

Hochschule Heilbronn  
Fakultät für Informatik

# Masterarbeit Medizinische Informatik

## Segmentierung von Pathologien der Aorta mit deformierbaren Modellen

Katharina Thiel

15.02.2013

### **Referent**

PD Dr. Karl Rohr

### **Korreferent**

Prof. Dr. Rolf Bendl  
Hochschule Heilbronn

**Katharina Thiel:**

*Segmentierung von Pathologien der Aorta mit deformierbaren Modellen*

Masterarbeit Medizinische Informatik  
Hochschule Heilbronn

Bearbeitungszeitraum: 15. Juli 2012 - 15. Februar 2013

**Erklärung:**

Ich versichere, die Masterarbeit selbständig und lediglich unter Benutzung der angegebenen Quellen und Hilfsmittel verfasst zu haben.

Heidelberg, den 15.02.2013

Katharina Thiel



# Zusammenfassung

Die häufigste Todesursache in Deutschland sind Erkrankungen des Herz-Kreislaufsystems. Zwei häufig auftretende Krankheiten sind Aortenaneurysmen und Aortendissektionen. Für die Diagnose und die computerunterstützte OP-Planung wird eine semantische Annotation der präoperativ akquirierten Bilddaten benötigt. Dies wird herkömmlich durch eine manuelle Segmentierung der betroffenen Strukturen erreicht. Mit Verfahren aus der medizinischen Bildverarbeitung, darunter die deformierbaren Modelle, ist es möglich diese Segmentierung weitgehend zu automatisieren.

In dieser Masterarbeit wird ein Verfahren vorgestellt, das mit Hilfe von deformierbaren Modellen eine automatische Segmentierung der Aorta und Aortenpathologien in 2D-CTA-Aufnahmen ermöglicht. Hierfür wurde ein geeignetes deformierbares Modell identifiziert, welches mit üblichen Störungen von CTA-Aufnahmen zurecht kommt. Das Verfahren ist eine Kombination aus den *Dual Snakes* und den *GVF-Snakes* und wird *Dual-GVF-Snakes* genannt. Das Besondere an diesem Verfahren ist, dass nicht nur das Lumen der Aorta und eines Aortenaneurysmas, sondern auch die zwei Lumen einer Aortendissektion gleichzeitig segmentiert werden können. Realisiert wird dies durch eine Unterteilung der Kontur in Segmente mit unterschiedlichen Eigenschaften.

Das in dieser Arbeit vorgestellte Verfahren wurde zur Segmentierung von Objekten in synthetischen und klinischen Bildern angewendet, wobei die klinischen Bilder die Aorta, ein Aortenaneurysma und verschiedene Aortendissektionen beinhalten. Zur Evaluierung wurde das Verfahren mit den *GVF-Snakes* und den *AB-Snakes* verglichen, indem der Abstand zwischen Referenzkonturen und berechneter Konturen ermittelt wurde. Ein Vorteil gegenüber *GVF-Snakes* ist, dass zwei Objekte segmentiert und voneinander unterschieden werden können. Im Gegensatz zu den *GVF-Snakes* und den *AB-Snakes* müssen weniger Parameter eingestellt werden und die Membran zwischen den beiden Lumen der Aortendissektion wird erkannt. Das Verfahren ist robuster gegenüber der Initialisierung und liefert vergleichbare Ergebnisse wie das *GVF-Snakes* Verfahren mit gezielter Initialisierung.



## Danksagung

An dieser Stelle möchte ich mich bei PD Dr. Karl Rohr, dem Leiter der Biomedical Computer Vision Group (BMCV), für die Ermöglichung dieser Masterarbeit bedanken. Ein besonderer Dank geht auch an Dr. Stefan Würz, für die hervorragende Betreuung bei der Erstellung der Arbeit. Auch Simon Eck danke ich für die Unterstützung und Hilfsbereitschaft. Ich bedanke mich bei PD Dr. Hendrik von Tengg-Koblick von der Abteilung Diagnostische und Interventionelle Radiologie der Universität Heidelberg für das zur Verfügung gestellte Bildmaterial.

Weiterhin bedanke ich mich bei allen Personen, die mir durch ihre Unterstützung geholfen haben, diese Arbeit zu erstellen.



# Inhaltsverzeichnis

Abbildungsverzeichnis	IX
Tabellenverzeichnis	XIII
Abkürzungsverzeichnis	XV
<b>1 Einleitung</b>	<b>1</b>
1.1 Motivation . . . . .	1
1.2 Zielsetzung . . . . .	3
1.3 Methode . . . . .	4
1.4 Gliederung . . . . .	4
<b>2 Überblick aktueller Verfahren</b>	<b>5</b>
2.1 Deformierbare Modelle . . . . .	5
2.1.1 Parametrische bzw. explizite Aktive Konturen . . . . .	6
2.1.2 Geometrische bzw. implizite Aktive Konturen . . . . .	6
2.1.3 Geodätische Aktive Konturen ( <i>geodesic Snakes</i> ) . . . . .	8
2.1.4 Statistische Formmodelle . . . . .	9
2.2 Segmentierung von Pathologien der Aorta . . . . .	10
2.2.1 Aortendissektion . . . . .	12
2.2.1.1 Segmentierungsmethoden der Aortendissektion	
13	
2.2.2 Aortenaneurysma . . . . .	15
2.2.2.1 Statistische Verfahren zur Segmentierung von	
abdominalen Aortenaneurysmen . . . . .	16
2.2.2.2 Implizite Aktive Konturen zur Segmentierung	
von abdominalen Aortenaneurysmen . . . . .	17
2.2.2.3 Parametrische Aktive Konturen zur Segmentie-	
rung von abdominalen Aortenaneurysmen . . . . .	19

2.2.2.4	Geodätische Aktive Konturen zur Segmentierung von abdominalen Aortenaneurysmen . . . . .	20
2.3	Vergleich der Verfahren . . . . .	20
2.4	Verwandte Arbeiten . . . . .	24
<b>3</b>	<b><i>Snakes</i>: Stand der Technik</b>	<b>25</b>
3.1	Das klassische Aktive Konturen Modell . . . . .	25
3.1.1	Definition . . . . .	25
3.1.2	Energiefunktionale . . . . .	26
3.1.2.1	Interne Energie . . . . .	26
3.1.2.2	Externe Energie . . . . .	26
3.1.3	Energieminimierung durch Variationsrechnung . . . . .	27
3.1.3.1	Diskretisierung . . . . .	27
3.1.3.2	Vor- und Nachteile der Variationsrechnung . . . . .	29
3.1.4	Weitere Energiefunktionale . . . . .	29
3.1.4.1	Zusätzliche Energien $E_{con}$ . . . . .	29
3.1.4.2	Distanz Energie . . . . .	30
3.1.5	Vor- und Nachteile der klassischen <i>Snakes</i> . . . . .	31
3.1.6	Energieminimierungsverfahren . . . . .	31
3.1.6.1	Erweiterte Variationsrechnung . . . . .	31
3.1.6.2	Dynamische Programmierung . . . . .	32
3.1.6.3	Greedy Algorithmus . . . . .	34
3.1.6.4	<i>Simulated Annealing</i> . . . . .	35
3.1.6.5	Vergleich der Optimierungsverfahren . . . . .	35
3.1.7	<i>3D-Snakes</i> . . . . .	36
3.2	<i>Snakes</i> Varianten . . . . .	36
3.2.1	<i>Balloon Snakes</i> . . . . .	37
3.2.2	<i>Fuzzy Snakes</i> . . . . .	37
3.2.3	<i>B-Snakes</i> . . . . .	39
3.2.4	<i>LSB Snakes</i> . . . . .	40
3.2.5	<i>AB-Snakes</i> . . . . .	40
3.2.6	<i>Ziplock Snakes</i> . . . . .	41
3.2.7	<i>Fourier Snakes</i> . . . . .	42
3.2.8	<i>T-Snakes</i> . . . . .	42
3.2.9	Überblick von <i>Snakes</i> Varianten mit zwei Startkonturen . . . . .	43
3.2.10	<i>Dual Snakes</i> . . . . .	44
3.2.10.1	Algorithmus . . . . .	44

