini dinamakan *Region-Scalable Fitting* (RSF). Melalui fungsi evolusinya yang mampu mengaproksimasi intensitas secara lokal dalam kontur, RSF mampu mengatasi ketidakhomogenan secara efektif. Akan tetapi, RSF sangat bergantung kepada posisi kontur awal yang diinisialisasikan dan tidak mampu mengatasi citra dengan *noise* seperti *low contrast* dan *weak boundary*. Metode Active Contour membutuhkan inisialisasi awal kontur untuk mendefinisikan *region* dari obyek. Inisialisasi kontur awal diberikan oleh *user* secara manual untuk memberikan informasi kepada komputer terkait posisi obyek yang akan disegmentasi. Apabila kontur awal yang diinisialisasikan melebihi obyek dari ROI, maka citra yang tersegmentasi bisa melampaui target ROI (*oversegmentation*), dan sebaliknya.

Oleh karena itu, (Rabeh dkk, 2017) mengembangkan Active Contour dengan inisialisasi awal kontur yang diperoleh melalui informasi priori dari *shape prior*, yang dilakukan berbasis *training phase* untuk melakukan segmentasi citra MRI dengan *intensity inhomogeneity*. Tahap *training phase* membutuhkan data training dengan kriteria kombinasi setiap bentuk (*shape*) dan lokasi obyek ROI yang mungkin sehingga menghasilkan inisialisasi kontur awal yang menyerupai hasil segmentasi akhir. Selanjutnya, kontur awal dievolusi dengan menggunakan fungsi

evolusi agar dapat mendeteksi obyek ROI dari data uji yang akan disegmentasi. Fungsi evolusi kontur yang digunakan adalah fungsi evolusi Level Set standar. Namun, fungsi evolusi Level Set standar tidak dapat menangani obyek dengan weak boundary, sehingga dapat menimbulkan kesalahan dalam mengevolusi inisialisasi segmentasi awal.

Selanjutnya, (Wang dkk, 2009) mengusulkan model Active Contour berbasis Local Gaussian yang menggunakan local relationship yang dikembangkan dengan distribusi Gaussian lokal, yang disebut dengan Local Gaussian Distribution Fitting (LGDF). Fungsi evolusi kontur pada LGDF menggunakan variational level set standar dengan komponen energy term untuk menggerakkan evolusi kontur berdasarkan MRF, length term untuk proses smoothing dalam akurasi segmentasi, dan regularization term untuk menjamin stabilitas evolusi kontur. Namun, energy term pada LGDF tidak dapat mengatasi citra dengan kontras yang rendah disekitar obyek dan weak boundary atau garis tepi antara obyek dengan background yang lemah sehingga sulit untuk diterapkan pada Globus Pallidus. Maka dibutuhkan variational level set dengan energy term pada LGDF yang dapat mendeteksi boundary secara akurat.

Dalam penelitian ini diusulkan Active Contour berbasis *Local Gaussian* dengan *New Variational Level Set* untuk segmentasi citra MRI pada obyek *Globus Pallidus*. Fungsi evolusi kontur *New Variational Level Set* (Dong dkk, 2019) dikembangkan pada Active Contour berbasis *Local Gaussian* untuk mencegah terjadinya *false boundary* pada evolusi kontur untuk meningkatkan akurasi segmentasi. Penelitian ini dilakukan menggunakan 2 (dua) skenario uji coba, yaitu: 1) Inisialisasi kontur secara manual, dan 2) Inisialisasi kontur secara otomatis. Metode usulan akan dibandingkan secara kualitatif dan kuantitatif dengan metode segmentasi Active Contour lainnya, yaitu Chan-Vese (CV), Region Scalable Fitting (RSF), dan *Local Gaussian* Distribution Fitting (LGDF). Pengukuran yang akan digunakan dalam penilaian secara kuantitatif adalah Dice Similarity Coefficient (DSC) untuk mengukur akurasi dan Misclassification Error (ME) untuk mengukur error pada hasil segmentasi.

1. 2. Perumusan Masalah

Rumusan masalah pada penelitian ini adalah sebagai berikut:

- 1. Bagaimana mengembangkan Active Contour berbasis *Local Gaussian* dengan *New Variational Level Set*?
- 2. Bagaimana melakukan segmentasi *Globus Pallidus* menggunakan modifikasi fungsi evolusi *New Variational Level Set* dengan *Local Gaussian*?
- 3. Bagaimana cara melakukan evaluasi terhadap hasil segmentasi citra *Globus Pallidus*?

1. 3. Tujuan Penelitian

Tujuan dari penelitian ini adalah mengembangkan Active Contour berbasis Local Gaussian dengan New Variational Level Set untuk segmentasi Globus Pallidus.

1. 4. Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut:

- 1. Mendapatkan metode segmentasi citra MRI yang lebih akurat
- 2. Hasil segmentasi dapat digunakan lebih lanjut untuk deteksi awal penyakit Parkinson.

1. 5. Kontribusi Penelitian

Kontribusi dari penelitian ini adalah mengusulkan metode Active Contour berbasis *Local Gaussian* dengan *New Variational Level Set* untuk perbaikan deteksi *boundary* pada evolusi kurva segmentasi *Globus Pallidus* pada data MRI.

1. 6. Batasan Masalah

Penelitian ini memiliki batasan, yaitu:

- 1. Segmentasi Globus Pallidus dilakukan berbasis 2D.
- 2. *Slicing* dari citra MRI untuk melakukan segmentasi *Globus Pallidus* dilakukan secara axial.
- 3. Pemilihan *slice* untuk citra MRI dilakukan secara manual dengan cara memilih citra yang mengandung *Globus Pallidus*.

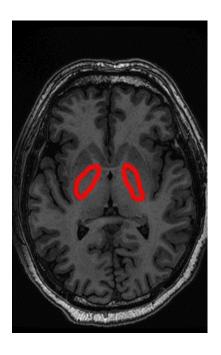
BAB 2

KAJIAN PUSTAKA DAN DASAR TEORI

Pada Bab ini akan dijelaskan terkait referensi mengenai penelitian. Hal-hal yang dijelaskan yakni tentang *Globus Pallidus*, *Statistical Deformable Model*, Active Contour, metode *New Variational Level Set*, segmentasi citra dengan Active Contour berbasis *Local Gaussian*, dan evaluasi hasil.

2. 1. Globus Pallidus

Globus Pallidus merupakan bagian dari subcortical brain atau basal ganglia nuclei (Iacono dkk, 2011). Globus Pallidus terlibat stimulasi listrik pada daerah fungsional struktur otak bagian dalam penyakit Parkinson (González-Villà dkk, 2016), sehingga citra Globus Pallidus dapat disegmentasi untuk membantu diagnosa otomatis Parkinson dengan bantuan komputer. Contoh gambar dari Globus Pallidus dapat dilihat pada Gambar 2.1. Boundary berwarna merah pada Gambar 2.1 menunjukkan obyek Globus Pallidus.



Gambar 2.1. Citra MRI dengan Globus Pallidus

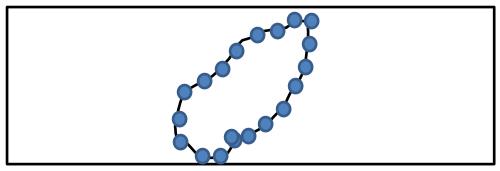
2. 2. Statistical Deformable Model

Statistical Deformable Model merupakan model berbasis statistik yang digunakan untuk mengekstraksi citra yang deformable. Salah satu metode berbasis statistical deformable model adalah Active Shape Model (ASM), yang digukana untuk mengekstraksi obyek yang kompleks dan non-rigid (Ben Rabeh dkk, 2017). Keuntungan menggunakan ASM ini adalah evolusi kurva yang didasarkan pada informasi priori yang kuat perihal geometri dan struktur model deformable yang telah di-training sebelumnya.

Ide dasar dari ASM adalah bentuk model statistik (*statistical shape of model*) dibangun oleh *training phase* berdasarkan peletakan titik pada obyek yang akan disegmentasi pada data training (Bi *dkk*, 2019). Selanjutnya, model yang telah dibangun pada sesi *training phase* digunakan pada sesi *testing phase* pada citra yang belum disegmentasi dengan mengevolusi model kurvanya, seperti yang dilakukan oleh (Ben Rabeh dkk, 2017). Tahap *training phase* digunakan untuk mengekstrak rata-rata dari bentuk di setiap citra yang *deformable* untuk melakukan proses otomatisasi terhadap inisialisasi kontur pada Active Contour, dengan mempelajari setiap geometri dan variasi dari struktur yang diinginkan. Banyaknya data *training* yang berupa segmentasi manual harus mewakili seluruh kemungkinan model obyek yang ingin dilatih.

2.2.1 Labelling Data Training

Himpunan titik model diperlukan untuk dapat mengenali bentuk (shape) dari suatu model. Proses labeling pada himpunan titik model sangat penting, karena titik yang telah dilabeli merepresentasikan bagian tertentu dari obyek atau boundary (Cootes dkk, 2013). Oleh karena itu penting sekali bahwa setiap labelling titik pada obyek diletakkan secara tepat untuk setiap data training. Proses labelling memang harus dilakukan secara manual, namun nantinya pencarian mean shape dan variasi dari bentuk dilakukan secara otomatis. Misalkan terdapat m data training yang telah di-labeling secara manual. Untuk setiap data training i, terdapat himpunan titik x_i , i = 1, 2, ..., m yang diperoleh dari ekstraksi boundary object dari citra segmentasi manual. Proses ini digambarkan pada Gambar 2.2.



Gambar 2.2. Contoh model *labelling* data training. Lingkaran biru mewakili titik dari *shape* dari obyek.

2.2.2 Proses Alignment Data Training

Himpunan titik dari semua data training yang telah dilakukan proses *labelling* akan dilakukan proses *aligment* dengan menggunakan Procrustes Analysis. Proses *alignment* antar data training dilakukan agar antara satu data training dengan data training lainnya saling berkorespondensi dengan proses translasi, rotasi, dan penskalaan (Cootes dkk, 2013). Setelah semua data training ter-*alignment*, maka dihitung rata-ratanya (*mean shape*). Himpunan titik yang telah di-*alignment* oleh Procrustes Analysis disimbolkan oleh x_i' , i = 1, 2, ..., m (Bi dkk, 2019).

Misalkan terdapat himpunan titik shape $x_i = \{x_1, x_2, ..., x_m\}$, dengan m banyaknya data training, dan $x_1 = ((a_{11}, b_{11}), ..., (a_{k1}, b_{k1})), x_2 = ((a_{12}, b_{12}), ..., (a_{k2}, b_{k2})), ..., x_m = ((a_{1m}, b_{1m}), ..., (a_{km}, b_{km}))$, maka proses translating didefinisikan seperti pada Persamaan 2.1.

$$(a_{km}, b_{km}) \rightarrow (a_{km} - \overline{a_{km}}, b_{km} - \overline{b_{km}}),$$
 (2.1)

dimana:

k = banyaknya titik dalam sebuah shape

 $\overline{a_{km}}$ = rata-rata (mean) dari a_{km}

 $\overline{b_{km}}$ = rata-rata (mean) dari b_{km} .

Proses penskalaan didefinisikan seperti pada Persamaan 2.2 hingga 2.4 pada titik (a_{km}, b_{km}) .

$$(a_{km}, b_{km}) \to \left(\frac{a_{km} - \overline{a_{km}}}{s}, \frac{b_{km} - \overline{b_{km}}}{s}\right). \tag{2.2}$$

$$S = \sqrt{\frac{(a_{1m} - \overline{a_{1m}})^2 + (a_{2m} - \overline{a_{2m}})^2 + \dots + (a_{km} - \overline{a_{km}})^2}{k}}.$$
(2.3)

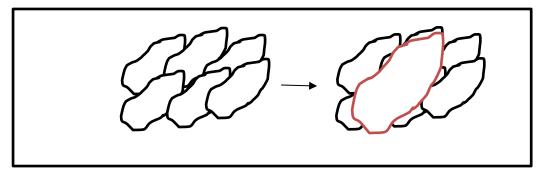
$$S = \sqrt{\frac{(b_{1m} - \overline{b_{1m}})^2 + (b_{2m} - \overline{b_{2m}})^2 + \dots + (b_{km} - \overline{b_{km}})^2}{k}}.$$
(2.4)

Proses rotasi dilakukan antara 2 (dua) himpunan titik shape yang berbeda. Misalkan terdapat 2 (dua) himpunan titik shape $x_1 = ((a_{11}, b_{11}), ..., (a_{k1}, b_{k1})), x_2 = ((a_{12}, b_{12}), ..., (a_{k2}, b_{k2}))$. Rotasi x_1 dan x_2 dengan sudut θ diberikan pada Persamaan 2.5 hingga 2.7. Contoh proses *alignment* digambarkan pada Gambar 2.3. Gambar kiri menunjukkan kumpulan data training yang belum di-*alignment*. Gambar kanan menunjukkan data training yang telah di-*alignment* dengan rata-rata dari model yang telah ter-*alignment* (*mean shape*) yang ditunjukkan oleh gambar bergaris merah.

$$(a_{k1}, b_{k1}) \to (a_{k1}\cos\theta - b_{k1}\sin\theta, a_{k1}\sin\theta + b_{k1}\cos\theta).$$
 (2.5)

$$(a_{k2}, b_{k2}) \to (a_{k1}\cos\theta - b_{k1}\sin\theta, a_{k1}\sin\theta + b_{k1}\cos\theta).$$
 (2.6)

$$\theta = \arctan\left(\frac{\sum_{i=1}^{k} (a_{i2}b_{i1} - b_{i2}a_{i1})}{\sum_{i=1}^{k} (a_{i2}a_{i1} + b_{i2}b_{i1})}\right). \tag{2.7}$$



Gambar 2.3. Contoh proses alignment.

2. 3. Active Contour

Istilah "Active Contour" mengandung kata *contour* (kontur) yang merupakan relasi dasar antar pixel pada suatu citra. Kontur, yang disebut juga sebagai *boundary* atau *border* dari sebuah region *R* merupakan himpunan pixel dari region *R* yang *adjecent* pada pixel dalam komplemen dari *R*. Ide dasar dari model Active Contour adalah proses evolusi kurva yang *active* dengan tujuan untuk mendeteksi objek dari suatu citra (Chan dan Vese, 2001). Dimulai dari sebuah kurva yang terletak diantara objek, kemudian kurva akan berevolusi pada *boundary* obyek yang disegmentasi

Model Active Contour paling awal adalah model Snakes (Kass dkk, 1988). Misalkan Ω merupakan himpunan terbatas \mathbb{R}^2 , $u_0 \colon \overline{\Omega} \to \mathbb{R}$ merupakan citra yang diberikan, dan $C(s) \colon [0,1] \to \mathbb{R}^2$ merupakan *parameterized curve*. Model Snakes mendeteksi *edge* secara aktif yang bergantung pada gradien citra u_0 untuk menghentikan proses evolusi kurva pada obyek yang diinginkan. Model Snakes $\inf_C J_1(C)$ dengan parameter α, β dan λ dapat dilihat pada Persamaan 2.8:

$$\inf_{C} J_{1}(C) = \inf_{C} \left\{ \alpha \int_{0}^{1} |C'(S)|^{2} ds + \beta \int_{0}^{1} |C''(S)| ds - \lambda \int_{0}^{1} |\nabla u_{0}(C(S))|^{2} ds \right\}.$$
(2.8)

Dua suku pertama didalam himpunan infimum merupakan energi internal yang mengontrol *smoothness* dari kontur, sementara suku ketiga merupakan energi eksternal yang menarik kontur terhadap obyek pada citra. Model Snakes meminimalkan fungsi energi dan membuat kontur "merayap seperti ular" dalam proses mencari *boundary*. Akan tetapi, model Snakes memiliki kelemahan, yaitu

tidak dapat beradaptasi pada perubahan topologi pada kontur. Hal inilah yang diperbaiki pada Active Contour model Level Set.