3.2.10.2	Vor- und Nachteile . . . . .	45
3.2.11	<i>Dual-T-Snakes</i> . . . . .	46
3.2.12	Erweiterung der externen Kräfte der <i>Snakes</i> . . . . .	47
3.2.12.1	<i>Gradient vector flow (GVF) Snakes</i> . . . . .	47
3.2.12.2	Veränderungen der externen Energien . . . . .	49
3.2.12.3	Alternative externe Kräfte . . . . .	52
3.2.13	Vergleich der Verfahren . . . . .	52
<b>4</b>	<b>Methode</b>	<b>55</b>
4.1	Motivation . . . . .	55
4.2	Übersicht über das Verfahren . . . . .	58
4.3	<i>GVF-Snakes</i> . . . . .	58
4.3.1	Externe Energie: <i>GVF-Snakes</i> . . . . .	58
4.4	<i>Dual Snakes</i> . . . . .	60
4.4.1	Interne Energie: <i>Dual Snakes</i> . . . . .	61
4.5	Kombination . . . . .	63
4.5.1	Verformung zweier Konturen . . . . .	63
4.5.2	Verformung dreier Konturen . . . . .	63
4.5.3	Berechnung der korrespondierenden Punkte . . . . .	63
4.5.3.1	Berechnung der korrespondierenden Punkte mit zwei Konturen . . . . .	63
4.5.3.2	Berechnung der korrespondierenden Punkte mit drei Konturen . . . . .	66
4.5.3.3	Berechnung der korrespondierenden Punkte mit mehr als drei Konturen . . . . .	67
4.5.4	Abstand zwischen beiden inneren Konturen . . . . .	68
4.5.5	Verformungsprozess . . . . .	69
4.5.5.1	Gesamtenergie . . . . .	69
4.5.5.2	Verringerung der <i>adaptive driving forces</i> . . . . .	72
4.5.5.3	<i>Spring forces</i> und <i>volcano forces</i> . . . . .	73
4.6	Initialisierung . . . . .	73
4.7	Übersicht über Parametereinstellungen . . . . .	74
4.7.1	Matlab-Implementierung von <i>GVF-Snakes</i> . . . . .	75
<b>5</b>	<b>Evaluation und Ergebnisse</b>	<b>77</b>
5.1	Evaluationsziel und Evaluationsmethode . . . . .	77
5.2	Parametereinstellungen . . . . .	79
5.3	Vergleich von manuellen Segmentierungsergebnissen . . . . .	81

5.4	Synthetische Bilder . . . . .	82
5.4.1	Ergebnisse der synthetischen Bilder mit einem Objekt . .	82
5.4.2	Ergebnisse der synthetischen Bilder mit zwei Objekten .	86
5.4.2.1	Ergebnisse <i>GVF-Snakes</i> . . . . .	88
5.4.2.2	Ergebnisse <i>Dual-GVF-Snakes</i> . . . . .	88
5.4.3	Vergleich <i>GVF-Snakes</i> und <i>Dual-GVF-Snakes</i> . . . . .	89
5.4.4	<i>AB-Snakes</i> . . . . .	89
5.5	Klinische Bilder . . . . .	90
5.5.1	Klinische Bilder mit einem Lumen . . . . .	91
5.5.1.1	Ergebnisse <i>GVF-Snakes</i> . . . . .	91
5.5.1.2	Ergebnisse <i>Dual-GVF-Snakes</i> . . . . .	93
5.5.1.3	Vergleich <i>GVF-Snakes</i> und <i>Dual-GVF-Snakes</i> .	93
5.5.2	Klinische Bilder mit zwei Lumen . . . . .	93
5.5.2.1	Ergebnisse <i>GVF-Snakes</i> . . . . .	94
5.5.2.2	Ergebnisse <i>Dual-GVF-Snakes</i> . . . . .	97
5.5.2.3	Ergebnisse der <i>Dual-GVF-Snakes</i> mit zusätzli- chen Kräften . . . . .	99
5.5.2.4	Vergleich <i>GVF-Snakes</i> und <i>Dual-GVF-Snakes</i> .	100
<b>6</b>	<b>Diskussion und Ausblick</b>	<b>103</b>
6.1	Ausblick . . . . .	104

# Abbildungsverzeichnis

1.1	Arten von Aortenaneurysmen (aus <a href="http://www.anatomie-online.com">www.anatomie-online.com</a> ) . . . . .	2
1.2	Aortenaneurysma und Aortendissektion . . . . .	3
2.1	Segmentierung mittels deformierbarer Modelle (aus [46]). . . . .	6
2.2	<i>Level Set</i> Funktion zu unterschiedlichen Zeiten (aus [81]). . . . .	7
2.3	Richtung, in der die Geschwindigkeitsfunktion die Kontur verformt (aus [37]). . . . .	8
2.4	Schematische Abbildung der Aorta mit Abgängen (aus [36]). . . . .	11
2.5	Gefäßwandaufbau einer Arterie (aus [36]) und CTA-Aufnahme einer Aortendissektion. . . . .	12
2.6	Klassifikation der Aortendissektion (aus [67]). . . . .	13
2.7	Segmentierungsergebnisse von Aortendissektionen von Kovács et al. (aus [47]). . . . .	14
2.8	Segmentierungsergebnisse der Aortendissektion von Lee et al. (aus [70]). . . . .	14
2.9	Beispiel eines abdominalen Aortenaneurysma (Wikipedia) . . . . .	15
3.1	Die <i>spring forces</i> werden zu dem gesetzten Punkt hingezogen und die <i>volcano forces</i> stoßen die Kontur weg (aus [68]). . . . .	30
3.2	Realisierungsmöglichkeiten für Aktive Konturen auf 3D-Netzen (aus [50]) . . . . .	37
3.3	<i>Snakes</i> Varianten . . . . .	38
3.4	Regeln zur Berechnung der externen Energie der <i>Fuzzy Snakes</i> (aus [35]) . . . . .	39
3.5	<i>Ziplock Snakes</i> Algorithmus schematisch (aus [72]) . . . . .	41
3.6	Segmentierung einer Tasse mittels der <i>Dual Snakes</i> und der klassischen <i>Snakes</i> (aus [31]). . . . .	46
3.7	Schwierigkeiten bei der Segmentierung einer Aortendissektion . . . . .	46
4.1	CTA-Aufnahmen der Aorta . . . . .	56
4.2	Allgemeiner Überblick des <i>Dual-GVF-Snakes</i> Verfahrens . . . . .	59

4.3	<i>Local shape model</i> für die Berechnung der internen Kräfte (aus [31]) . . . . .	61
4.4	Übersicht über den Verformungsprozess von zwei Konturen . . .	64
4.5	Übersicht über den Verformungsprozess von drei Konturen . . .	65
4.6	Segmenteinteilung und Anordnung von zwei inneren Konturen .	67
4.7	Korrespondierende Punkte . . . . .	68
4.8	Verformungsprozess einer Kontur . . . . .	70
4.9	Energie des Gradientenfeldes und des <i>gradient vector field</i> für die unten abgebildeten Grauwerte eines Bildes . . . . .	71
4.10	Energie der <i>Dual Snakes</i> in Abhängigkeit der Iterationsschritte	72
4.11	Wirkung der <i>volcano forces</i> . . . . .	73
4.12	CTA Aufnahmen der Aorta, Aortenaneurysma und der Aortendissektion mit Initialisierung . . . . .	74
5.1	Testbilder mit unterschiedlichem Rauschen . . . . .	78
5.2	Synthetisch erstelltes Bild mit zwei Objekten . . . . .	78
5.3	Abstand zwischen Konturpunkten . . . . .	79
5.4	Pixelgenaue manuelle und subpixelgenaue automatische Segmentierung . . . . .	80
5.5	Manuell segmentierte Lumen zu unterschiedlichen Zeitpunkten (rote und blaue Kontur); links Segmentierung des wahren Lumens und rechts des falschen Lumens . . . . .	81
5.6	Ergebnisse der Segmentierung von synthetischen Bildern mit einem Objekt; die blaue Kontur ist die Referenzkontur und die rote die automatisch generierte Kontur . . . . .	83
5.7	Ergebnisse der Segmentierung von synthetischen Bildern mit einem Objekt; die blaue Kontur ist die Referenzkontur und die rote die automatisch generierte Kontur . . . . .	84
5.8	Segmentierungsergebnisse der synthetischen Bilder mit <i>GVF-Snakes</i> mit zwei Objekten und drei unterschiedlichen Startkonturen, die unterschiedliche Parametereinstellungen haben, und gleichzeitig erstellte Segmentierungsergebnisse der <i>Dual-GVF-Snakes</i> mit den gleichen Parametereinstellungen . . . . .	87
5.9	Parametereinstellungen der <i>AB-Snakes</i> . . . . .	89
5.10	Segmentierungsergebnisse mit <i>AB-Snakes</i> . . . . .	90
5.11	Segmentierungsergebnis der <i>AB-Snakes</i> eines verrauschten Bildes mit einem <i>gradient threshold</i> 40, 10 Iterationen . . . . .	90
5.12	Ergebnisse der Segmentierung von klinischen Bildern einer Aorta und eines Aortenaneurysmas; die blaue Kontur ist die Referenzkontur und die rote die automatisch generierte Kontur . . .	92

5.13	Ergebnisse der Segmentierung von klinischen Bildern von Aortendissektionen; die blaue Kontur ist die Referenzkontur und die rote die automatisch generierte Kontur . . . . .	95
5.14	Ergebnisse der Segmentierung von klinischen Bildern von Aortendissektionen; die blaue Kontur ist die Referenzkontur und die rote die automatisch generierte Kontur . . . . .	96
5.15	<i>GVF-Snakes</i> : Verformungsprozess der inneren Kontur im Bild Dissektion 1; blaue Kontur: Startkontur; rote Kontur: aktuelle Kontur; grüner Bereich: Bewegung der Kontur von der Startkontur bis zur aktuellen Kontur und der Bereich wird nach jedem Iterationsschritt dunkler . . . . .	97
5.16	<i>Dual-GVF-Snakes</i> : Verformungsprozess der inneren Kontur des falschen Lumens im Bild Dissektion 1 . . . . .	98
5.17	Ergebnisse der Segmentierung des falschen Lumens im Bild Dissektion 3 mittels der <i>GVF-Snakes</i> und der <i>Dual-GVF-Snakes</i> . . . . .	99
5.18	Ergebnis der Segmentierung des Bildes Dissektion 2 mittels der <i>Dual-GVF-Snakes</i> mit <i>spring forces</i> und <i>volcano forces</i> . . . . .	99
5.19	Ergebnis der <i>Dual-GVF-Snakes</i> mit den Positionen der <i>spring forces</i> und der <i>volcano forces</i> . . . . .	100



# Tabellenverzeichnis

2.1	Auflistung aller erwähnten Methoden . . . . .	22
2.2	Vor- und Nachteile der expliziten und der impliziten Aktiven Konturen (aus [21].) . . . . .	23
5.1	Parametereinstellungen . . . . .	80
5.2	Mittelwert und Standardabweichung der manuell segmentierten Konturen in Pixel (px) . . . . .	81
5.3	Parameter der <i>GVF-Snakes</i> . . . . .	82
5.4	Werte der Abstandsberechnung zwischen Referenzkontur und <i>GVF-Snakes</i> bzw. <i>Dual-GVF-Snakes</i> Segmentierung von den synthetisch erstellten Bildern mit einem Objekt in Pixel . . . . .	85
5.5	Werte der Abstandsberechnung zwischen manueller, <i>GVF-Snakes</i> und <i>Dual-GVF-Snakes</i> Segmentierung von den synthetisch er- stellten Bildern mit zwei Objekten in Pixel (px) . . . . .	87
5.6	Werte der Abstandsberechnung zwischen manueller, <i>GVF-Snakes</i> und <i>Dual-GVF-Snakes</i> Segmentierung der klinischen Bilder ei- ner Aorta und eines Aortenaneurysmas in Pixel (px) . . . . .	91
5.7	Werte der Abstandsberechnung zwischen manueller, <i>GVF-Snakes</i> und <i>Dual-GVF-Snakes</i> Segmentierungsergebnissen der Aorten- dissektion in Pixel (px) . . . . .	94



# Abkürzungsverzeichnis

<b>AAA</b>	....	Abdominales Aortenaneurysma
<b>AAM</b>	....	Active Appearance Model
<b>BVF</b>	....	Boundary Vector Field
<b>CT</b>	.....	Computertomographie
<b>CTA</b>	.....	Computertomographische Angiographie
<b>DDGVF</b>	.	Dynamic Directional Gradient Vector Flow
<b>DGVF</b>	...	Directional Gradient Vector Flow
<b>DSA</b>	.....	Digital Subtraction Angiography
<b>EEF</b>	.....	Electric Edge Field
<b>EPGVF</b>	.	Edge Preserving Gradient Vector Flow
<b>FEM</b>	....	Finite Element Method
<b>FVF</b>	.....	Fluid Vector Flow
<b>GDM</b>	....	Geometric Deformable Model
<b>GGVF</b>	...	General Gradient Vector Field
<b>GVF</b>	.....	Gradientenvektorfeld
<b>HG</b>	.....	Hintergrund
<b>LSB</b>	.....	Least Squares B-Spline
<b>MRI</b>	.....	Magnetic Resonance Imaging
<b>MRT</b>	....	Magnet Resonanz Tomographie
<b>NURBS</b>	.	Non-Uniform Rational B-Spline

**px** ..... Pixel  
**SSEF** .... Simulated Static Electric Field  
**VFC** ..... Vector Field Convolution

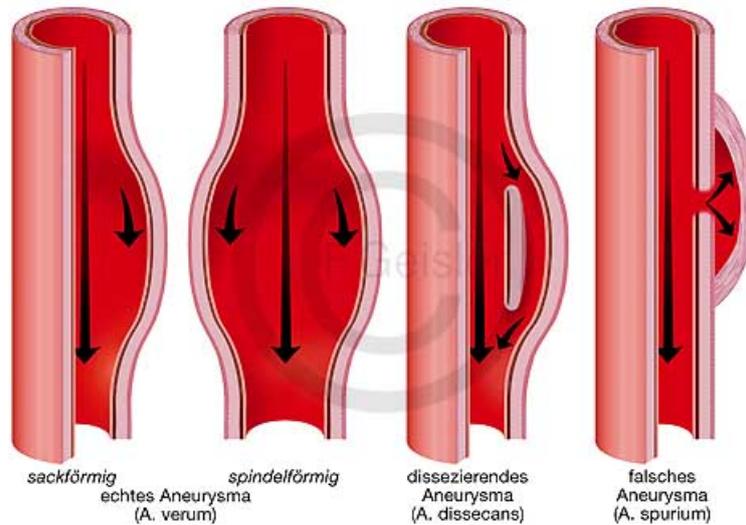
# Kapitel 1

## Einleitung

### 1.1 Motivation

Die häufigste Todesursache in Deutschland ist die Erkrankung des Herz-Kreislaufsystems. Die meisten krankhaften Veränderungen lassen sich dabei auf eine Arteriosklerose zurückführen. Die Arteriosklerose ist eine Systemerkrankung der Schlagadern, die die arteriellen Gefäße zunehmend in Folge von Ablagerungen von Blutfetten, Thromben, Bindegewebe und in geringeren Mengen auch Kalk in den Gefäßwänden verengt. Gleichzeitig führt sie zu einer "Regulationsstörung des Gefäßtonus, was letztlich eine Mangeldurchblutung von Gewebe und Organen zur Folge hat."([36]). Sie kann sich über Jahrzehnte symptomlos entwickeln und wird meist erst dann diagnostiziert, wenn der Patient an Thrombose, Herzinfarkt, Schlaganfall, Ischämie oder Angina pectoris erkrankt. Desweiteren wird von Huch und Jürgens [36] beschrieben, dass arteriosklerosebedingte Herz-Kreislauf-Erkrankungen zu den häufigsten Todesursachen in Industriestaaten zählen. Auch das Aneurysma, eine spindel- oder sackförmige, permanente Erweiterung von Blutgefäßen infolge von Wandveränderungen, entsteht häufig auf Grund einer Arteriosklerose. Größe und Form des Aneurysmas können stark variieren. Aneurysmen werden unterteilt in „wahre“ Aneurysmen (*Aneurysma verum*), in „falsche“ Aneurysmen (*Aneurysma falsum* bzw. *spurium*) und in dissezierende Aneurysmen (*Aneurysma dissecans*) (s. Abbildung 1.1). Beim *Aneurysma verum* werden alle Schichten der Aorta erweitert und beim *Aneurysma spurium* entwickelt sich nach einem Riss in der Aortenwand eine Bindegewebskapsel.