Model Level Set dapat diumpamakan seperti propagasi antara *interfaces* dengan *fluids*. Pada pengolahan citra digital, *fluids* melambangkan region dari citra, dan *interfaces* menjadi segmentasi kontur yang memisahkan satu region dengan region lainnya. Kurva C pada model Level Set dilambangkan secara implisit via fungsi Lipschitz ϕ dengan $C = \{(x,y)|\phi(x,y)=0\}$ dan fungsi evolusi kurva diberikan pada waktu t dinotasikan $\phi(t,x,y)$. Evolusi kurva C pada direksi normal dengan kecepatan F melalui persamaan diferensial seperti pada Persamaan 2.9.

$$\begin{cases} \frac{\partial \phi}{\partial t} = |\nabla \phi| F, & t > 0, x \in \mathbb{R}^2 \\ \phi(0, x, y) = \phi_0(x, y), & x \in \mathbb{R}^2 \end{cases} , \tag{2.9}$$

dimana $\phi(0, x, y)$ melambangkan inisialisasi kontur, dan $F = div(\nabla \phi/|\nabla \phi|)$. Pengembangan Active Contour model Level Set yang populer adalah model *Chan-Vese* dan *Region Scalable Fitting* yang akan dijelaskan pada sub-bab 2.3.1 dan 2.3.2.

2.3.1 Model Active Contour Chan-Vese

Permasalahan model Active Contour sebelumnya yang bergantung pada gradien citra untuk menghentikan proses evolusi kurva mengakibatkan model hanya dapat mendeteksi obyek dengan garis (edge) yang terdefinisi oleh gradien, sehingga kurva mungkin dapat lewat dari boundary, seperti pada citra noisy (Chan and Vese, 2001). Oleh karena itu, model Chan-Vese (CV) tidak berdasarkan gradien dalam menghentikan proses evolusi kurva, melainkan dengan teknik segmentasi Mumford-Shah. Model CV dapat mendeteksi kontur baik dengan maupun tanpa gradien seperti pada obyek dengan boundary yang sangat smooth maupun boundary yang tidak kontinu.

Model CV meminimalisasi energi dalam proses melakukan segmentasi. Misalkan kurva C di Ω sebagai boundary dari sebuah region $\omega \subset \Omega$, inside(C) melambangkan region ω , dan outside(C) melambangkan region $\Omega \setminus \omega$. Diasumsikan citra u_0 dibentuk dari 2 (dua) region yakni u_0^i dan u_0^o . Selanjutnya,

diasumsikan obyek segmentasi direpresentasikan oleh region u_0^i dan *boundary*-nya dinotasikan C_0 , sehingga dapat disimpulkan bahwa u_0^i merupakan $inside(C_0)$ dan u_0^o merupakan $outside(C_0)$. Didefinisikan *fitting term* seperti pada Persamaan 2.10:

$$F_{1}(C) + F_{2}(C) = \int_{inside(C)} |u_{0}(x, y) - c_{1}|^{2} dx dy$$

$$+ \int_{outside(C)} |u_{0}(x, y) - c_{2}|^{2} dx dy,$$
(2.10)

dimana c_1, c_2 adalah rata-rata dari u_0 berturut-turut didalam dan diluar C. Jelas bahwa boundary obyek C_0 adalah minimizer dari fitting term, yaitu $\inf_C \{F_1(C) + F_2(C)\} \approx 0 \approx F_1(C_0) + F_2(C_0)$. Apabila kurva C didalam obyek, maka $F_1(C) > 0$ dan $F_2(C) \approx 0$. Apabila kurva C diluar obyek, maka $F_1(C) \approx 0$ dan $F_2(C) > 0$. Akhirnya, fitting energy minimal jika $C = C_0$, seperti jika kurva C berada pada boundary obyek. Model CV akan meminimalkan fitting term diatas dan menambahkan regularizing term, yaitu panjang kurva C, yang dinotasikan dengan Length(C), dan luas region didalam C, yang dinotasikan dengan Area(inside(C)), serta $\mu \geq 0$, $v \geq 0$, $\lambda_1, \lambda_2 > 0$ yang merupakan fixed parameter sehingga dapat didefinisikan energi fungsional $F(c_1, c_2, C)$ seperti pada Persamaan 2.11.

$$F(c_1, c_2, C) = \mu \cdot Length(C) + v \cdot Area(inside(C),$$

$$+ \lambda_1 \int_{inside(C)} |u_0(x, y) - c_1|^2 dx dy$$

$$+ \lambda_2 \int_{cutside(C)} |u_0(x, y) - c_2|^2 dx dy.$$

$$(2.11)$$

Energi fungsional segmentasi Mumford-Shah didefinisikan seperti pada Persamaan 2.12.

$$F^{MS}(u,C) = \mu \cdot Length(C) \tag{2.12}$$

$$+ \lambda \int_{\Omega} |u_0(x,y) - u(x,y)|^2 dx dy$$
$$+ \int_{\Omega \setminus C} |\nabla u(x,y)|^2 dx dy.$$

Pengembangan dari energi fungsional Mumford-Shah oleh CV menghasilkan perumusan energi $F(c_1, c_2, \phi)$ seperti pada Persamaan 2.13.

$$\begin{split} F(c_{1},c_{2},\varphi) &= \mu \; . \; Length(\phi=0) + v \; . \; Area(\phi \geq 0) \\ &+ v \; \int_{\Omega} \; \delta \big(\phi(x,y) \big) |\nabla \phi(x,y)| \, dx dy \\ &+ \lambda_{1} \int_{\Omega} \; |u_{0}(x,y) - c_{1}|^{2} H(\phi(x,y)) \, dx dy \\ &+ \lambda_{2} \int_{\Omega} \; |u_{0}(x,y) - c_{2}|^{2} (1 - H(\phi(x,y))) \, dx dy. \end{split} \tag{2.13}$$

Dimana $Length(\phi=0)$, $Area(\phi\geq0)$, fungsi Heaviside H_{ϵ} , dan Dirac $measure \delta_{\epsilon}$ didefinisikan seperti pada Persamaan 2.14 hingga 2.17.

$$Length(\phi = 0) = \int_{\Omega} |\nabla H(\phi(x, y))| dxdy$$

$$= \int_{\Omega} \delta |\nabla \phi(x, y)| dxdy.$$
(2.14)

$$Area(\phi \ge 0) = \int_{\Omega} |\nabla H(\phi(x, y))| dxdy. \tag{2.15}$$

$$H_{\epsilon}(x) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan\left(\frac{x}{\epsilon}\right) \right]. \tag{2.16}$$

$$\delta_{\epsilon}(x) = H'_{\epsilon}(x) = \frac{1}{\pi} \left[\frac{\epsilon}{\epsilon^2 + x^2} \right]. \tag{2.17}$$

Melalui fungsi energi diatas, konstanta c_1 dan c_2 dapat dituliskan seperti pada Persamaan 2.18 dan 2.19.

$$c_1(\phi) = \frac{\int_{\Omega} u_0(x,y)H(\phi(x,y))dxdy}{\int_{\Omega} H(\phi(x,y))dxdy}.$$
 (2.18)

$$c_2(\phi) = \frac{\int_{\Omega} u_0(x, y)(1 - H(\phi(x, y))) dx dy}{\int_{\Omega} (1 - H(\phi(x, y))) dx dy}.$$
(2.19)

Fungsi energi diminimalkan untuk memperoleh perubahan fungsi level set ϕ dengan persamaan diferensial seperti pada Persamaan 2.20.

$$\frac{\partial \phi}{\partial t} = \delta_{\epsilon}(\phi) \left[\mu \operatorname{div}\left(\frac{\nabla \phi}{|\nabla \phi|}\right) - \nu - \lambda_1 (u_0 - c_1)^2 + \lambda_2 (u_0 - c_2) \right]. \tag{2.20}$$

Perhitungan Persamaan 2.24 dilakukan secara pendekatan analisis numerik dengan menggunakan *finite differences implicit*.

2.3.2 Model Active Contour Region Scalable Fitting (RSF)

Pada model CV, citra diasumsikan memiliki *intensity homogeneity*, yang artinya obyek yang sama pasti memiliki intensitas yang homogen (Li dkk, 2008). Hal tersebut tentu tidak cocok untuk melakukan proses segmentasi citra dengan karakteristik *intesity inhomogeneity* atau citra dengan intensitas yang tidak homogen. Dalam hal ini ketika model *intensity homogeneity* digunakan untuk melakukan segmentasi pada citra berkarakteristik *intensity inhomogeneity*, maka yang terjadi adalah obyek diluar inisialisasi kontur dapat terdeteksi sebagai *region of interest*.

Kasus ketidakhomogenan intensitas sering terjadi pada citra medis, yang pada umumnya dikarenakan keterbatasan teknis atau *artifact/noise* pada obyek yang difoto. Pada citra *Magnetic Resonance Imaging* (MRI), ketidakhomogenan intensitas dihasilkan oleh frekuensi radio serta kerentanan variasi dari obyek. Oleh

karena itu, pada proses segmentasi MRI umumnya memerlukan proses *enhancement* pada ketidakhomogenan intensitas sebagai tahap preproses.

Model Region Scalable Fitting (RSF) diusulkan oleh (Li dkk, 2008) untuk mengatasi citra dengan ketidakhomogenan intensitas melalui Active Contour berbasis region. RSF didefinisikan dalam arti sebuah kontur dan dua fungsi fitting yang mengaproksimasi intensitas citra secara lokal dari dua sisi kontur. Fungsi fitting optimal berupa rata-rata dari intensitas lokal dari dua sisi kontur. Region-scalability dari RSF didasarkan pada fungsi kernel dengan parameter yang mengizinkan penggunaan informasi intensitas dalam region pada skala yang terkontrol, dari neighborhood kecil hingga keseluruhan domain.

Misalkan $\Omega_1 = outside(C)$ dan $\Omega_2 = inside(C)$. Fungsi energi *local* intesity fitting ε_x^{Fit} didefinisikan dengan fungsi Heaviside seperti pada Persamaan 2.21.

$$\varepsilon_x^{Fit}(\phi, f_1(x), f_2(x))$$

$$= \sum_{i=1}^2 \lambda_i \int K_{\sigma}(x - y) |I(y) - f_i(x)|^2 M_i(\phi(y)) dy,$$
(2.21)

dimana $M_1 = H(\phi)$, $M_2 = 1 - H(\phi)$, λ_1 , λ_2 adalah konstanta positif, $f_1(x)$, $f_2(x)$ adalah dua nilai *fitting* yang mengaproksimasi intensitas citra Ω_i , i = 1,2, I(y) adalah intensitas di region lokal yang ada ditengah koordinat x, dan K_{σ} adalah kernel yang berperan penting pada model RSF, yang diasumsikan mendekati distribusi Gaussian dengan definisi seperti pada Persamaan 2.22.

$$K_{\sigma}(u) = \frac{1}{(2\pi)^{\frac{n}{2}}\sigma_n} \exp\left(-\frac{|u|^2}{2\sigma^2}\right). \tag{2.22}$$

Fungsi energi *local intesity fitting* ε_x^{Fit} merupakan *weighted mean square* error dari aproksimasi intensitas citra I(y) diluar dan didalam kontur C oleh nilai fitting $f_1(x)$, $f_2(x)$, dengan K_σ sebagai *weight* yang menentukan intensitas I(y) di y. Kemudian, kontribusi intensitas I(y) pada fungsi energi ε_x^{Fit} adalah mengurangi dan mendekati nol ketika titik y menjauh dari titik tengah x. Jadi, energi ε_x^{Fit} dipengaruhi oleh intensitas I(y) dari titik y dalam *neighborhood* x.

Untuk mempertahankan regularisasi fungsi level set ϕ yang dibutuhkan

untuk keakuratan komputasi dan kestabilan evolusi kurva level-set, maka RSF menggunakan *levet set regularization term* dalam formulasi level-setnya. *Level set regularization* tersebut didefinisikan seperti pada Persamaan 2.23.

$$P(\phi) = \int \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx$$
 (2.23)

Selanjutnya, RSF meminimalkan fungsi energi evolusi kontur $F(\phi, f_1, f_2)$ yang didefinisikan seperti pada Persamaan 2.24.

$$F(\phi, f_1, f_2) = \varepsilon_x^{Fit}(\phi, f_1(x), f_2(x)) + \mu P(\phi), \tag{2.24}$$

dimana μ adalah konstanta positif. Untuk meminimalkan fungsi energi tersebut, digunakan *gradient flow* sebagai persamaan evolusi kurva. Melalui teknik kalkulus variasi, diperoleh Persamaan 2.25.

$$f_i = \frac{K_{\sigma(x)} * [M_i(\phi(x)I(x)]}{K_{\sigma(x)} * M_i(\phi(x))}, i = 1, 2.$$
(2.25)

Parameter f_1 dan f_2 bersifat tetap, lalu fungsi energi F diminimalkan dengan menggunakan persamaan *gradient flow* seperti pada Persamaan 2.26.

$$\begin{split} \frac{\partial \phi}{\partial t} &= \delta_{\epsilon}(\phi) \left(\lambda_{1} e_{1} - \lambda_{2} e_{2} \right) + v \delta_{\epsilon}(\phi) \, div \left(\frac{\nabla \phi}{|\nabla \phi|} \right), \\ &+ \mu \left(\nabla^{2} \phi - div \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right). \end{split} \tag{2.26}$$

dengan e_1 dan e_2 merupakan fungsi seperti pada Persamaan 2.27.

$$e_i = \int K_{\sigma}(y - x)|I(x) - f_i(y)|^2 dy, i = 1, 2.$$
(2.27)

Suku pertama pada Persamaan 2.30 merupakan *data fitting energy* atau *data fitting term*, yang memainkan peran penting untuk melakukan evolusi kontur kepada kontur obyek. Suku kedua dinamakan *arc length term*, yang melakukan efek *smoothing* pada zero level contour sehingga mempertahankan regularisasi kontur. Suku ketiga merupakan *level set regularization* seperti yang telah dijelaskan sebelumnya, yakni menjaga regularisasi fungsi level set.

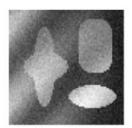
2. 4. New Variational Level Set

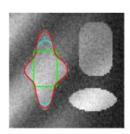
Fungsi New Variational Level Set diusulkan oleh (Dong dkk, 2019) untuk memperbaiki metode yang mensegmentasi citra yang mengandung intensity inhomogeneity. New Variational Level Set membatasi range segmentasi sehingga tidak melebihi batas dari inisialisasi segmentasi awal dan memperbaiki kecepatan dari segi komputasi serta mengurangi sensitivitas terhadap inisialisasi kontur awal pada Active Contour. Salah satu metode Active Contour yang berhasil diperbaiki adalah metode RSF seperti yang telah dijelaskan pada sub-bab 2.3.2. Fungsi RSF yang telah diperbaiki itu dijelaskan melalui Persamaan 2.28.

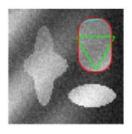
$$\frac{\partial \phi}{\partial t} = -\alpha \delta_{\epsilon}(\phi) \arctan\left(\frac{\lambda_1 e_1 - \lambda_2 e_2}{\tau}\right),\tag{2.28}$$

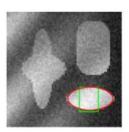
dimana α dan τ merupakan konstata yang berturut-turut mengatur kecepatan segmentasi dan membatasi range segmentasi serta memperbaiki kemiringan kurvanya. Fungsi arctan digunakan untuk mengontrol dan memperhalus besarnya $data\ driver$.