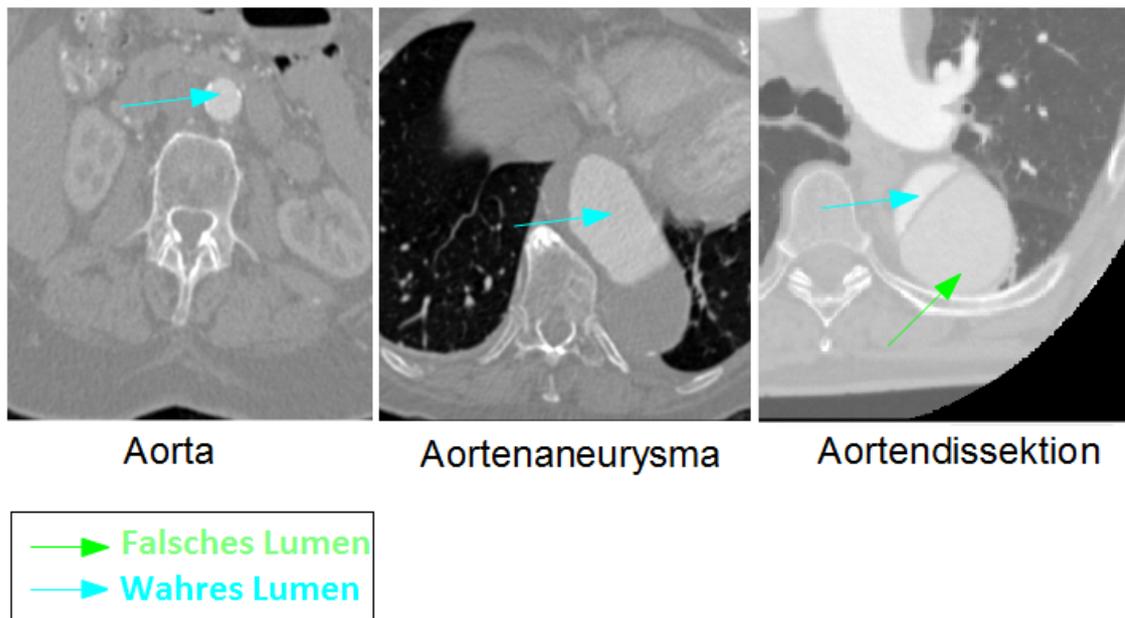
Das *Aneurysma dissecans* ist ein Spezialfall der Aortendissektion, da es aus einem bestehenden *Aneurysma verum* entsteht. Bei der Aortendissektion reißt die innere Schicht der Aorta (*Tunica intima*) und Blut tritt zwischen der *Tunica intima* und der mittleren Schicht, der *Tunica media*, ein. Da das Gefäß unter hohem Druck steht, kommt es zu einer longitudinalen Aufspaltung der *Tunica media*. Es entsteht ein künstlicher Raum, der auch falsches Lumen



**Abbildung 1.1:** Arten von Aortenaneurysmen (aus [www.anatomie-online.com](http://www.anatomie-online.com))

genannt wird. Sowohl beim Aortenaneurysma als auch bei der Aortendissektion besteht eine erhöhte Gefahr einer Ruptur.

Sowohl beim Aneurysma als auch bei der Dissektion (s. Abbildung 1.2) ist es für den Arzt meist schwierig auf Grund der Symptomatik eine Diagnose zu stellen. Bei einem gesundheitlich stabilen Patienten werden computertomographische Angiographie Aufnahmen (CTA-Aufnahmen) der Aorta durchgeführt. Für eine kontrastreichere Aufnahme der Aorta wird dem Patienten ein Röntgenkontrastmittel injiziert. Ärzte nutzen CTA-Aufnahmen aber nicht nur um Diagnosen zu stellen, sondern um die Aortenpathologie zu lokalisieren und weitere Schritte der Behandlung, wie z.B. die Operationsplanung, einzuleiten. Unterstützt werden sie insbesondere bei der Segmentierung der Aorta durch Methoden der qualitativen Bildanalyse. Schwierigkeiten bei der Segmentierung sind die unterschiedlichen Formen der Aortenpathologien, Intensitätsschwankungen, ein schwacher Kantenkontrast und damit Lücken in den Objektkonturen. Ein weiteres Problem ist, dass Aortenpathologien und Knochen in CTA-Aufnahmen eine ähnliche Bildintensität haben und nahe aneinander liegen. Einfache Schwellwertverfahren zur Segmentierung von Aortenpathologien sind daher problematisch. Auch gibt es Probleme bei der Segmentierung mit Standardverfahren wie beispielsweise dem *Region Growing Verfahren* und dem *Watershed-Algorithmus*. Da die Kontur nicht durch einen anderen Intensitätswert abgegrenzt ist, kann das *Region Growing Verfahren* die Grenzen der Kontur überschreiten. Der *Watershed-Algorithmus* und das Schwellwertverfahren segmentieren fälschlicherweise weit entfernt liegende Gebiete mit, die nicht relevant sind und daher nachher entfernt werden müssen (vgl. [37]). Gute Ergebnisse kann eine manuelle Segmentierung liefern. Dieses Verfahren ist aber mit hohem Zeitaufwand verbunden, besonders wenn der Benutzer die Bilder



**Abbildung 1.2:** Aortenaneurysma und Aortendissektion

eines 3D Datensatzes Schicht für Schicht segmentieren soll.

In der medizinischen Bildverarbeitung werden zur Segmentierung von Objekten häufig deformierbare Modelle eingesetzt. Diese Modelle ermöglichen es, dass durch Integration von a priori Wissen über die Form und andere Merkmale, wie Objekttexturen und die Farbe, ein Objekt segmentiert werden kann. Eine Segmentierung kann damit als Auffinden derjenigen Modellinstanz aufgefasst werden, die am besten die Werte eines vorliegenden Bildes unter Berücksichtigung der Modellinformation erklären kann[46]. Mathematisch gesehen sind deformierbare Modelle iterative Verfahren, die ausgehend von einer manuell oder automatisch erzeugten Startkontur durch Energienminimierung verformt werden und nach einem Gleichgewichtszustand suchen.

## 1.2 Zielsetzung

Ziel dieser Arbeit ist es ein deformierbares Modell zu identifizieren, anzupassen, zu erweitern und zu evaluieren, so dass

- CTA-Aufnahmen von Aortenpathologien möglichst genau und mit einem möglichst hohen Automatisierungsgrad segmentiert werden, um zeitaufwendige Benutzerinteraktionen zu vermindern und reproduzierbare Ergebnisse zu liefern
- übliche Störungen von CTA-Aufnahmen kompensiert werden

- Aortenpathologien wie Aortenaneurysmen und Aortendissektionen segmentiert werden
- der Benutzer durch zusätzliches a priori Wissen in die Lage versetzt wird, die Ergebnisse interaktiv zu verbessern.

### 1.3 Methode

Zum Erreichen der Zielsetzung wurden die klassischen expliziten Aktiven Konturen wie folgt weiterentwickelt:

- Kombination der *GVF-Snakes* und *Dual Snakes* zu den *Dual-GVF-Snakes*
- gleichzeitige Segmentierung von zwei Objekten, indem
  - die Kontur in Segmente aufgeteilt wird
  - die spezifischen Kräfte der *Dual Snakes*, die *adaptive driving forces*, zwischen den Lumen modifiziert werden.

### 1.4 Gliederung

Die Arbeit gliedert sich in sechs Kapitel. Nach der Einleitung wird in Kapitel 2 erläutert, was deformierbare Modelle sind und welche Verfahren bei der Segmentierung von den Aortenpathologien Aneurysma und Dissektion verwendet werden. Diese zur Segmentierung verwendeten Verfahren sind die *Active Shape Models*, die impliziten, die expliziten und die geodätischen Aktiven Konturen.