Hasil percobaan yang dilakukan oleh (Dong dkk, 2019) menunjukkan bahwa New Variational Level Set memperbaiki hasil segmentasi citra RSF yang sangat bergantung pada inisialisasi kontur. Perbaikan tersebut ditunjukkan secara efektif melalui hasil segmentasi yang tidak false boundary (salah segmentasi obyek) dan membuat kontur menjadi lebih halus dengan proses komputasi yang cepat. Hasil segmentasi ditunjukkan oleh Gambar 2.4.









Gambar 2.4. Hasil segmentasi citra dari *New Variational Level Set* (Dong dkk, 2019)

2. 5. Segmentasi Citra dengan Local Gaussian

Segmentasi citra dengan Active Contour berbasis *Local Gaussian* dikembangkan dari Teori Bayes mengenai distribusi intesitas lokal melalui pembagian citra ke dalam beberapa partisi dari *neighborhood*-nya, yang disebut sebagai *Local Gaussian Distribution Fitting* (LGDF) (Wang *dkk*, 2009). Misalkan Ω merupakan domain citra untuk setiap titik x. Didefinisikan sebuah *circular neighborhood* $O_x \triangleq \{y \mid |x-y| \leq r\}$ dengan radius r. Kemudian, $\{\Omega_i\}_{i=1}^n$ merupakan himpunan sejumlah region citra n sedemikian sehingga $\Omega = \bigcup_{i=1}^n \Omega_i$ dan $\Omega_i \cap \Omega_j \neq \emptyset$, $\forall i \neq j$. Region $\{\Omega_i\}_{i=1}^n$ membagi citra Ω berdasarkan neighborhood O_x sedemikian sehingga $\{\Omega_i\}_{i=1}^n = \{\Omega_i \cap O_x\}_{i=1}^n$. Segmentasi dari *circular neighborhood* O_x disebut sebagai Max *A Posteriori Probability* (MAP).

Misalkan $P(y \in \Omega_i \cap O_x | I(y))$ merupakan *A Posteriori Probability* dari subregion $\Omega_i \cap O_x$ dengan intensitas *neighborhood* I(y). Berdasarkan Teorema Bayes, $P(y \in \Omega_i \cap O_x | I(y))$, atau dapat dinotasikan sebagai $P_{i,x}(I(y))$ merupakan *probability density* di region $\Omega_i \cap O_x$ dengan $P(y \in \Omega_i \cap O_x)$ merupakan *A Priori Probability* dari region $\Omega_i \cap O_x$ untuk semua kemungkinan pembagian *neighborhood* O_x dan P(I(y)) merupakan *A Priori Probability* dari intensitas I(y). Teorema Bayes mengenai segmentasi citra diberikan pada Persamaan 2.29.

$$P(y \in \Omega_i \cap O_x | I(y)) = \frac{P(y \in \Omega_i \cap O_x | I(y) | P(y \in \Omega_i \cap O_x))}{P(I(y))}.$$
(2.29)

Karena *A Priori Probability* dari intensitas pixel P(I(y)) independen dari pemilihan region dan diberikan semua partisi memiliki kemungkinan yang sama sehingga $P(y \in \Omega_i \cap O_x) = \frac{1}{n}$, maka dalam kasus ini perhitungan *A Priori Probability* bisa diabaikan. LGDF mengasumsikan pixel untuk setiap region bersifat independen sedemikian sehingga MAP dapat diperoleh melalui memaksimalkan $P_{i,x}(I(y))$ terhadap region O_x . Lalu, hasilnya dikonversi pada meminimalkan untuk memperoleh energi En_x^{LGDF} melalui operasi logaritma. Energi En_x^{LGDF} didefinisikan pada Persamaan 2.30.

$$En_x^{LGDF} = \sum_{i=1}^n \int -\log |P_{i,x}(I(y))| \, dy. \tag{2.30}$$

Untuk menaksir nilai *A Posteriori Probability* $P_{i,x}(I(y))$, LGDF menggunakan *Gaussian probability density* and mengasumsikan *mean* dan *variance* dari distribusi Gaussian tersebut sebagai *spatially varying parameters*. Sehingga, *A Posteriori Probability* $P_{i,x}(I(y))$ pada distribusi Gaussian dengan *local average* u_i dan *standard deviation* σ_i dapat ditulis pada Persamaan 2.31.

$$P_{i,x}(I(y)) = \frac{1}{\sqrt{2\pi}\sigma_i} exp\left(\frac{(u_i - I(y))^2}{2\sigma_i^2}\right). \tag{2.31}$$

Lalu, LGDF menggunakan fungsi pembobotan non-negatif w untuk segmentasi citra secara cepat sedemikian sehingga obyek dapat tersegmentasi dengan tepat. Energi En_x^{LGDF} dapat ditulis sepert pada Persamaan 2.32.

$$En_x^{LGDF} = \sum_{i=1}^n \int -w \log |P_{i,x}(I(y))| dy,$$
 (2.32)

Pada kasus segmentasi citra, domain citra Ω dapat dibagi dalam dua region: region foreground (obyek) Ω_F dan region background Ω_B . Region tersebut dapat direpresentasikan dalam bentuk fungsi level set ϕ sedemikian sehingga $\Omega_F = \{\phi < 0\}$ dan $\Omega_B = \{\phi > 0\}$. Seperti halnya CV dan RSF, LGDF menggunakan $Length(\phi)$, $Area(\phi)$, fungsi Heaviside H_ϵ , dan Dirac measure δ_ϵ pada fungsi zero level setnya.

Parameter u_i dan σ_i^2 pada A Posteriori Probability $P_{i,x}(I(y))$ diminimalkan dengan menggunakan kalkulus variasi sehingga memenuhi Persamaan Euler Lagrange. Kemudian, LGDF memperoleh u_i and σ_i^2 seperti diberikan pada Persamaan 2.33 dan 2.34.

$$u_i = \frac{\int w I(y) M(\phi(y)) dy}{\int w M(\phi(y)) dy}.$$
 (2.33)

$$\sigma_i^2 = \frac{\int w \left(u_i - I(y)\right)^2 M(\phi(y)) dy}{\int w M(\phi(y)) dy}.$$
 (2.34)

Energi harus diminimalisasi melalui solusi dari gradient descent flow seperti halnya RSF dan CV. Gradient descent flow meliputi suku energi sebagai suku pertama, length term sebagai suku kedua, dan regularization term seperti terlihat

pada Persamaan 2.35. Konstanta e_1 and e_2 untuk menjalankan segmentasi LGDF diberikan pada Persamaan 2.36 dan 2.37.

$$\begin{split} \frac{\partial \phi}{\partial t} &= -\delta_{\epsilon}(\phi) \; (e_{1} - e_{2}) + \; v \delta_{\epsilon}(\phi) \; div \left(\frac{\nabla \phi}{|\nabla \phi|} \right), \\ &+ \mu \; \left(\nabla^{2} \phi - div \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right). \end{split} \tag{2.35}$$

$$e_1 = \int w \left[\log(\sigma_1) + \frac{(u_i - I(y))^2}{2\sigma_1^2} \right] dy.$$
 (2.36)

$$e_2 = \int w \left[\log(\sigma_2) + \frac{(u_i - I(y))^2}{2\sigma_2^2} \right] dy.$$
 (2.37)

2. 6. Metode Evaluasi Segmentasi Citra

Segmentasi citra berbasis komputer berkembang pesat agar membantu pekerjaan manusia yang memakan waktu lama untuk melakukan segmentasi secara manual. Kualitas segmentasi tetap menjadi prioritas utama selain kecepatan prosesnya. Oleh karena itu diperlukan metode evaluasi segmentasi citra untuk menilai segmentasi yang dilakukan oleh komputer yang dibandingkan dengan segmentasi manual atau *ground truth*-nya. Salah satu metode pengukuran akurasi segmentasi citra adalah *Dice Similarity Coefficient* (DSC), yang didefinisikan pada Persamaan 2.38.

$$DSC = \frac{2(S_G \cap S_C)}{S_G + S_C}.\tag{2.38}$$

Dimana S_G adalah hasil segmentasi manual atau *ground truth* dan S_C adalah hasil segmentasi yang dilakukan oleh komputer atau metode yang diimplementasikan. Semakin nilai DSC pada Persamaan 2.43 mendekati 1 (satu), maka akurasi segmentasi semakin tinggi atau hasil segmentasi komputer semakin mendekati/mirip dengan hasil segmentasi manualnya.

Kemudian, metode pengukuran segmentasi lainnya adalah *Misclassification Error* (ME). Jika DSC menilai hasil segmentasi dari akurasinya, maka ME digunakan untuk mengukur seberapa besar *error* segmentasi citra dari *ground truth*nya. Sehingga, semakin nilai ME mendekati nol, maka hasil segmentasi citra semakin baik karena menghasilkan *error* yang kecil.

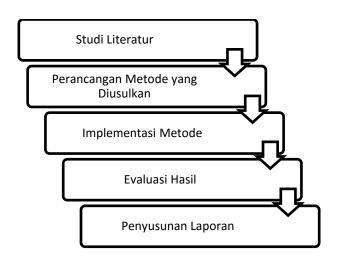
Misalkan F_G dan B_G berturut-turut merupakan pixel dari *foreground* dan *background* dari citra *ground truth* atau hasil citra segmentasi manual. Kemudian F_M dan B_M berturut-turut merupakan pixel dari *foreground* dan *background* dari hasil segmentasi. ME didefinisikan seperti pada Persamaan 2.39.

$$ME = 1 - \frac{|F_G \cap F_M| + |B_G \cap B_M|}{|F_G| + |B_G|}.$$
 (2.39)

BAB 3

METODE PENELITIAN

Pada Bab ini akan dijelaskan alur metodologi yang digunakan pada penelitian. Metodologi yang dilakukan terdiri dari studi literatur, perancangan metode yang diajukan, implementasi, pengukuran performa, analisa hasil, dan terakhir merupakan penyusunan laporan. Gambar 3.1. merupakan ilustrasi alur yang dilakukan.



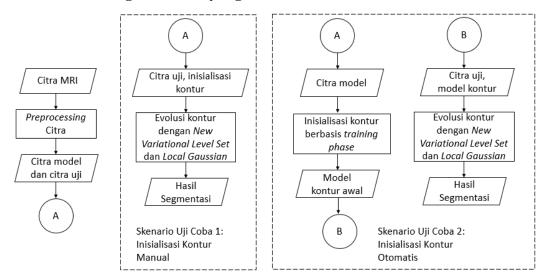
Gambar 3. 1. Alur Metodologi Penelitian

Pada Sub-bab berikut ini akan dibahas tahapan metodologi penelitian secara lebih rinci.

3. 1. Studi Literatur

Tahap pertama yang dilakukan pada penelitian ini merupakan pengkajian literatur yang sesuai dengan topik penelitian. Literatur yang digunakan yaitu tentang training phase dengan Statistical Deformable Model, New Variational Level Set, dan Local Gaussian Distribution Fitting.

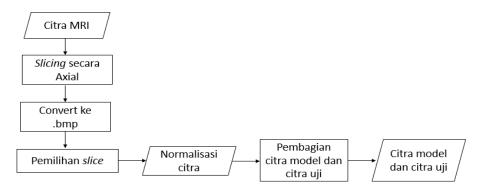
3. 2. Perancangan Metode yang Diusulkan



Gambar 3. 2. Flowchart metode penelitian

Pada penelitian ini, inputnya adalah citra MRI. Sebelum citra dilakukan proses segmentasi, maka perlu dilakukan *preprocessing* terlebih dahulu. Output dari tahap *preprocessing* adalah citra model dan citra uji. Terdapat 2 model skenario uji coba pada penelitian ini. Pada skenario uji coba 1, inisialisasi kontur dilakukan secara manual dan dievolusi dengan metode usulan. Pada skenario uji coba 2, terdapat dua proses utama yaitu proses A adalah inisialisasi kontur berbasis *training phase* untuk mendapatkan inisialisasi kontur awal (model kontur) sebagai output dengan input citra model, dilanjutkan dengan proses B yaitu evolusi kontur dengan metode *New Variational Level Set* dan *Local Gaussian*. Output dari penelitian ini adalah citra hasil segmentasi *Globus Pallidus*. Berikut merupakan penjelasan tiap bagian dalam *flowchart* yang ditunjukkan pada Gambar 3.2.

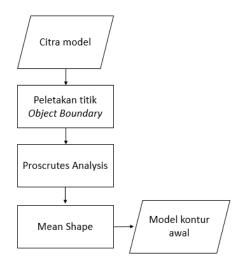
3.2.1 Preprocessing Citra



Gambar 3. 3. Flowchart tahap preprocessing citra

Tahap *preprocessing* merupakan tahap persiapan sebelum citra diproses lebih lanjut ke tahap segmentasi. Input adalah citra MRI DICOM dengan *default slicing* Sagittal. Lalu MRI di-*slicing* secara Axial. Kemudian citra di-*convert* ke dalam format .bmp dalam *slicing* Axial. Lalu dipilih *slice* citra MRI yang mengandung *Globus Pallidus* (GPi). Selanjutnya dilakukan proses normalisasi citra untuk menyeragamkan ukuran citra. Setelah itu, citra dibagi menjadi data model untuk inisialisasi kontur dan data uji untuk menguji model inisialisasi kontur. Gambar 3.3 merupakan alur dari tahap *preprocessing* yang diusulkan.

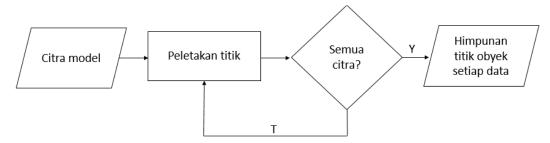
3.2.2 Inisialisasi Kontur Awal berbasis *Training Phase*



Gambar 3. 4. Flowchart tahap inisialisasi kontur awal berbasis training phase

Input adalah citra model MRI yang merupakan kombinasi dari semua bentuk dan posisi *Globus Pallidus* yang mungkin. Selanjutnya dilakukan proses peletakan titik *object boundary* untuk memperoleh titik-titiknya. Kemudian dilakukan proses *alignment* pada seluruh titik dari *object boundary* secara bersama dengan Proscrutes Analysis. Lalu dihitung rata-rata dari setiap bentuk yang variasi *object boundary* yang terdeteksi (*mean shape*) untuk memperoleh model yang akan dijadikan sebagai inisialisasi kontur awal secara otomatis pada evolusi kurva level set. Gambar 3.4 merupakan alur dari tahap *training*.

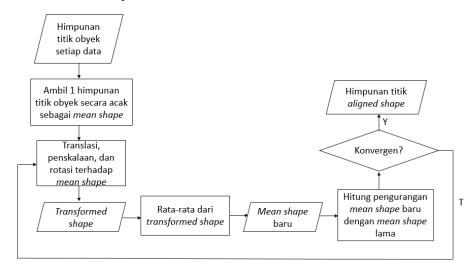
3.2.2.1 Peletakan Titik Object Boundary



Gambar 3.5. Flowchart peletakan titik object boundary

Input adalah kumpulan citra model. Proses peletakan titik *object boundary* dilakukan secara manual pada citra *training*. Output adalah himpunan titik dari setiap kontur untuk setiap data training. Alur proses ekstraksi titik *object boundary* diberikan pada Gambar 3.5

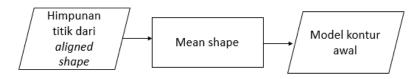
3.2.2.2 Proscrustes Analysis



Gambar 3.6. Flowchart Proscrustes Analysis

Input adalah himpunan titik obyek setiap data. Proscrustes Analysis akan melakukan proses *aligning* pada data training. Proses awal dipilih secara acak 1 himpunan titik obyek yang menjadi inisialisasi awal *mean shape*. Selanjutnya dihitung translasi, penskalaan, dan rotasi semua data terhadap *mean shape* dengan Persamaan 2.1 hingga 2.7. Hasil dari perhitungan tersebut adalah *transformed shape*. Kemudian dihitung rata-rata dari *transformed shape* sehingga menjadi *mean shape* baru. Lalu dilakukan pengurangan antara *mean shape* baru dengan *mean shape* sebelumnya (*mean shape* lama). Jika belum konvergen (hasil pengurangan *mean shape* lama dengan baru diatas batas yang ditentukan), maka diulangi dari translasi, penskalaan, dan rotasi semua data terhadap *mean shape* baru. Output adalah himpunan titik dari *shape* yang sudah ter-*aligned* (*aligned shape*). Alur proses Proscrustes diberikan pada Gambar 3.6.

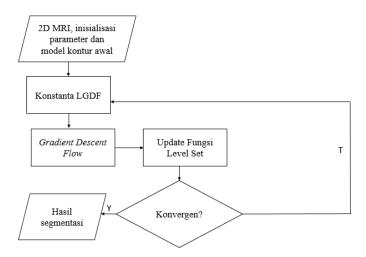
3.2.2.3 Mean Shape



Gambar 3.7. Flowchart Mean Shape

Input adalah himpunan titik dari *aligned shape*. Tahap ini menghitung rata-rata dari *shape* yang telah diperoleh. Output adalah inisialisasi awal kontur. Alur proses *Mean Shape* diberikan pada Gambar 3.7.

3.2.3 Evolusi Kontur dengan Metode Usulan



Gambar 3.8. Flowchart tahap evolusi kontur

Input adalah citra uji, model inisialisasi awal kontur yang telah didapatkan dari training phase dan parameter fungsi evolusi kontur. Kemudian menghitung konstanta LGDF seperti pada Persamaan 2.40 dan 2.41. Setelah itu, dihitung gradient descent flow yang merupakan fungsi evolusi yang diusulkan seperti pada Persamaan 3.1.

$$\begin{split} \frac{\partial \phi}{\partial t} &= -\alpha \; \delta_{\epsilon}(\phi) \; \mathrm{arctan} \; (e_1 - e_2) + \; v \delta_{\epsilon}(\phi) \; div \left(\frac{\nabla \phi}{|\nabla \phi|} \right), \\ &+ \mu \; \left(\nabla^2 \phi - div \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right). \end{split} \tag{3.1}$$

Selanjutnya, dilakukan proses *update* fungsi level set (kontur) dengan Persamaan 3.2 sebagai berikut.

$$\phi^{i+1} = \phi^i + \Delta t \frac{\partial \phi}{\partial t}, i = iterasi. \tag{3.2}$$

Fungsi arctan berfungsi untuk membatasi energi pada segmentasi agar tidak melebar kepada *background* disebabkan oleh *weak boundary* pada obyek. Alur proses evolusi kontur diberikan pada Gambar 3.8.

3. 3. Implementasi Metode

a. Dataset

Dataset yang digunakan pada penelitian ini adalah 40 dataset citra MRI dari National Hospital, Surabaya sebanyak dari 40 pasien dari citra beresolusi 256 x 256 dengan format DICOM (.dcm). Pembagian data dilakukan dengan membagi 5 data sebagai data model untuk proses *modelling* inisialisasi kontur secara otomatis dan 35 data sebagai data uji.

Citra MRI dari 1 pasien berukuran $m \times n \times s$, dengan $m \times n$ adalah dimensi citra dan s adalah banyaknya slice. Melalui citra MRI tersebut, dapat diperoleh citra MRI 2D:

- 1. Sebanyak s dengan slicing secara Sagittal berdimensi m x n,
- 2. Sebanyak n dengan slicing secara Axial berdimensi m x s
- 3. Sebanyak *m* dengan *slicing* secara Coronal berdimensi *n* x s.

b. Pengujian

Pada proses pengujian, penelitian ini akan menggunakan *Dice Similarity Coefficient* (DSC) dan *Misclassification Error* (ME) untuk mengukur akurasi dan error/kesalahan hasil segmentasi dengan *ground truth*. Penjelasan tentang DSC dan ME dapat dilihat pada sub-bab 2.6.

3. 4. Evaluasi Hasil

Evaluasi hasil dilakukan dengan membandingkan DSC dan ME pada metode usulan dengan metode Chan-Vese (CV), Region Scalable Fitting (RSF), dan *Local Gaussian* Distribution Fitting (LGDF). Perbandingan dilakukan dengan analisis statistika deskriptif berupa rata-rata hasil (Mean), standar deviasi hasil (Std) hasil, nilai minimum hasil (Min), dan nilai maksimum hasil (Max).

Halaman ini sengaja dikosongkan

BAB 4

HASIL PENELITIAN DAN PEMBAHASAN

Pada Bab ini akan dijelaskan hasil penelitian yang telah dilakukan dan pembahasan dari hasil penelitian. Pada hasil penelitian, dijelaskan mengenai lingkungan uji coba, hasil pre-processing, dan hasil penelitian per skenario uji coba. Selanjutnya, pada pembahasan dijelaskan mengenai analisis hasil penelitian pada seluruh skenario uji coba.

4. 1. Hasil Penelitian

Hasil penelitian akan dipaparkan secara lengkap pada bagian sub-bab ini. Setiap skenario uji coba disusun untuk dapat menganalisis hasil metode usulan dengan metode pembanding. Data hasil uji coba dilampirkan sebagai pendukung dari penjelasan hasil penelitian.

4.1.1 Lingkungan Uji Coba

Lingkungan uji coba yang digunakan pada penelitian ini dilakukan pada perangkat keras (*hardware*) dan lunak (*software*). Perangkat keras yang digunakan ialah sebagai berikut:

- a. Model: Laptop HP G42 Processor Intel Core i5
- b. RAM: 8 GB
- c. Harddisk: 146 GB (Local Disk C), 319 GB (Local Disk D)

Sementara itu, perangkat lunak yang digunakan ialah sebagai berikut:

- a. Sistem operasi Windows 10 x64
- b. MATLAB R2020a
- c. RadiAnt DICOM Viewer 2020.1

4.1.2 Data Uji Coba

Data uji coba yang digunakan pada penelitian ini adalah 40 dataset citra MRI dari National Hospital, Surabaya sebanyak dari 40 pasien dari citra beresolusi 256 x 256 dengan format DICOM (.dcm). Citra MRI dari 1 pasien berukuran 256 x 256 x s, dengan 256 x 256 adalah dimensi citra dan s adalah banyaknya slice.

Melalui citra MRI tersebut, dapat diperoleh citra MRI 2D dengan *slicing* secara Axial sebanyak 256 citra berdimensi 256 x s.

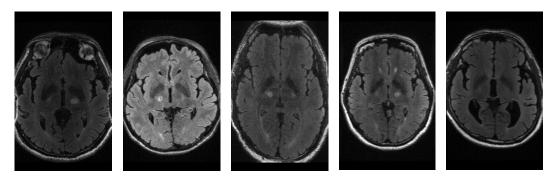
4.1.3 Hasil Pre-Processing

Sebagaimana telah dijelaskan pada sub-bab 3.4, dataset MRI yang digunakan masih dalam format DICOM (.dcm). Oleh karena itu, tahap preprocessing diperlukan untuk mengubah citra ke dalam bentuk BITMAP (.bmp) dengan *slicing* Axial dan memilih citra dengan Globus Pallidus agar tahap segmentasi berbasis 2D dapat dilakukan. Proses pengubahan format DICOM ke BITMAP dengan *slicing* Axial dilakukan dengan perangkat lunak RadiAnt DICOM Viewer. Citra output akan berukuran 256 x s, dengan s adalah banyaknya *slice* dalam 1 dataset MRI. Selanjutnya, dilakukan pemilihan *slice* dari citra MRI yang terdapat obyek Globus Pallidus. Tahap terakhir adalah melakukan normalisasi pada setiap citra agar setiap citra memiliki dimensi yang sama. Normalisasi citra dilakukan dengan mengambil rata-rata dari dimensi seluruh dataset citra (40 dataset citra MRI) yang digunakan. Tabel perhitungan normalisasi citra diberikan pada Tabel 4.1.

Tabel 4.1 Normalisasi Citra

Citra	Height (pixel)	Width (pixel)
Citra 1	256	148
Citra 2	256	148
Citra 3	256	156
:	:	:
Citra 39	256	167
Citra 40	256	159
Rata-rata	256	156

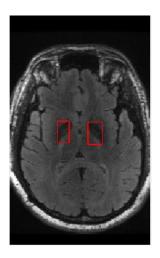
Selanjutnya, dilakukan pemilihan 5 citra dari 40 dataset citra MRI sebagai citra model yang akan digunakan untuk inisialisasi kontur secara otomatis. Pemilihan citra didasarkan pada kombinasi bentuk citra otak MRI dan letak Globus Pallidus. Citra yang terpilih sebagai citra model diberikan pada Gambar 4.1. Kemudian, 35 citra lainnya sebagai citra uji yang akan digunakan pada seluruh skenario percobaan.



Gambar 4.1 Citra Model

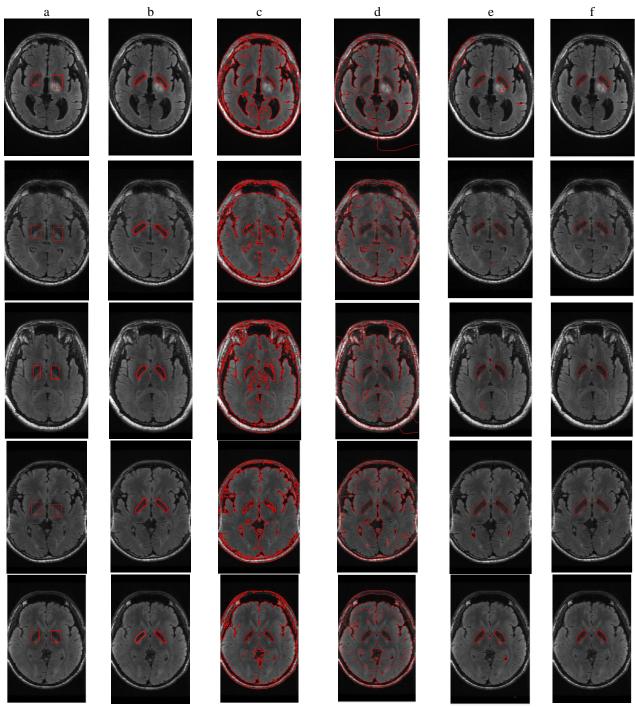
4.1.4 Hasil Skenario Uji Coba 1: Inisialisasi Kontur secara Manual

Pada skenario uji coba 1 ini dilakukan inisialisasi kontur secara manual pada citra MRI. Inisialisasi kontur dibentuk pada model *Rectangle* (persegi panjang) dan ditempatkan tepat pada Globus Pallidus (*left* dan *right*). Contoh model inisialisasi kontur secara manual diberikan pada Gambar 4.2.



Gambar 4.2 Contoh inisialisasi kontur

Kemudian, inisialisasi kontur dievolusi dengan metode usulan. Metode usulan, yakni Active Contour berbasis *Local Gaussian* dan New Variational Level Set akan dibandingkan dengan metode segmentasi Chan-Vese (CV), Region Scalable Fitting (RSF), dan *Local Gaussian* Distribution Fitting (LGDF).



Gambar 4.3. Contoh Hasil Uji Coba Skenario 1: (a) Inisialisasi kontur, (b) *Ground truth*, (c) Hasil dari metode CV, (d) Hasil dari metode RSF, (e) Hasil dari metode LGDF, (f) Hasil dari metode usulan

Secara kualitatif, contoh hasil segmentasi dapat dilihat pada Gambar 4.3. Hasil segmentasi secara lengkap dapat dilihat pada Lampiran 1. Secara kuantitatif, perbandingan dilakukan dengan analisis statistika deskriptif dari *Dice Similarity Coefficient* (DSC) dan *Misclassification Error* (ME) berupa rata-rata (mean), standar

deviasi (Std), nilai minimal (Min), dan nilai maksimal (Max). Hasil DSC dan ME tersebut ditunjukkan pada Tabel 4.2.

Tabel 4.2. Hasil DSC dan ME Skenario Uji Coba 1

Statistika	Metode Pembanding						Metode Usulan	
	CV		RSF		LGDF		Metode Osufaii	
Deskriptif	DSC	ME	DSC	ME	DSC	ME	DSC	ME
Mean	0.0207	0.4818	0.0755	0.2904	0.6935	0.0129	0.8335	0.0050
Std	0.0185	0.0403	0.0243	0.0757	0.1729	0.0126	0.0409	0.0025
Min	0.0015	0.3866	0.0131	0.1763	0.2760	0.0024	0.7119	0.0023
Max	0.0642	0.5630	0.1199	0.4923	0.8857	0.0548	0.9050	0.0155

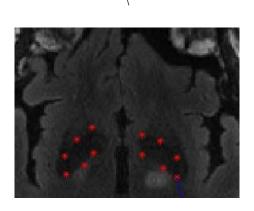
Tabel 4.2 menunjukkan bahwa metode usulan berada pada posisi teratas pada Mean, Min, dan Max dari perhitungan DSC dan ME dengan nilai berturut-turut 0.8335, 0.7119, dan 0.9050. Sementara itu, Std terkecil dari DSC dicapai oleh metode CV, sehingga setiap hasil metode CV sangat mendekati Mean-nya. Metode usulan memperoleh Std terkecil pada perhitungan ME, sehingga hasil ME pada metode usulan stabil dalam mendekati Mean-nya.

4.1.5 Hasil Skenario Uji Coba 2: Inisialisasi Kontur secara Otomatis

Pada skenario uji coba ke-2 ini, inisialisasi kontur dilakukan secara otomatis dengan proses membuat model inisial kontur model *shape prior* dengan Active Shape Model seperti yang diusulkan oleh (Rabeh dkk, 2017). Melalui usulan tersebut, penulis mengembangkan model *shape prior* menjadi model *Rectangle* (persegi panjang) dari *output* metode inisialisasi kontur usulan (Rabeh dkk, 2017). Sehingga skenario uji coba 2 akan diteliti hasil segmentasi model *shape prior* dan model *Rectangle* otomatis.

4.1.5.1 Hasil Peletakan Titik Data Model

Input dari proses *training phase* adalah himpunan titik-titik dari citra model. Citra model memang dikhususkan untuk membentuk model inisialisasi kontur awal secara otomatis. Sebanyak enam titik ditempatkan pada Globus Pallidus *left* dan *right*, sehingga total input terdapat duabelas titik untuk diproses pada *training phase*. Contoh peletakan titik diberikan pada Gambar 4.4.



Gambar 4.4 Contoh proses peletakan titik

Pada Gambar 4.4, terlihat bahwa peletakan titik dilakukan mulai dari ujung paling atas hingga ujung paling bawah dari Globus Pallidus. Hal ini dilakukan agar detail panjang dan lebar Globus Pallidus dapat terdeteksi dengan baik.

4.1.5.2 Hasil Keluaran Inisialisasi Kontur Berbasis Training Phase

Hasil dari peletakan titik berupa kumpulan koordinat (x, y) diproses dalam Active Shape Model pada *training phase* sehingga memberikan *output* yaitu kumpulan koordinat koordinat (x, y) yang digunakan sebagai inisialisasi kontur tetap untuk semua data uji. Hasil koordinat model inisialisasi kontur dapat dilihat pada Tabel 4.3.