In Kapitel 3 werden die mathematischen und algorithmischen Grundlagen der parametrischen Aktiven Konturen erläutert. Da diese aber in ihrer klassischen Form einige Probleme aufweisen, werden verschiedene Erweiterungen der *Snakes* vorgestellt und erläutert. In Kapitel 4 wird das verwendete Verfahren mit den Erweiterungen der ursprünglichen Methoden erläutert. Das Verfahren ist eine Kombination der *Dual Snakes* und *GVF-Snakes* und wird *Dual-GVF-Snakes* genannt. Die erzielten Ergebnisse und die Eigenschaften der Parameter werden in Kapitel 5 illustriert. Die Ergebnisse der Segmentierung werden mit einer manuellen Segmentierung und den *GVF-Snakes* verglichen. Abschließend wird das Verfahren in Kapitel 6 kritisch beleuchtet und mögliche Verbesserungen des entwickelten Verfahrens ausblickend vorgeschlagen.

# Kapitel 2

## Überblick aktueller Verfahren

### 2.1 Deformierbare Modelle

„Die Form von Objekten stellt für die menschliche Perzeption das wichtigste Erkennungsmerkmal dar“[100]. Doch Objekte haben nicht immer die gleiche Form, sie weisen Variabilitäten auf. Der Mensch kann auf Grund seiner Erfahrungen und Kenntnisse erkennen, um welches Objekt es sich handelt. In der Bildverarbeitung ist das nicht so einfach, da auf Grund von Bildeigenschaften nicht immer das gesuchte Objekt richtig erkannt werden kann. Für die Objekterkennung wurden vor allem inkrementelle Verfahren entwickelt, die Konturen iterativ verformen und sich an die Form eines Objektes anpassen können. In der medizinischen Bildverarbeitung spielen verschiedene deformierbare Modelle eine wichtige Rolle, da Formen der gesuchten Objekte variabel sein können. Außerdem weisen die Aufnahmen je nach Modalität Rauschen, Intensitätsschwankungen, einen schwachen Kontrast und damit Lücken in den Objektgrenzen auf. Auch können Objekte, die nicht segmentiert werden sollen, ähnliche Eigenschaften wie das gesuchte Objekt haben und statt des gesuchten Objektes segmentiert werden (vgl. [46]). Kohnen [46] beschreibt die Segmentierung mittels deformierbarer Modelle als „Auffinden derjenigen Modellinstanzen [...], die am besten die Werte eines vorliegenden Bildes unter Berücksichtigung der Modellinformationen erklären können“.

In Abbildung 2.1 wird die Segmentierung mittels deformierbarer Modelle schematisch dargestellt. Es wird a priori Wissen, wie Form und Textur, und es werden Eigenschaften des Bildes, wie Gradienten, Texturen und Farben, für die Deformationsvorschrift verwendet. Das Ergebnis ist eine statische Objektpräsentation. Im Folgenden werden vier relevante deformierbare Modelle beschrieben, die für die Segmentierung von den Aortenpathologien Dissektion und Aneurysma verwendet werden.

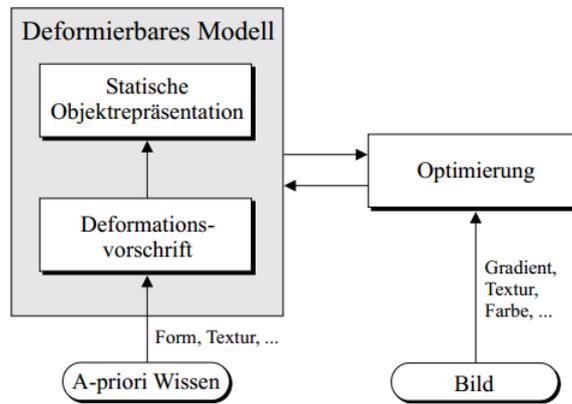


Abbildung 2.1: Segmentierung mittels deformierbarer Modelle (aus [46]).

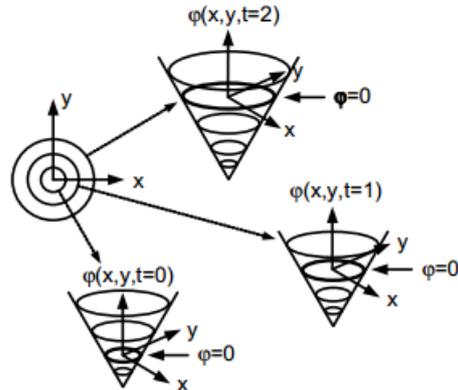
### 2.1.1 Parametrische bzw. explizite Aktive Konturen

Die expliziten bzw. parametrischen Aktiven Konturen, auch *Snakes* genannt, wurden als mathematisches Modell für deformierbare Kurven zunächst zur Konturfindung bzw. Merkmalsextraktion in der digitalen Bildverarbeitung konzipiert. Entwickelt wurde die ursprüngliche Form 1988 von Kass et al. [40]. In einem Optimierungsverfahren wird durch Auffinden eines Minimums eine Kontur gesetzt, die möglichst genau der Kontur eines gesuchten Objektes entspricht. Hierfür werden zum einen *interne* Kräfte definiert, welche bewirken, dass bestimmte Anforderungen an die Form (beispielsweise die Glattheit) erfüllt werden und zum anderen *externe* Kräfte, die die Kontur zu starken Beträgen des Gradienten des Bildes ziehen. Ein Vorteil der *Snakes* ist, dass Vorwissen berücksichtigt werden kann und verrauschte Bilder und Objekte mit Lücken segmentiert werden können.

Der ursprüngliche Algorithmus hat aber nach Ströble [84] zwei wesentliche Probleme: das Initialisierungs- und das Topologieproblem. Das Initialisierungsproblem tritt auf, wenn die Startkontur zu weit von dem gesuchten Objekt entfernt gesetzt wird und beim Optimierungsverfahren ein lokales Minimum findet. Eine Änderung der Topologie der Kontur, wie zum Beispiel das Trennen und Zusammenfügen, ist nicht möglich. Im Abschnitt 3.1 werden die expliziten Aktiven Konturen weiter erläutert.

### 2.1.2 Geometrische bzw. implizite Aktive Konturen

Entwickelt wurden die impliziten Aktiven Konturen, auch geometrische Aktive Konturen genannt, zeitgleich mit den expliziten Aktiven Konturen im Jahre 1988 von Osher und Sethian [74]. Diese Methode stellt „eine bedeutende Alternative zum herkömmlichen *Snakes*-Ansatz dar“ [42]. Sie sind eine numerische Methode zur Verfolgung der Entwicklung einer Kurve, die *propagating front*



**Abbildung 2.2:** *Level Set* Funktion zu unterschiedlichen Zeiten (aus [81]).

genannt wird. Kerschner vergleicht die *propagating front* mit krümmungsabhängiger Geschwindigkeit mit einer Flammenfront bei einem Flächenbrand. Es folgt dem Huygensschen Prinzip, das besagt, dass wenn ein Partikel verbrannt ist, kann es nicht wieder entfacht werden [42]. Übertragen in die Bildverarbeitung bedeutet dies, wurde ein Pixel einmal ausgeschlossen, wird dieser nicht noch einmal untersucht, ob er zur Kontur gehört.

Ausgehend von der Startkontur, dem *Zero-Level-Set*, und einer Umgebung, die in ein skalares Feld abgebildet wird, werden die Verschiebung und Verformung der Kontur mit Hilfe der sogenannten *Level Set* Funktion berechnet:

$$\psi = \psi(\vec{x}, t) \quad (2.1)$$

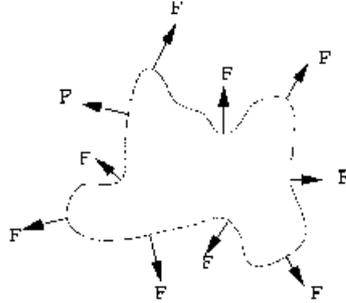
Die Funktion nimmt negative Werte innerhalb des Objektes an, positive Werte außerhalb des Objektes und den Wert 0 auf der Kontur des Objektes. Der Funktion wird eine räumliche und eine zeitliche Komponente zugeordnet, so dass die Bewegung der Kontur beschrieben werden kann (vgl. [59]).