Tabel 4.3 Hasil Koordinat Model Inisialisasi Kontur

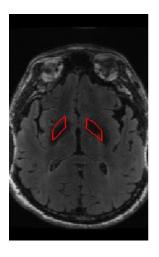
No.	x	у
1	117.2225	119.9416
2	124.5531	129.2355
3	128.4139	125.3807
4	133.2882	136.9999

5	135.4005	133.1106
6	143.1455	144.6907
7	63.18855	88.02809
8	55.20026	87.69343
9	64.54471	97.89139
10	49.12481	96.51425
11	57.82773	104.7863
12	50.14487	105.528

Seperti dilihat pada Tabel 4.3, terdapat 12 titik hasil inisialisasi kontur. Pada tabel nomor 1 hingga 6 merupakan koordinat titik dari Globus Pallidus *left*, sedangkan nomor tujuh hingga duabelas merupakan koordinat titik dari Globus Pallidus *right*.

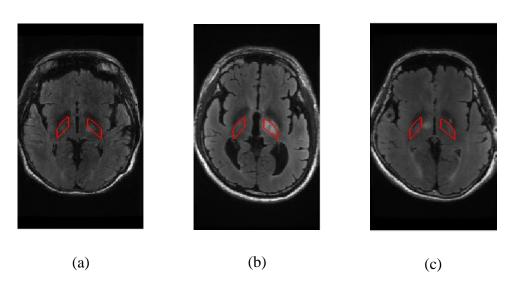
4.1.5.3 Hasil Segmentasi Model Shape Prior

Pada segmentasi model *shape prior*, hasil koordinat titik pixel pada *training phase* dibentuk hingga membentuk garis *shape prior* yang menjadi inisialisasi kontur untuk dilakukan proses evolusi kontur dengan metode usulan. Contoh hasil model kontur *shape prior* dari (Rabeh dkk, 2017) diberikan pada Gambar 4.5. Model kontur awal *shape prior* menyerupai Globus Pallidus yang nantinya akan dievolusi agar memiliki hasil segmentasi yang sesuai dengan *boundary* dari citranya.



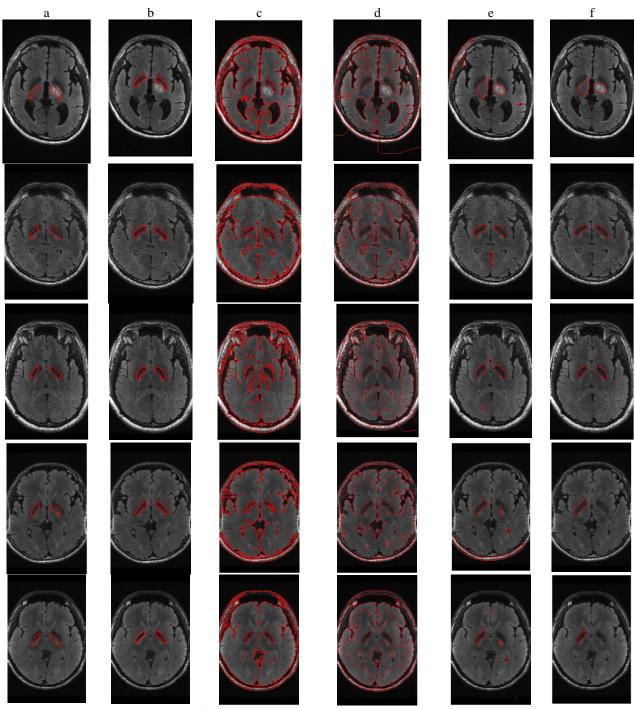
Gambar 4.5 Contoh hasil model kontur awal shape prior

Seperti terlihat pada Gambar 4.5, model kontur *shape prior* cocok dengan citra uji. Namun demikian, terdapat citra-citra yang tidak cocok dengan model kontur *shape prior*. Beberapa contoh dari citra yang tidak cocok dengan model kontur tersebut diberikan pada Gambar 4.6.



Gambar 4.6 Citra yang Tidak Cocok dengan Model Shape Prior

Pada Gambar 4.6(a) dan 4.6(b), inisialisasi kontur tidak mengenai boundary pada Globus Pallidus *left* maupun *right*. Sementara itu, Gambar 4.5(c) menunjukkan ada sebagian inisialisasi kontur mengena pada Globus Pallidus *left*, namun keluar *boundary* pada Globus Pallidus *right*. Contoh hasil segmentasi model *Shape Prior* diberikan pada Gambar 4.7.



Gambar 4.7. Contoh Hasil Uji Coba Skenario 2 Model *Shape Prior*: (a) Inisialisasi kontur, (b) *Ground truth*, (c) Hasil dari metode CV, (d) Hasil dari metode RSF, (e) Hasil dari metode LGDF, (f) Hasil dari metode usulan

Seperti terlihat pada Gambar 4.6, terdapat hasil segmentasi yang berhasil dan tidak berhasil. Pada hasil segmentasi yang berhasil, metode usulan mampu memberikan hasil yang terbaik dibandingkan dengan metode lainnya. Sementara pada hasil segmentasi yang tidak berhasil, pengaruh inisialisasi kontur yang tidak

tepat menunjuk pada obyeknya membuat metode usulan melakukan segmentasi pada obyek sesuai dengan inisialisasinya. Kemudian, hasil kuantitatif menggunakan DSC dan ME ditunjukkan pada Tabel 4.4

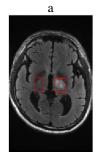
Tabel 4.4. Hasil DSC dan ME Skenario Uji Coba 2 (Model Shape Prior)

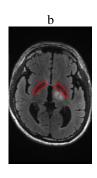
Statistika	Metode Pembanding						Metode Usulan	
	CV		RSF		LGDF		Wietode Osufaii	
Deskriptif	DSC	ME	DSC	ME	DSC	ME	DSC	ME
Mean	0.0177	0.4766	0.0539	0.3060	0.4077	0.0251	0.5522	0.0084
Std	0.0177	0.0364	0.0331	0.0800	0.2626	0.0198	0.3329	0.0054
Min	0.0015	0.3866	0.0001	0.2169	0	0.0048	0	0.0023
Max	0.0642	0.5573	0.1116	0.4825	0.8412	0.0771	0.9068	0.0284

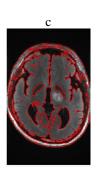
Pada Tabel 4.4, ditunjukkan hasil DSC dan ME pada model *Shape Prior*. Metode usulan memiliki Mean, Std, Min, dan Max terbaik pada hasil tersebut. Hal tersebut menunjukkan kekuatan metode usulan dalam memberikan hasil segmentasi yang terbaik meskipun pada segmentasi otomatis masih ditemukan inisialisasi kontur yang tidak tepat.

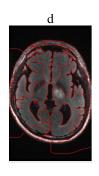
4.1.5.4 Hasil Segmentasi Model *Rectangle*

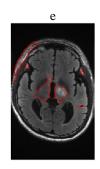
Pada skenario uji coba ke-2, hasil dari inisialisasi kontur berbasis *training phase* pada Tabel 4.3 dapat direpresentasikan dalam bentuk persegi panjang (*Rectangle*). Sehingga inisialisasi kontur dapat berbentuk *Rectangle* seperti halnya inisialisasi kontur manual sebelumnya. Hasil segmentasi menggunakan inisialisasi kontur secara otomatis dengan model *Rectangle* ditunjukkan pada Gambar 4.8.

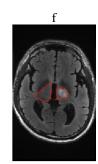


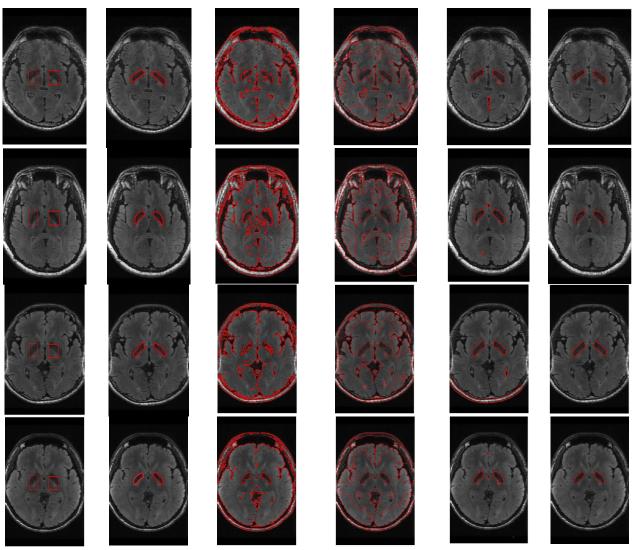












Gambar 4.8. Contoh Hasil Uji Coba Skenario 2 Model *Rectangle*: (a) Inisialisasi kontur, (b) *Ground truth*, (c) Hasil dari metode CV, (d) Hasil dari metode RSF, (e) Hasil dari metode LGDF, (f) Hasil dari metode usulan

Seperti terlihat pada Gambar 4.8, terdapat segmentasi yang berhasil dan segmentasi yang tidak berhasil. Sebagian besar segmentasi pada Gambar 4.7 berhasil disegmentasi oleh metode usulan. Ketidakberhasilan segmentasi terjadi akibat inisialisasi kontur yang tidak cocok menunjuk obyek seperti kasus skenario uji coba metode *Shape Prior*. Kesalahan melakukan inisialisasi kontur mengakibatkan hasil segmentasi tidak tepat dalam melakukan segmentasi. Hasil pengukuran DSC dan ME pada model *Rectangle* ini ditunjukkan pada Tabel 4.5.

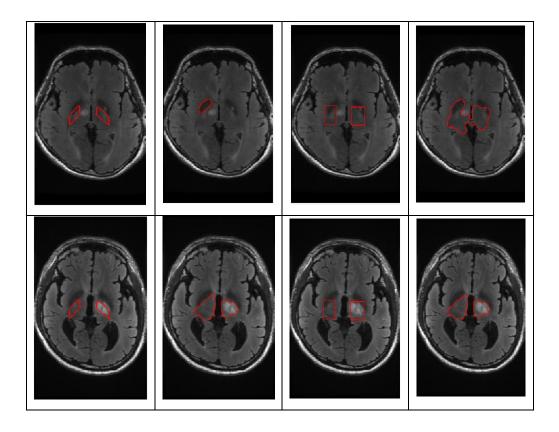
Tabel 4.5. Hasil DSC dan ME Skenario Uji Coba 2 (Model Rectangle)

Statistika	Metode Pembanding						Metode Usulan	
	CV		RSF		LGDF		ivietode Osufali	
Deskriptif	DSC	ME	DSC	ME	DSC	ME	DSC	ME
Mean	0.0150	0.4750	0.0662	0.2930	0.4828	0.0279	0.6672	0.0114
Std	0.0165	0.03633	0.0254	0.0822	0.2340	0.0216	0.2407	0.0115
Min	0.0015	0.3866	0.0128	0.1763	0.0057	0.0023	0.0055	0.0023
Max	0.0642	0.5630	0.124	0.5147	0.8889	0.0991	0.9031	0.0541

Berdasarkan Tabel 4.5, metode usulan menghasilkan nilai DSC dan ME yang terbaik pada Mean, Std, Min, dan Max. Hal ini menunjukkan keunggulan metode usulan dalam melakukan segmentasi Globus Pallidus. Selanjutnya, Tabel 4.6 menunjukkan contoh gambar dari model *Shape Prior* dan *Rectangle* yang tidak berhasil disegmentasi akibat inisialisasi kontur yang tidak tepat.

Tabel 4.6 Contoh Gambar Gagal Segmentasi

Inisialisasi Kontur	Hasil Citra model	Inisialisasi Kontur	Hasil Citra model
model Shape Prior	Shape Prior	model Rectangle	Rectangle
			3.



4. 2. Pembahasan Hasil Penelitian

Pada subbab ini akan diberikan pembahasan secara menyeluruh dari hasil uji coba pada subbab sebelumnya. Pembahasan akan dipaparkan secara kualitatif dan kuantitatif. Pembahasan secara kualitatif dilakukan dengan membandingkan *output* citra segmentasi metode usulan dengan metode-metode pembanding, yakni Chan-Vese (CV), Region Scalable Fitting (RSF), dan *Local Gaussian* Distribution Fitting (LGDF). Pembahasan secara kuantitatif dilakukan dengan membandingkan hasil statistika deskriptif dari DSC dan ME, yaitu rata-rata (Mean), standar deviasi (Std), nilai minimum hasil (Min) dan nilai maksimum hasil (Max).

4.2.1 Pembahasan secara Kualitatif

Hasil segmentasi yang dilakukan oleh metode CV menunjukkan hasil yang seperti membagi citra menjadi beberapa daerah, bukan secara langsung melakukan segmentasi kepada Globus Pallidus. Meskipun Globus Pallidus tersegmentasi oleh metode CV, namun daerah *background* lainnya terdeteksi sebagai obyek. Hal ini diakibatkan oleh metode CV yang berbasis *edge*, yakni bergantung pada garis/tepi

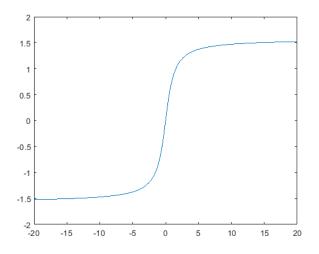
obyek dengan asumsi *intensity homogeneity*, yaitu setiap obyek memiliki intensitas yang sama. Sehingga asumsi tersebut tidak sesuai dengan karakteristik citra MRI yang *intensity inhomogeneity* dan Globus Pallidus yang memiliki kontras rendah disekitarnya. Metode usulan terbukti mampu menangani citra dengan *intensity inhomogeneity* dengan hasil segmentasi yang berfokus pada obyek yang diinisialisasikan pada inisialisasi awal kontur.

Sementara itu, metode RSF memiliki hasil yang tidak jauh berbeda dengan metode CV. Meskipun kontur yang dihasilkan jauh lebih *smooth* (tidak patah-patah) seperti metode CV, namun *background* masih terdeteksi sebagai obyek. Hal ini menunjukkan bahwa RSF tidak mampu dalam melakukan segmentasi pada citra dengan *intensity inhomogeneity* yang parah dan *weak boundary* seperti Globus Pallidus pada citra MRI. Sehingga metode usulan terbukti memiliki hasil yang terbaik dengan melakukan segmentasi secara khusus pada Globus Pallidus.

Kemudian, metode LGDF memiliki hasil yang jauh lebih baik dibandingkan metode CV dan RSF. LGDF mampu melakukan segmentasi Globus Pallidus dengan baik. Namun, masih terdapat *background* yang terdeteksi sebagai obyek sehingga tersegmentasi dan hasil kurva masih patah-patah tidak sesuai dengan *boundary*-nya. Sehingga hasil segmentasi LGDF tidak menunjukkan kualitas yang baik karena kotor dengan tersegmentasinya *background*. Metode usulan memperbaiki hasil segmentasi Globus Pallidus dari LGDF dengan memberikan hasil segmentasi yang *smooth* dan bersih sehingga jangkauan segmentasi tidak melebar kepada *background* meskipun Globus Pallidus sangat *weak boundary* dengan *background*-nya.

Melalui fungsi arctan pada *New Variational Level Set*, metode usulan mengatasi citra MRI yang mengandung *intensity inhomogeneity* dan *weak boundary* pada sekitar area *Globus Pallidus*. Gambar 4.9 menunjukkan grafik fungsi arctan dari MATLAB R2020a. Seperti pada gambar, fungsi arctan memiliki *range* fungsi $y \in \left[-\frac{\pi}{2}, \frac{\pi}{2}\right] \approx y \in [-1.57, 1.57]$ dari *domain* fungsi $x \in \mathbb{R}$. Pada subbab 2.5 telah dijelaskan bahwa domain citra Ω dapat dibagi dalam dua region: region *foreground* (obyek) Ω_F dan region *background* Ω_B . Region tersebut berturut-turut dapat direpresentasikan dalam bentuk fungsi level set ϕ yaitu $\Omega_F = \{\phi < 0\}$ dan $\Omega_B =$

 $\{\phi>0\}$. Fungsi awal dari level set Ω_F dan Ω_B didefinisikan pada inisialisasi kontur. Fungsi arctan yang digunakan pada LGDF membatasi energi evolusi kontur pada LGDF agar tidak melebar kepada kontur yang tidak termasuk dalam region foreground Ω_F , yang dalam penelitian ini adalah Globus Pallidus. Sehingga hasil segmentasi hanya pada obyek yang ditunjuk oleh inisialisasi kontur dan tidak jatuh pada false boundary atau hasil segmentasi pada boundary non-obyek. Hal itu dibuktikan dengan kesesuaian antara citra hasil segmentasi metode usulan dengan citra ground truth. Berbeda dengan LGDF yang memiliki hasil yang kotor karena masih terdapat kontur non Globus Pallidus yang terdeteksi sebagai obyek dan mempengaruhi akurasi segmentasinya.



Gambar 4.9 Grafik Fungsi arctan

Oleh sebab itu, kebergantungan pada inisialisasi kontur membuat hasil segmentasi yang tidak tepat pada obyeknya sehingga tidak akan berhasil disegmentasi dengan baik dan sempurna. Tabel 4.7 memberikan contoh citra yang sama dengan inisialisasi yang berbeda, dengan satu dilakukan dengan inisialisasi kontur secara manual dan yang lainnya merupakan hasil keluaran dari inisialisasi kontur otomatis pada model *Rectangle*. Secara visual, terlihat kedua inisialisasi kontur tersebut sama, yaitu tepat mengenai obyek Globus Pallidus. Namun, inisialisasi kontur otomatis model *Rectangle* mendefinisikan posisi kontur awal

berwarna putih juga ikut terdeteksi sebagai Globus Pallidus. Berbeda dengan inisialisasi kontur manual yang mendefinisikan posisi kontur awal lebih mengena kepada obyeknya dan menghindari noise berwarna putih pada Globus Pallidus bagian kanan. Inisialisasi kontur awal sangat berperan dalam mendefinisikan suatu region obyek sehingga boundary-nya dapat dideteksi. Pada kasus segmentasi Globus Pallidus dalam penelitian ini, inisialisasi kontur harus tepat diatas Globus Pallidus dengan panjang dan lebar yang didominasi oleh obyek Globus Pallidus. Kasus inisialisasi kontur otomatis mode Rectangle yang mengalami false boundary disebabkan oleh inisialisasi kontur yang terlalu panjang ke bawah bagian Globus Pallidus dan terlalu lebar sehingga mengenai noise berwarna putih pada Globus Pallidus bagian kanan.

Tabel 4.7 Contoh Posisi Inisialisasi Kontur

Inisialisasi Kontur Manual	Inisialisasi Kontur Otomatis Model Rectangle	Hasil Inisialisasi Kontur Manual	Hasil Inisialisasi Kontur Otomatis Model <i>Rectangle</i>

Segmentasi citra pada skenario uji coba 1 menunjukkan hasil yang terbaik dikarenakan inisialisasi kontur yang sesuai dengan obyek. Sementara itu, hasil pada skenario uji coba 2 menunjukkan terdapat citra yang gagal disegmentasi oleh semua metode, baik metode pembanding maupun usulan. Model *Shape Prior* menunjukkan hasil yang tidak baik disebabkan oleh posisi inisialisasi kontur yang berada di luar *boundary* dari obyek (Globus Pallidus). Demikian pula model *Rectangle* menunjukkan hasil yang tidak lebih baik daripada inisialisasi kontur manual.

Inisialisasi kontur otomatis dengan model *Rectangle* memiliki hasil yang lebih baik daripada model *Shape Prior* dikarenakan jangkauan inisialisasinya lebih lebar. Namun, jangkauan inisialisai yang terlalu lebar melebihi obyek dapat mengakibatkan *background* juga turut terdeteksi sebagai obyek akibat pengaruh *intensity inhomogeneity* pada citra MRI yang sulit membedakan antara intensitas obyek dengan *background*. Masih terdapat citra yang gagal tersegmentasi dari model *Rectangle* karena kesalahan posisi inisialisasi kontur. Hal ini menunjukkan bahwa 1 (satu) model dari *training phase* belum dapat mewakili seluruh citra MRI yang tersedia. Namun demikian, metode usulan mampu mengendalikan hasil segmentasi agar hanya mendeteksi *boundary* pada sekitar inisialisasi kontur sebagai obyek dengan hasil evolusi kurva Level Set yang *smooth* mengikuti *real boundary* dari obyek. Metode usulan secara konsisten mengidentifikasi inisialisasi kontur awal sebagai obyek sehingga jika terjadi kesalahan posisi pada inisialisasi kontur maka hasil segmentasi menjadi berbeda.

4.2.2 Pembahasan secara Kuantitatif

Sesuai dengan pembahasan secara kualitatif, hasil rata-rata (Mean) dari metode usulan menjadi hasil yang tertinggi dibandingkan dengan metode-metode pembanding lainnya. Nilai Mean tertinggi dari metode usulan diperoleh dari skenario uji coba 1, yaitu inisialisasi kontur secara manual dengan hasil DSC terbesar bernilai 0.8335 dan ME terkecil bernilai 0.0050. Sementara inisialisasi kontur secara otomatis dengan model *Rectangle* menempati urutan ke-2 terbesar dengan hasil DSC sebesar 0.6672 dan ME sebesar 0.0114. Kemudian urutan terakhir diikuti oleh model *Shape Prior* dengan hasil DSC sebesar 0.5522 dan ME sebesar 0.0084. Demikian halnya nilai Min dan Max dari metode usulan lebih tinggi daripada metode pembanding lainnya. Hal ini membuktikan metode usulan mampu melakukan segmentasi dengan akurasi terbaik disertai *error* (kesalahan) sekecil mungkin.

Metode CV dan RSF memiliki hasil yang hampir mirip dalam Mean, Min, dan Max meskipun hasil segmentasi RSF lebih tinggi daripada CV. Metode CV dan RSF hanya memiliki nilai Std yang terkecil dibanding metode LGDF dan usulan sehingga CV dan RSF konsisten dalam melakukan segmentasi sesuai dengan nilai

rata-ratanya. Meski demikian, konsistensi CV dan RSF merupakan konsistensi dalam melakukan segmentasi dengan nilai DSC terkecil dan ME terbesar. Artinya, CV dan RSF tidak berhasil dalam melakukan segmentasi Globus Pallidus. Metode LGDF memiliki nilai Mean yang lebih tinggi dibanding metode CV dan RSF. Namun, LGDF tetap tidak meraih hasil DSC yang maksimal dan ME yang minimal karena hasil segmentasi yang tidak sesuai dengan *ground truth*-nya sebagaimana telah dievaluasi pada pembahasan secara kualitatif. LGDF dan metode usulan sama-sama memiliki nilai Std yang tinggi dikarenakan terdapat hasil segmentasi yang kurang sesuai dengan *ground truth* atau bahkan gagal.

Pada skenario uji coba 1 (inisialisasi kontur manual), Std dari DSC pada LGDF dan metode usulan masih dibawah 0.1. Artinya, penyimpangan nilai hasil segmentasi dari rata-rata (Mean)nya sangat kecil. Namun, pada skenario uji coba 2, Std dari DSC pada LGDF dan metode usulan mencapai diatas 0.2, yang menunjukkan penyimpangan nilai DSC dari setiap citra terhadap rata-rata (Mean)nya sangat besar. Hal ini diakibatkan oleh banyaknya citra yang gagal tersegmentasi pada skenario uji coba 2, yaitu inisialisasi kontur secara otomatis, baik model *Shape Prior* maupun *Rectangle*. Melalui nilai minimum dari model *Shape Prior* dan *Rectangle* yang berturut-turut senilai 0 dan 0.0055, diketahui bahwa ada citra yang gagal disegmentasi oleh LGDF dan metode usulan. Metode usulan melakukan segmentasi citra sesuai dengan inisialisasi kontur yang diberikan meskipun terdapat *noise* yang mengganggu. Posisi inisialisasi kontur yang tidak tepat menyebabkan hasil segmentasi menjadi tidak berhasil.

BAB 5

KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian dan pembahasan yang telah diuraikan pada metode Active Contour berbasis *Local Gaussian* pada *New Variational Level Set*, maka dapat diuraikan kesimpulan dan saran untuk pengembangan penelitian lanjutan dari penelitian ini.

5. 1. Kesimpulan

Kesimpulan dari penelitian ini adalah sebagai berikut:

- 1. Penelitian ini telah mengembangkan metode Active Contour berbasis Local Gaussian dengan New Variational Level Set sebagai metode usulan untuk segmentasi Globus Pallidus. Metode usulan terbukti mampu melakukan segmentasi Globus Pallidus yang rendah kontras dan weak boundary pada citra MRI. Metode usulan mengembangkan fungsi arctan untuk membatasi energi sehingga segmentasi tidak melebar kepada <u>background</u> pada Metode usulan meraih nilai terbesar dan terkecil pada rata-rata (Mean) pada nilai DSC dan ME dibandingkan dengan metode lainnya.
- 2. Skenario uji coba 1 dilakukan dengan melakukan inisialisasi kontur secara manual, yaitu dengan meletakkan inisialisasi kontur secara tepat pada posisi Globus Pallidus. Skenario uji coba 2 dilakukan dengan melakukan inisialisasi kontur secara otomatis melalui training phase dengan model Shape Prior dan Rectangle. Proses evolusi kontur pada seluruh skenario uji coba dilakukan dengan metode usulan. Pada skenario uji coba 1, nilai Mean dari DSC dan ME berturut-turut adalah 0.8335 dan 0.0050.
- 3. Pada skenario uji coba 2 model *Shape Prior*, nilai nilai Mean dari DSC dan ME berturut-turut adalah 0.5523 dan 0.00843. Selanjutnya pada skenario uji coba 2 model *Rectangle*, nilai nilai Mean dari DSC dan ME berturut-turut adalah 0.6672 dan 0.0114. Ada kegagalan segmentasi pada

skenario uji coba 2 disebabkan oleh posisi inisialisasi kontur yang terlalu lebar mengenai *background* sehingga ikut terdeteksi sebagai obyek.

5. 2. Saran

Pada penelitian ini terdapat citra yang tidak dapat disegmentasi dengan menggunakan metode berbasis *shape prior*, sehingga disarankan untuk mencari metode lain yang lebih efektif dalam melakukan inisialisasi kontur secara otomatis.

DAFTAR PUSTAKA

Al-Radaideh, A. M. and Rababah, E. M. (2016) 'The role of magnetic resonance imaging in the diagnosis of Parkinson's disease: A review', *Clinical Imaging*. Elsevier Inc., 40(5), pp. 987–996. doi: 10.1016/j.clinimag.2016.05.006. Bankman, I. N. (2009) *Handbook of Medical Image Processing and Analysis, 2nd Edition*.

Bi, H. *et al.* (2019) 'Fast and Accurate Segmentation Method of Active Shape Model with Rayleigh Mixture Model Clustering for Prostate Ultrasound Images', *Computer Methods and Programs in Biomedicine*. Elsevier B.V., p. 105097. doi: 10.1016/j.cmpb.2019.105097.

Chan, T. F. and Vese, L. A. (2001) 'Active contours without edges', *IEEE Transactions on Image Processing*, 10(2), pp. 266–277. doi: 10.1109/83.902291. Cigdem, O., Beheshti, I. and Demirel, H. (2018) 'Effects of different covariates and contrasts on classification of Parkinson's disease using structural MRI', *Computers in Biology and Medicine*. Elsevier Ltd, 99(March), pp. 173–181. doi: 10.1016/j.compbiomed.2018.05.006.

Cootes, T. F. *et al.* (2013) 'Training Models of Shape from Sets of Examples', pp. 2.1-2.10. doi: 10.5244/c.6.2.

Dolz, J., Desrosiers, C. and Ben Ayed, I. (2018) '3D fully convolutional networks for subcortical segmentation in MRI: A large-scale study', *NeuroImage*. Elsevier, 170(April 2017), pp. 456–470. doi: 10.1016/j.neuroimage.2017.04.039.

Dong, B., Jin, R. and Weng, G. (2019) 'Active contour model based on local bias field estimation for image segmentation', *Signal Processing: Image Communication*. Elsevier Ltd, 78(178), pp. 187–199. doi: 10.1016/j.image.2019.07.001.

González-Villà, S. *et al.* (2016) 'A review on brain structures segmentation in magnetic resonance imaging', *Artificial Intelligence in Medicine*. Elsevier B.V., 73, pp. 45–69. doi: 10.1016/j.artmed.2016.09.001.

Heim, B. *et al.* (2017) 'Magnetic resonance imaging for the diagnosis of Parkinson's disease', *Journal of Neural Transmission*. Springer Vienna, 124(8), pp. 915–964. doi: 10.1007/s00702-017-1717-8.

Iacono, M. I. et al. (2011) 'Atlas-based segmentation for Globus Pallidus targeting on low-resolution MRI', *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 5706–5709. doi: 10.1109/IEMBS.2011.6091381.

Kass, M., Witkin, A. and Terzopoulos, D. (1988) 'Snakes: Active contour models', *International Journal of Computer Vision*, 1(4), pp. 321–331. doi: 10.1007/BF00133570.

Li, C. *et al.* (2008) 'Minimization of region-scalable fitting energy for image segmentation', *IEEE Transactions on Image Processing*, 17(10), pp. 1940–1949. doi: 10.1109/TIP.2008.2002304.

Liu, Y., Wei, Y. and Wang, C. (2019) 'Subcortical Brain Segmentation Based on Atlas Registration and Linearized Kernel Sparse Representative Classifier', *IEEE Access*. IEEE, 7, pp. 31547–31557. doi: 10.1109/ACCESS.2019.2902463.

R.J. Hemalatha, T.R. Thamizhvani, A. Josephin Arockia Dhivya, Josline Elsa Joseph, B. B. and R. C. (2018) 'Active Contour Based Segmentation Techniques for Medical Image Analysis', *Intech*, i(tourism), p. 13. doi: http://dx.doi.org/10.5772/intechopen.74576.

Ben Rabeh, A., Benzarti, F. and Amiri, H. (2017) 'Segmentation of brain MRI using active contour model', *International Journal of Imaging Systems and Technology*, 27(1), pp. 3–11. doi: 10.1002/ima.22205.

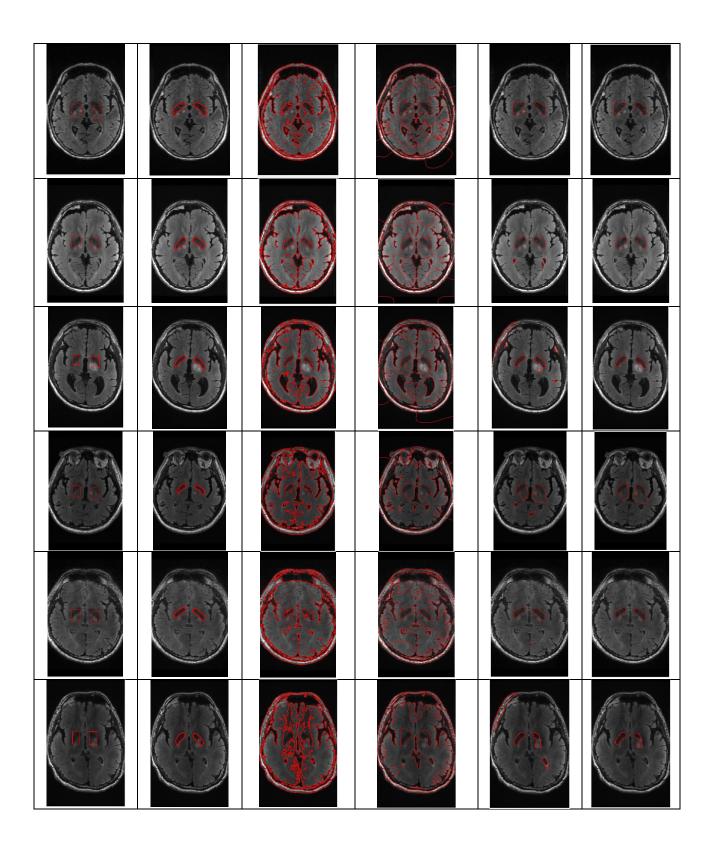
Shan, X., Gong, X. and Nandi, A. K. (2018) 'Active Contour Model Based on Local Intensity Fitting Energy for Image Segmentation and Bias Estimation', *IEEE Access*. IEEE, 6, pp. 49817–49827. doi: 10.1109/ACCESS.2018.2863719. Uros, V., Franjo, P. and Bostjan, L. (2007) 'A review of methods for correction of intensity inhomogeneity in MRI', *IEEE Transactions on Medical Imaging*, 26(3), pp. 405–421.