Abbildung 2.2 zeigt, „wie ein wachsender Kreis mittels einer *Level Set* Funktion modelliert werden kann. Der Kreis wird zu drei Zeitpunkten illustriert“ (s. [38]).

Die grundlegende Bewegungsgleichung, also die *Level Set* Gleichung, ist die folgende partielle Differentialgleichung

$$\psi_t + F |\nabla \psi| = 0 \quad (2.2)$$

wobei  $F$  die Geschwindigkeitsfunktion (Speed-Funktion) ist und  $\nabla$  der Gradient. Die Geschwindigkeitsfunktion „teilt“ jedem Kurvenpunkt mit, wie schnell er sich in Richtung des Normalenvektors bewegt. Repräsentiert wird die Wirkung der Geschwindigkeitsfunktion in der Abbildung 2.3. In der ursprünglichen Form enthält die Geschwindigkeitsfunktion nur einen krümmungsabhängigen



**Abbildung 2.3:** Richtung, in der die Geschwindigkeitsfunktion die Kontur verformt (aus [37]).

Term. Die Geschwindigkeitsfunktion wurde aber weiterentwickelt, indem zusätzliche Terme ergänzt wurden, sodass zum Beispiel die Geschwindigkeit in der Nähe von starken Bildkanten oder Linien reduziert wird oder die Kontur gleichmäßig durch einen zusätzlichen *Balloonterm* wächst.

Die *Level Sets* haben den Vorteil, dass sich die Topologie der Kurve während der Entwicklung verändern kann und dass die Methode starke Einbuchtungen und komplexere Formen besser segmentieren kann. Die Geschwindigkeit an starken Krümmungen nimmt zwar ab, aber durch eine große Anzahl von Iterationen nähert sich die Kurve den Objektgrenzen mit starker Krümmung an (vgl. [42]).

Auf der anderen Seite sind die *Level Set* Methoden rechenintensiv, was nach Kainmüller [38] an der Repräsentation des Verfahrens liegt, da nicht wie bei den impliziten Aktiven Konturen eine Menge von Stützpunkten neu berechnet wird, sondern eine höher dimensionale Funktion auf einen Bildbereich. Die hohe Rechenintensität kann durch die *Fast-Marching-* und *Narrow-Band-* Methode reduziert werden (vgl. [81]).

Außerdem ist es schwierig zusätzliche Kräfte hinzuzufügen, was bei stark verrauschten Bildern oder Objekten mit Lücken notwendig sein kann. So tendiert die Kontur dazu an Konturlücken “auszulaufen”. Bei einigen Bildern mit hohem Rauschanteil ist eine Vorverarbeitung notwendig, damit die Kontur nicht an verrauschten Stellen stehenbleibt. Eine Vorverarbeitung bedeutet aber auch, dass eine unbekannte Ungenauigkeit eintritt.

### 2.1.3 Geodätische Aktive Konturen (*geodesic Snakes*)

Die geodätischen Aktiven Konturen wurden von Caselles et al. [11] 1997 entwickelt. Das Verfahren basiert auf der Beziehung zwischen den expliziten Aktiven

Konturen und der Berechnung von Geodäten, die die kürzeste Strecke zwischen zwei Punkten darstellen, bzw. der Berechnung der minimalen Distanzkurven. Die minimalen Distanzkurven liegen im Riemannschen Raum, dessen Metrik auf Grundlagen der Bildeigenschaften definiert ist. Dieser geodätische Ansatz bietet die Möglichkeit das Optimierungsverfahren der expliziten Aktiven Konturen und das *Level Set* Verfahren gleichzeitig zu verwenden. Vorteil dieses Verfahrens ist, dass sich Konturen aufteilen und zusammenfügen können, so dass mehrere Objekte gleichzeitig erfasst werden können (vgl. [11]).

### 2.1.4 Statistische Formmodelle

Auch die statistischen Formmodelle (*statistical shape models*, SSMs) haben sich in der medizinischen Bildverarbeitung für die Segmentierung von Objekten etabliert. Die bekanntesten Varianten sind das *Active Shape Model* und das *Active Appearance Model* (vgl. [34]).

Cootes und Taylor [19] haben 1992 ein Verfahren entwickelt, das globales Formwissen durch statistische Analyse einer Trainingsdatenmenge in ein Modell integriert. Dieses Modell wird *Active Shape Model* genannt und ist prädestiniert für Objektszenarien, bei denen die Form der Objekte wesentliches Identifikationsmerkmal ist, die Bilder komplexe und damit variierende Hintergründe enthalten, das Objekt undeutliche, schwache und zum Teil nicht sichtbare Kanten besitzt und das Objekt sinnvolle a priori Informationen über Formvariationen und Kantenstrukturen enthält (vgl. [46]).

Das *Point Distribution Model* (PDM) ist ein Modell, das Formvariationen repräsentiert, welche aus Testdatensätzen generiert werden. Dabei wird jedes Trainingsbeispiel durch einen Vektor  $\mathbf{x}$  beschrieben, der die Koordinaten von  $n$  Landmarken enthält. Damit das Modell auch eine hohe Spezifikation hat, kann die Form des Bildobjektes auf die Rotation, Translation und Skalierung des Modells angepasst werden. Auf die Menge der Formenvektoren  $\mathbf{x}_i$  wird eine *Principal Component Analyse* (PCA), auch Hauptachsentransformation genannt, angewendet um die Anzahl der Trainingsdaten zu reduzieren. Dafür wird die Kovarianzmatrix  $\mathbf{S}$  benötigt:

$$\mathbf{S} = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \quad (2.3)$$

wobei  $\bar{\mathbf{x}}$  die Durchschnittsform ist. Aus der Kovarianzmatrix  $\mathbf{S}$  werden die Eigenvektoren  $\phi_i$  berechnet und nach deren Eigenwerten sortiert (vgl. [34]). Die Eigenwerte  $\phi_i$  stellen die Eigenschaften von Formvariationen, die in den Bildern vorhanden sind, bereit. Jede Form, die in der Trainingsdatenmenge vorhanden ist, kann mit  $\mathbf{x} = \bar{\mathbf{x}} + \Phi \mathbf{b}$  dargestellt werden. Dabei sind  $\Phi = (\phi_1 | \phi_2 | \dots | \phi_i)$  die Eigenvektoren, die eine Form beinhalten und  $\mathbf{b}$  ist der Modellparametervektor, der den Beitrag jedes Modells gewichtet (vgl. [46]).

Die Anpassung des Modells an die Daten erfolgt mit Hilfe eines Optimierungsverfahrens. Die Knotenpunkte werden iterativ „entlang des Normalenvektors in Richtung des höchsten Gradienten unter den Constraints des Formmodells verschoben“ (s. [46]), bis der Algorithmus eine Konvergenz erreicht hat.

Da das *Active Shape Model* nur in der Lage ist lokale Grauwertinformationen in das Modell mit einfließen zu lassen, haben Cootes et al. [18] das Modell zu dem *Active Appearance Model* weiterentwickelt. Sie beziehen die gesamten Bildinformationen (oder Texturen) des Objektes mit ein (vgl. [34]).

Das klassische Modell kann komplexe Formen anhand von wenigen Parametern segmentieren. Doch das Verfahren hat einige Nachteile. So wird eine große Anzahl von Trainingsdaten benötigt, je komplexer eine Form eines Objektes ist. Beim klassischen Verfahren fließt als Bildinformation nur der Bildgradient mit ein und es wird nur ein lokales Optimierungsverfahren verwendet (s. [46]).

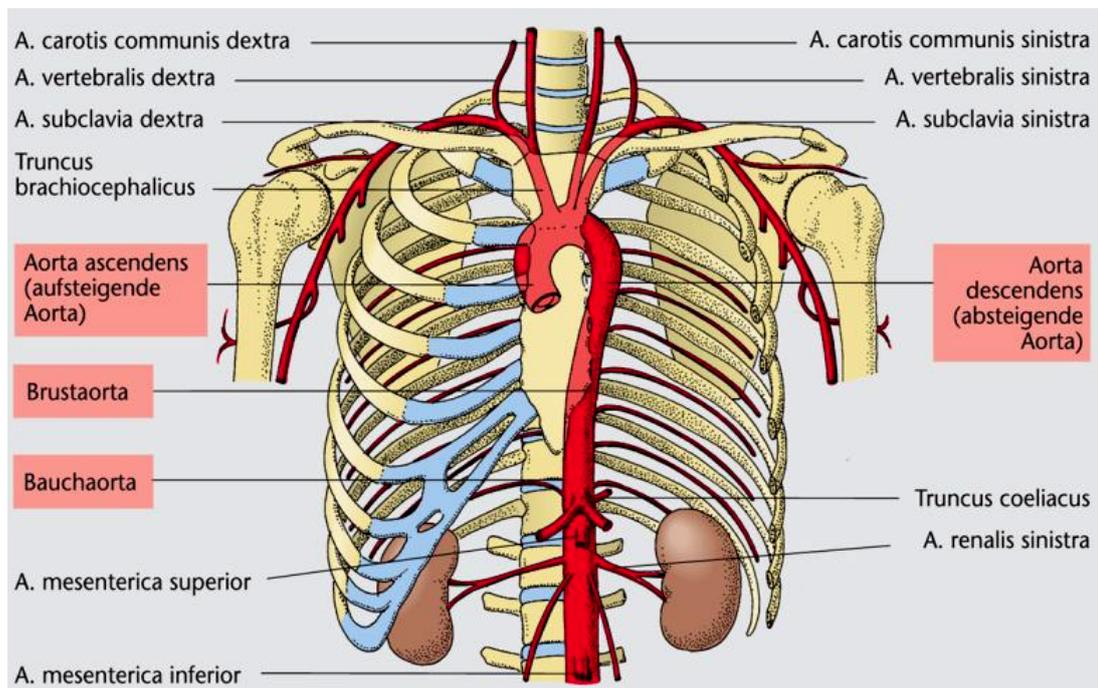
## 2.2 Segmentierung von Pathologien der Aorta

Die Aorta ist die Hauptschlagader des menschlichen Körpers. Sie entspringt aus der linken Seite des Herzens und leitet das Blut aus der linken Herzkammer in den großen Blutkreislauf. In Abbildung 2.4 werden schematisch die Aortenabschnitte, die zur Orientierung dienen, dargestellt. Ausgehend vom Herzen steigt die Aorta auf (*Aorta ascendens*) und verläuft im Bogen oberhalb der *Truncus pulmonalis*, einer herznahen Arterie. Anschließend steigt die Aorta ab, dieser Abschnitt heißt *Aorta descendens* (vgl. [36]).

Die Wand der Aorta bzw. aller Arterien bestehen aus drei Wandschichten (s. Abbildung 2.5), die einen Hohlraum umschließen, der Gefäßlumen genannt wird (Lumen bezeichnet die lichte Weite eines Hohlorgans [36]). Die *Tunica Intima*, kurz *Intima*, ist die innerste Schicht der Arterienwand und dient dem Stoffaustausch zwischen Blut und umliegendem Gewebe. Die *Tunica Media* ist die mittlere Schicht der Arterienwand und sie reguliert den Blutfluss durch Muskelkontraktion. Die äußere Schicht ist die *Tunica Adventitia*. Sie schließt das Gefäß nach außen hin ab (vgl. [24]).

Unter anderem gibt es folgende Erkrankungen der Aorta:

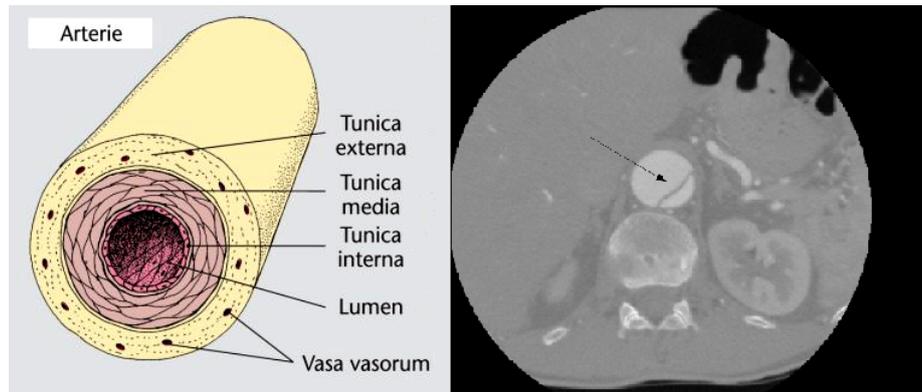
- die Arteriosklerose (ist eine zunehmende Verengung des Lumens und führt zu einer Regulationsstörung des Gefäßtonus, was eine Mangeldurchblutung von Gewebe und Organen verursacht (vgl. [36]))
- die Stenose (Verengung der Aorta)
- Dissektion (Einriss der Aortenwand und anschließende Aufspaltung der Aortenwand)
- Thrombus (Blutgerinnsel in der Aorta)



**Abbildung 2.4:** Schematische Abbildung der Aorta mit Abgängen (aus [36]).

- Aneurysma (spindel- oder sackförmige Erweiterung des Querschnitts der Aorta).

Für die Diagnose, Therapieplanung und Kontrolle von Aortenerkrankungen ist eine Segmentierung der Aorta beispielsweise in CTA-Aufnahmen nötig. Mit den Segmentierungsergebnissen können quantitative Aussagen über das Objekt, wie zum Beispiel Durchmesser und Oberfläche, abgeleitet werden. Nicht bei jedem Patienten ist gleich eine Operation notwendig, daher müssen immer wieder die Risiken abgewägt werden. Eine Arteriosklerose wird meistens durch blutverdünnende Medikamente behandelt. Bei den Aortenpathologien der Stenose, der Dissektion und dem Aneurysma werden nach Abwägung der Risiken entweder ein Stent gesetzt, ein medizinisches Implantat, das in den Hohlraum eingebracht wird, um es offen zu halten, oder der Aortenabschnitt ersetzt. Für die Bestimmung der Größe und Form des Stents und des zu ersetzenden Aortenabschnittes werden Segmentierungen der aktuellen Aorta benötigt (vgl. [94], [82] und [32]). Ein Thrombus kann durch eine konservative Therapie mit Kompression und Antikoagulation oder durch eine operative Therapie behandelt werden (vgl. [15]). In dieser Arbeit wird ein Segmentierungsverfahren entwickelt, das die Pathologien des Aortenaneurysmas und der Aortendissektion segmentiert (s. Kapitel 4).



**Abbildung 2.5:** Gefäßwandaufbau einer Arterie (aus [36]) und CTA-Aufnahme einer Aortendissektion.

### 2.2.1 Aortendissektion

“Eine Dissektion der Aorta entsteht, wenn die Gefäßintima einreißt und Blut fließt zwischen die *Intima* und die Gefäßmedia. Da das Blut unter hohem Druck steht, kommt es zu einer longitudinalen Aufspaltung der *Media* über weite Strecken. Bei der Dissektion entstehen funktionell zwei Gefäßlumina, ein wahres Lumen, das von der normalen *Gefäßintima* begrenzt wird, und ein falsches Lumen, das von der *Media* und der *Adventitia* begrenzt wird” [69]. In Abbildung 2.5 ist eine axiale 2D CTA-Aufnahme einer Aortendissektion abgebildet. Man erkennt eine Membran zwischen dem wahren und falschen Lumen.

Die Stelle, an der die Intima einreißt, wird als *Entry* bezeichnet. Das Blut strömt durch das *Entry* ins falsche Lumen und kann das richtige Lumen verdrängen oder verlegen. Hält die Intima dem Druck des Blutes nicht stand, reißt die Intima an einer anderen Stelle wieder auf und das Blut fließt von dem falschen Lumen wieder in das richtige Lumen. Dieser Riss wird *Reentry* genannt.

Die Aortendissektion kann in zwei Klassifikationen eingeteilt werden (s. Abbildung 2.6). Nach De Bakey und seinen Mitarbeitern wurden die Aortendissektionen nach der Lokalisation des *Entrys* und der Lage des falschen Lumens in die Typen: Typ I, Typ II und Typ III unterteilt. Nach der Stanford-Klassifikation werden die Aortendissektionen in Typ A und Typ B eingeteilt, die angeben, in welchem Bereich der Aorta sich das *Entry* befindet (vgl. [67]).