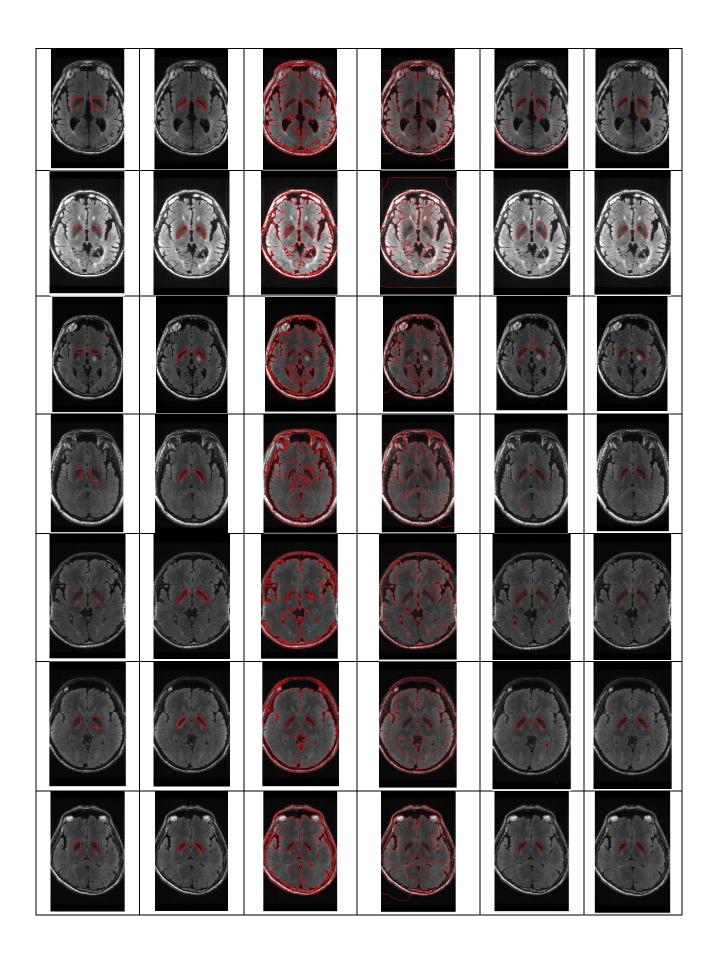
Wang, L. *et al.* (2009) 'Active contours driven by *Local Gaussian* distribution fitting energy', *Signal Processing*. Elsevier, 89(12), pp. 2435–2447. doi: 10.1016/j.sigpro.2009.03.014.

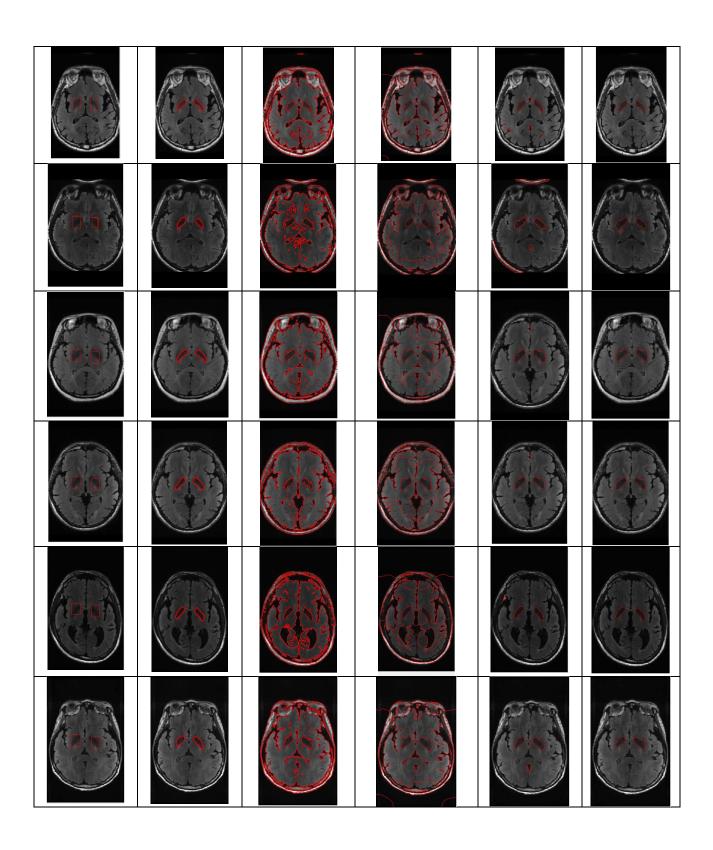
Zhang, K. *et al.* (2016) 'A Level Set Approach to Image Segmentation with Intensity Inhomogeneity', *IEEE Transactions on Cybernetics*. IEEE, 46(2), pp. 546–557. doi: 10.1109/TCYB.2015.2409119.

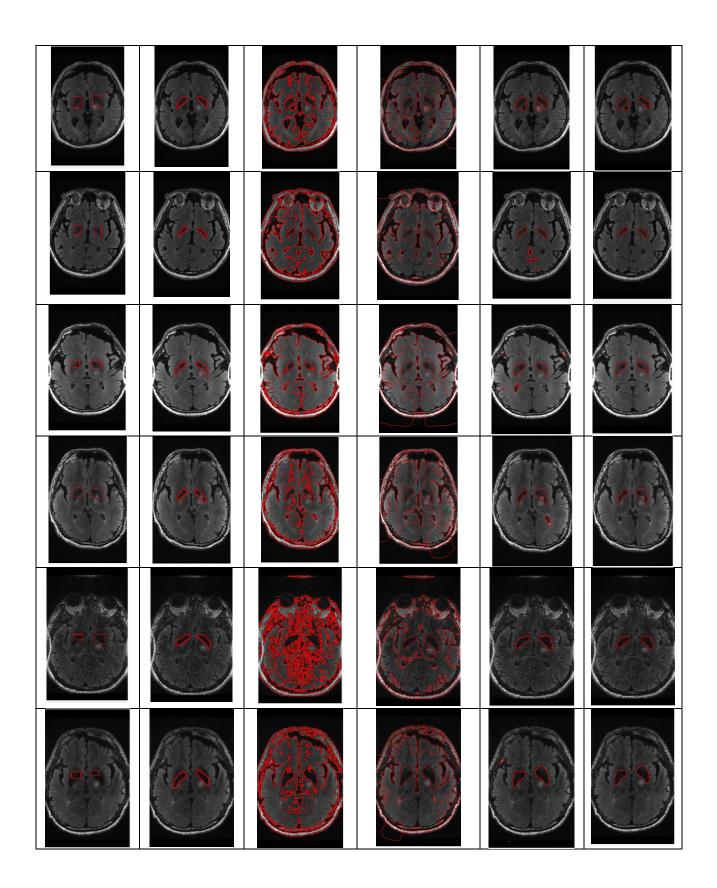
LAMPIRAN-LAMPIRAN Lampiran 1. Hasil Penelitian Inisialisasi Kontur Manual

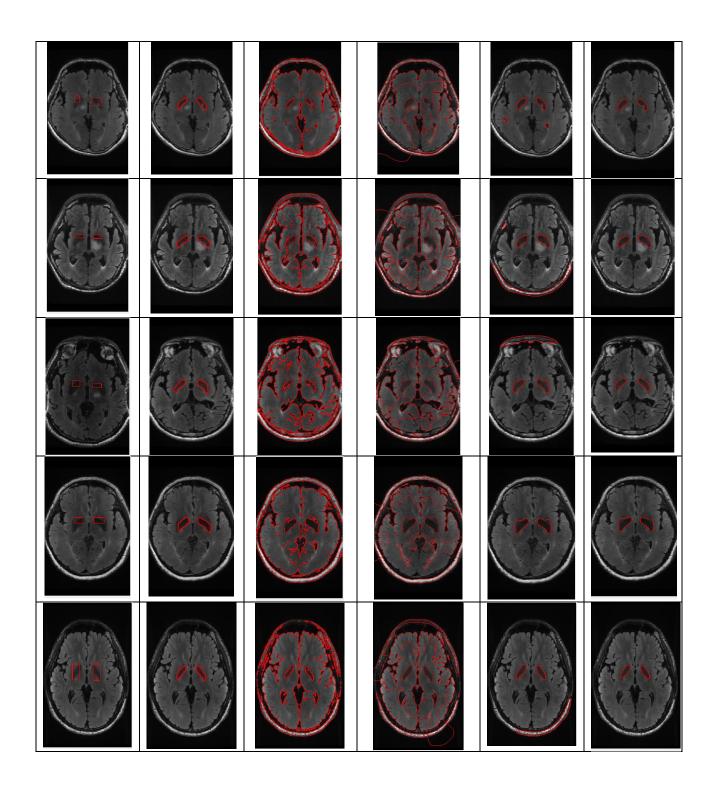
Inisialisasi Kontur	Ground Truth	Metode CV	Metode RSF	Metode LGDF	Metode Usulan
	09				





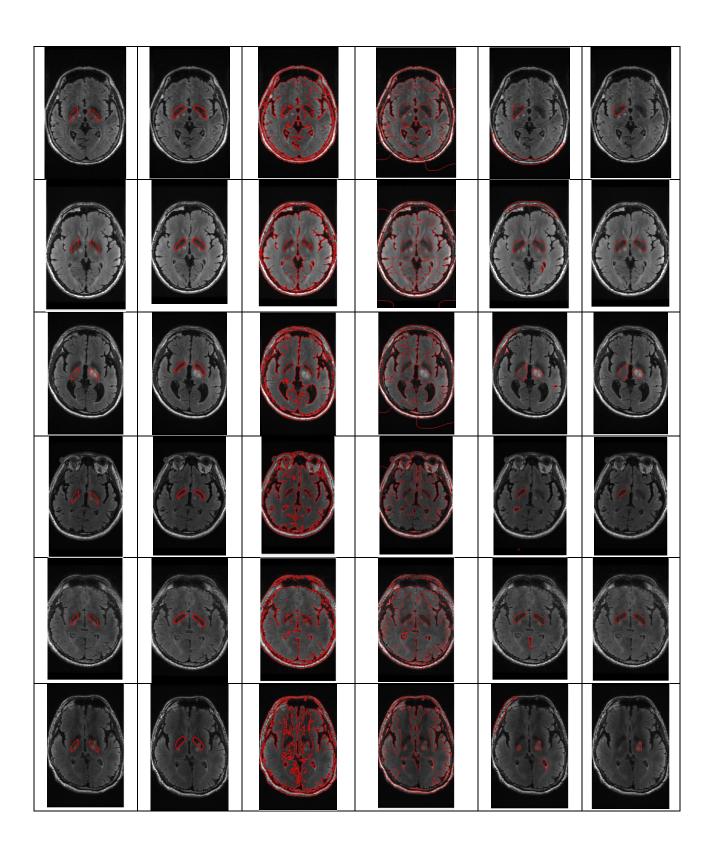


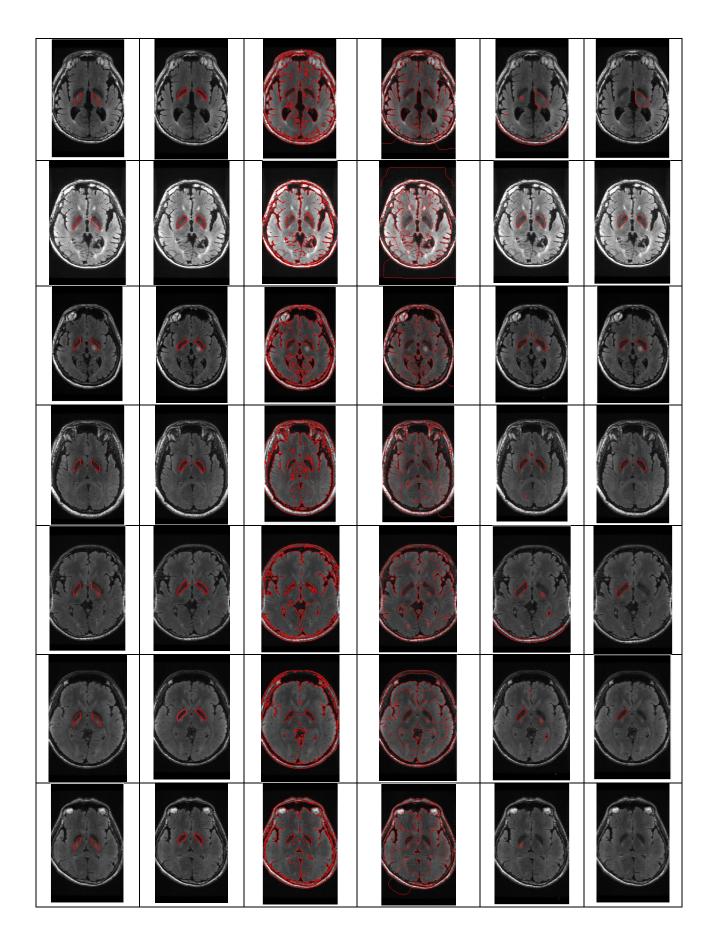


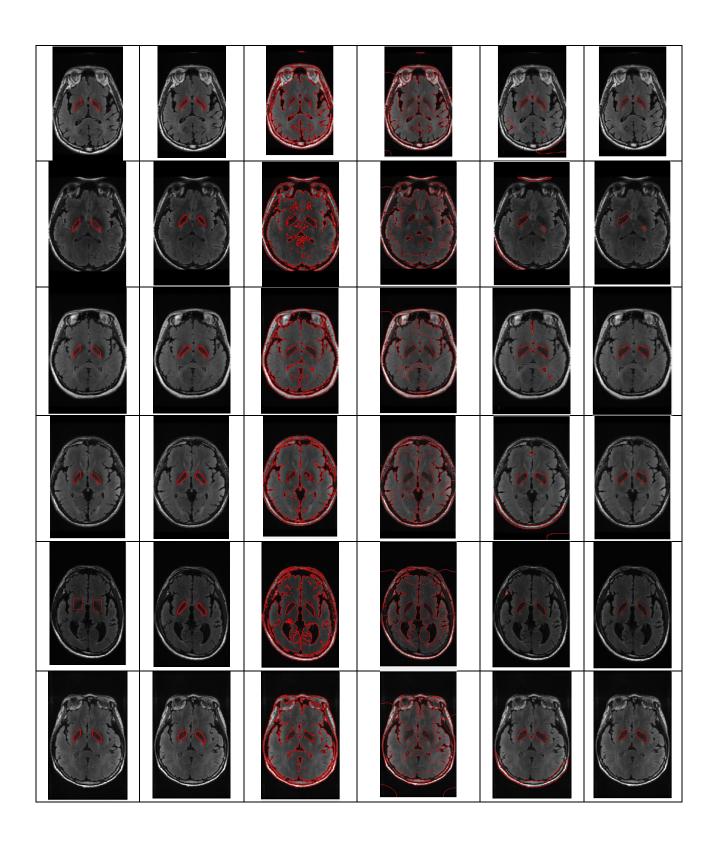


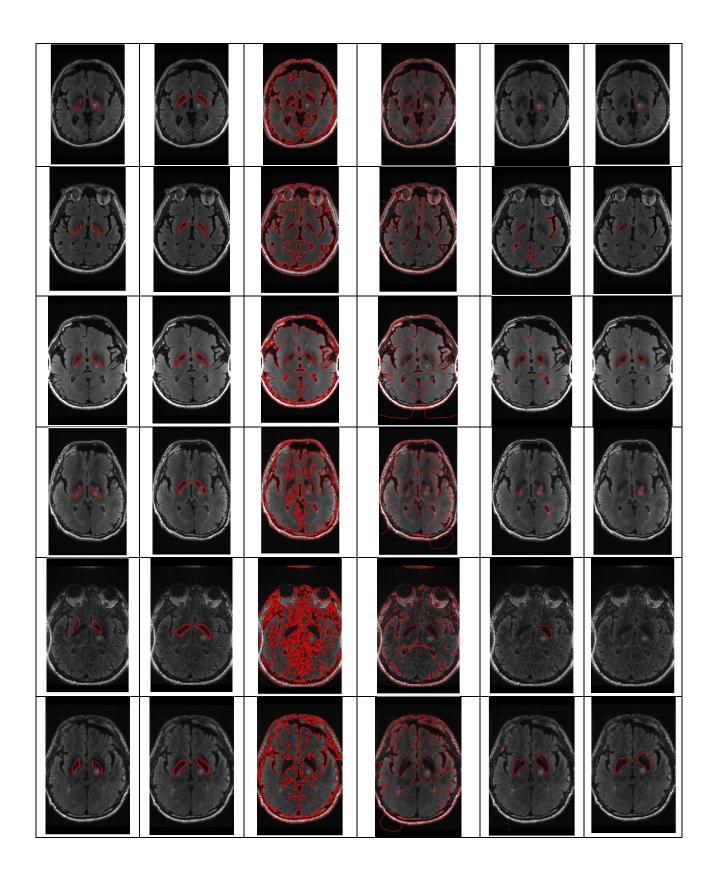
Lampiran 2 Hasil Penelitian Inisialisasi Kontur Otomatis Model Shape Prior

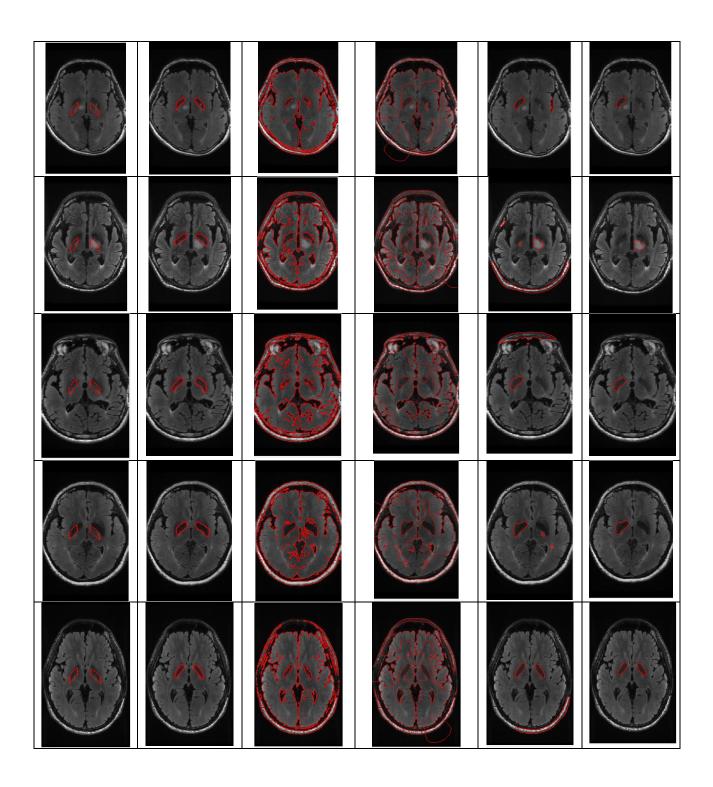
Inisialisasi Kontur	Ground Truth	Metode CV	Metode RSF	Metode LGDF	Metode Usulan
A Contain					
	0				





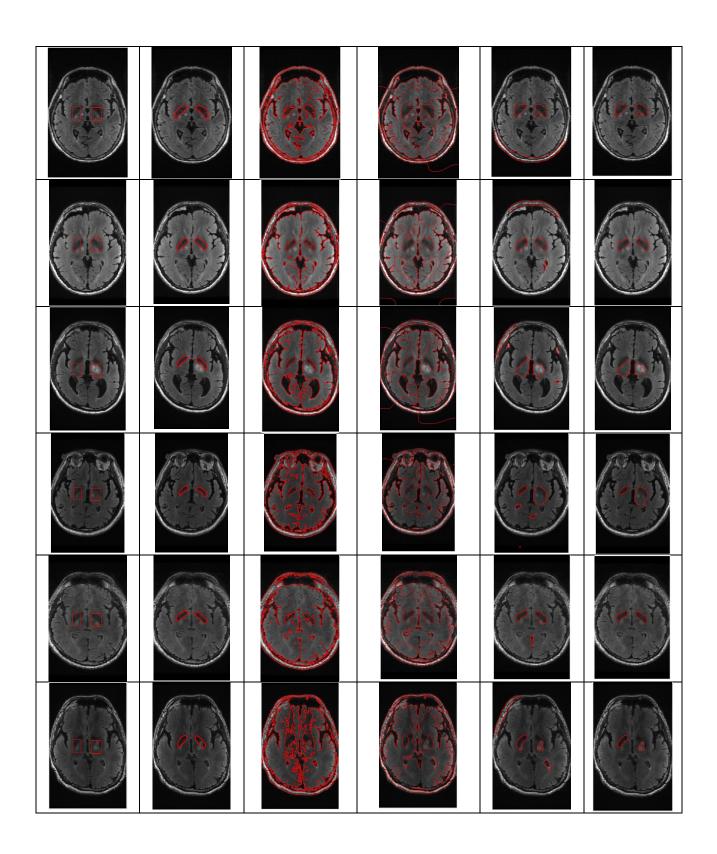


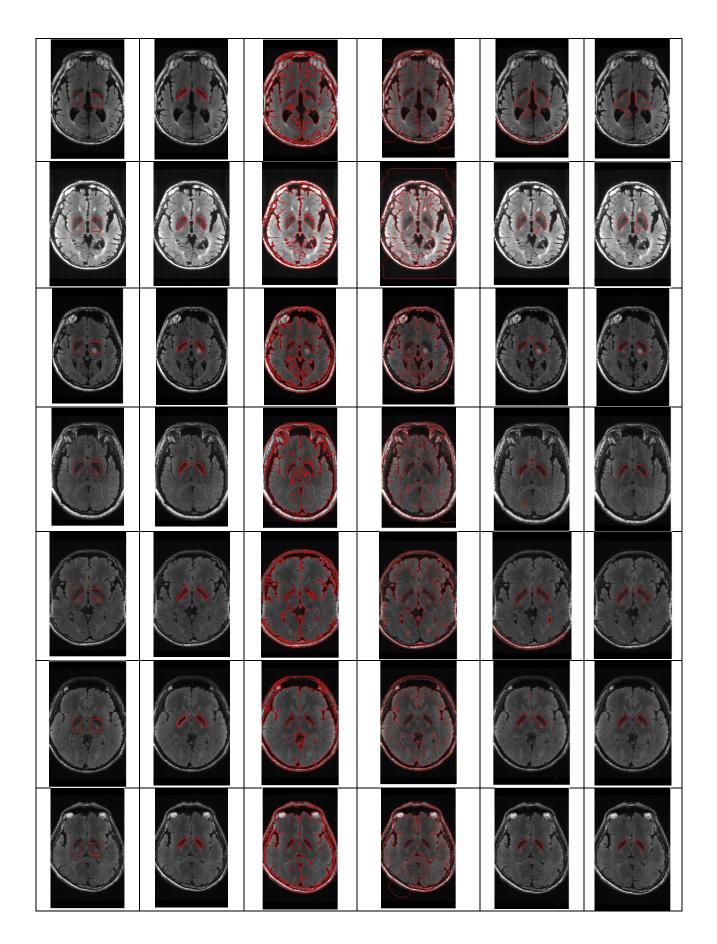


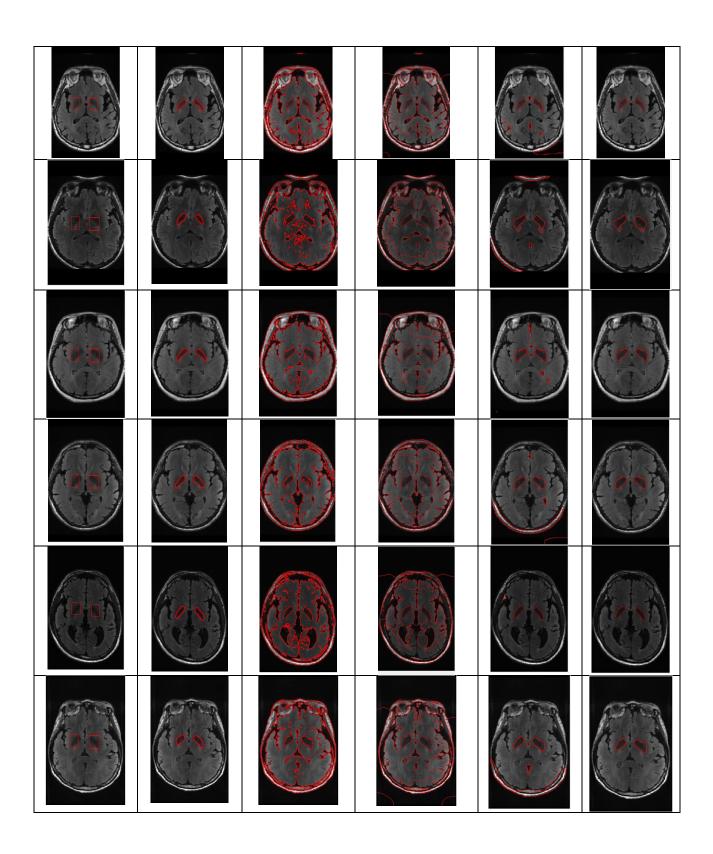


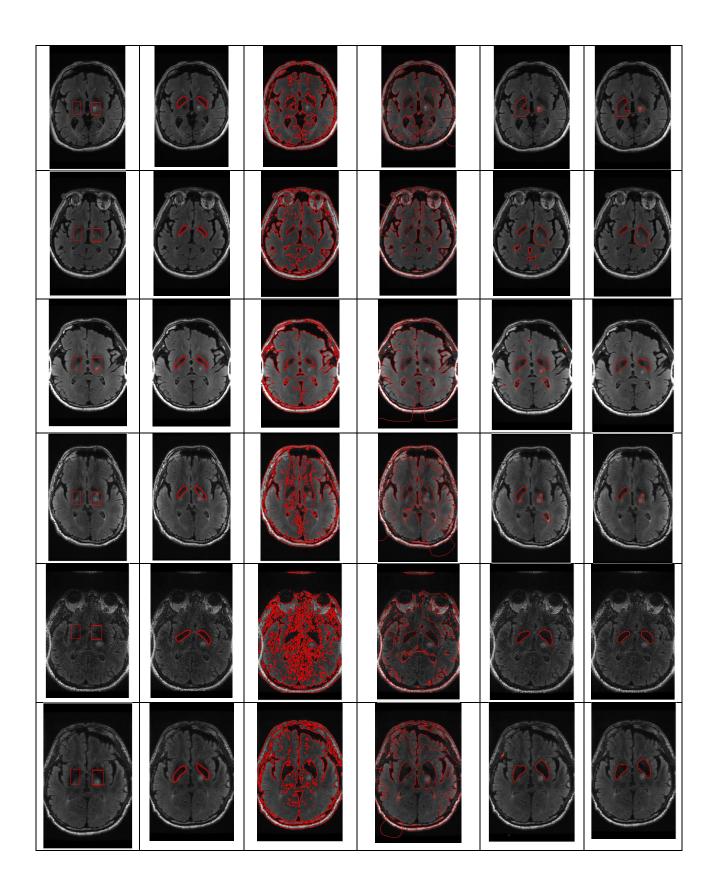
Lampiran 3. Hasil Penelitian Inisialisasi Kontur Otomatis Model Rectangle

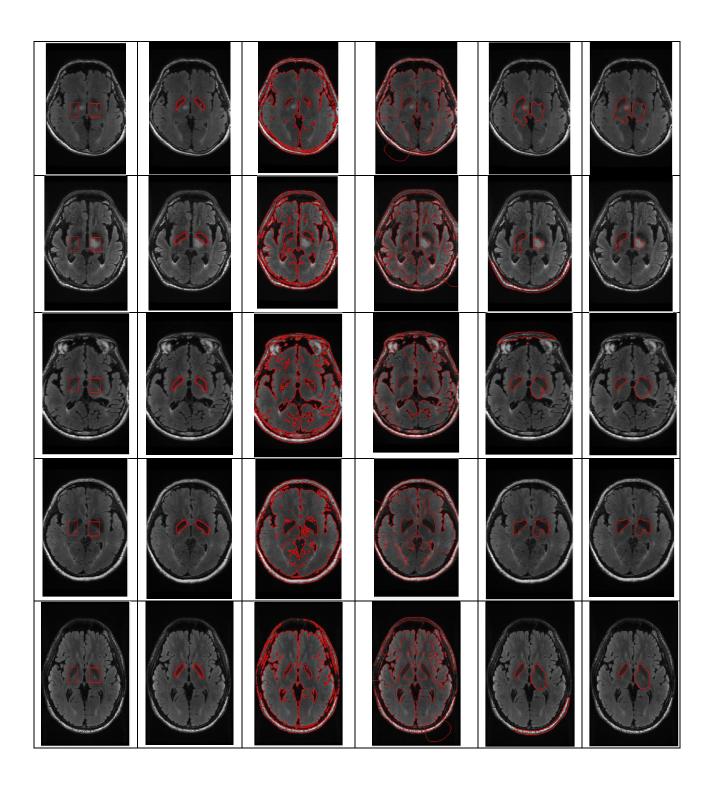
Inisialisasi Kontur	Ground Truth	Metode CV	Metode RSF	Metode LGDF	Metode Usulan
					(a)











BIODATA PENULIS



Yohanes Setiawan merupakan anak pertama yang dilahirkan pada 05 Juni 1995 dari dua bersaudara. Anak dari Gigih Daniel dan Antonia Wiryandari Mokalu. Penulis menempuh pendidikan di TK Santa Elisabet II Surabaya (2000-2001), SDN Gayungan II/423 Surabaya (2001-2007), SMP Santo Yosef Surabaya (2007-2010), SMA Santo Carolus Surabaya (2010-2013), dan Program Studi S1 Matematika, Fakultas Sains dan Teknologi, Universitas Airlangga (2013-2017). Saat menempuh skripsi (Tugas Akhir S1), penulis mengambil minat Matematika Terapan bidang Riset Operasi-Komputasi dan mengangkat topik

tentang *data mining* mengenai klasifikasi demam tifoid dengan *Adaptive Neuro Fuzzy Inference System* (ANFIS), yang mengantarkan penulis pada kegemaran terhadap bidang ilmu komputer dan melanjutkan studi di Pascasarjana Teknik Informatika ITS. Penulis memiliki ketertarikan dalam penelitian pada bidang *Data Mining, Computational Intelligence*, dan *Digital Image Processing*. Penulis dapat dihubungi via email di yoh.set95@gmail.com