Die Segmentierung der Aortendissektion erfolgte beispielsweise durch Kovács et al. [47] und Lee et al. [70] und wird im folgenden Abschnitt erläutert.

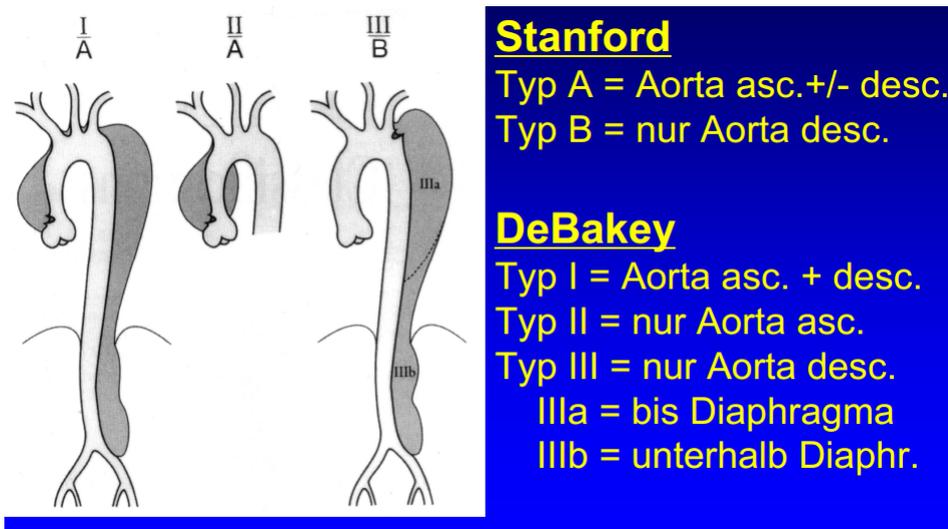
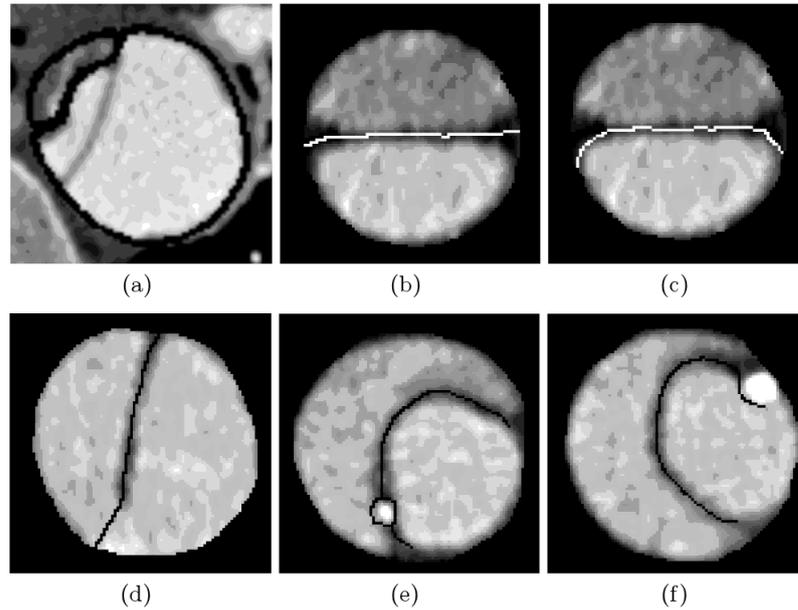


Abbildung 2.6: Klassifikation der Aortendissektion (aus [67]).

### 2.2.1.1 Segmentierungsmethoden der Aortendissektion

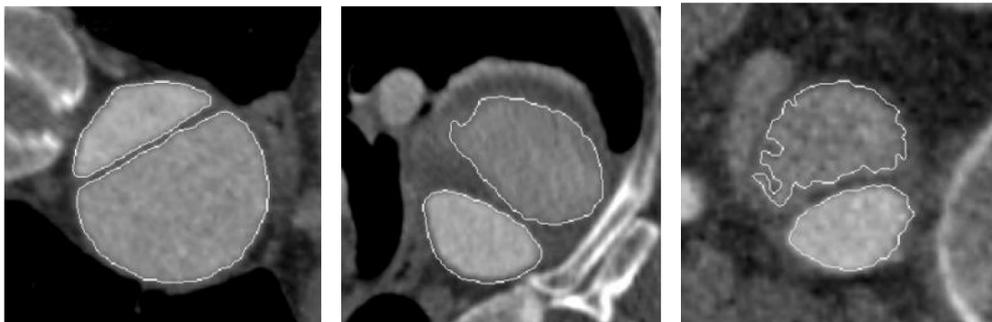
Kovács et al. [48] segmentierten mit Hilfe der Hough Transformation und eines deformierbaren Modells die Aorta in CTA-Aufnahmen. Die Methode segmentiert ausschließlich die Oberfläche der Aortenwand einer Dissektion. Das wahre und das falsche Lumen werden nicht voneinander getrennt. Die Hough Transformation wird verwendet um in jeder Schicht die kreisrunde Form der Aorta vorzusegmentieren. Anschließend wird mit einem elastischen deformierbaren Masse-Feder-Modell die Segmentierung verbessert. Daher ist nach Angaben von Kovács et al. das Verfahren robust gegenüber inhomogener Verteilung des Kontrastmittels in CTA-Aufnahmen und es ist robust gegenüber der Membran der Aortendissektion, die das falsche vom wahren Lumen separiert. Das beschriebene Verfahren wurde von Kovács et al. [47] weiterentwickelt um damit die Membran zwischen dem wahren und dem falschen Lumen segmentieren zu können. Nachdem die Aortenwand segmentiert ist, wird die Aorta zur Vereinfachung entlang der Mittellinie begradigt und die Membran wird in jeder Schicht mit Hilfe des Descoteaux's Maßes der Bogenhaftigkeit [23] gesucht. Dabei wird für jeden Punkt der Schichtaufnahmen im Bereich der Aorta die Wahrscheinlichkeit berechnet, dass der Punkt zur Membran gehört. Falls die Methode die Membran nicht vollständig detektiert hat, wird eine Extrapolation mit Hilfe von *Snakes* durchgeführt. Für die externe Energie wird dabei das Gradientenvektorfeld verwendet, das in Abschnitt 3.2.12.1 erläutert wird. Die Ergebnisse der Segmentierung in 2D Schichten sind in Abbildung 2.7 dargestellt. Man erkennt, dass der Algorithmus die Membran in den meisten Fällen gefunden hat und die Linie, die das wahre und falsche Lumen voneinander separiert, in



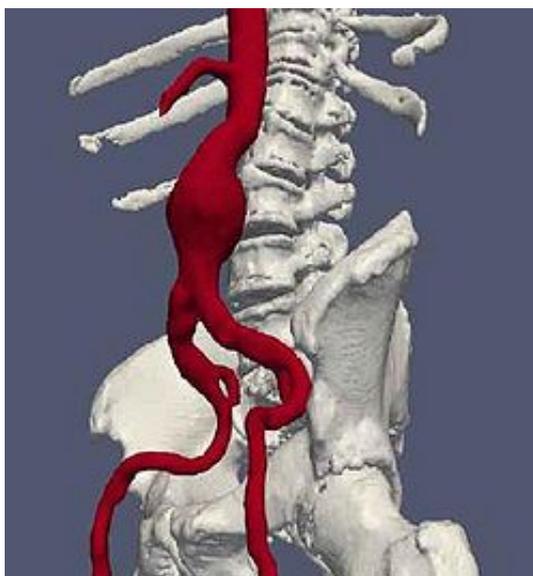
**Abbildung 2.7:** Segmentierungsergebnisse von Aortendissektionen von Kovács et al. (aus [47]).

der Membran liegt. Bei diesem Verfahren wurden die beiden Lumen aber nicht genau segmentiert, sondern nur mit einer Linie voneinander getrennt.

Lee et al. [70] verwenden zur Segmentierung von Aortendissektionen in CTA-Aufnahmen ein hybrides Lernverfahren, das generatives und diskriminatives Lernen mit einer Multi-Skalen Wavelet Analyse und einem probabilistischen Modellabgleich kombiniert. In Abbildung 2.8 ist zu erkennen, dass das wahre und falsche Lumen separat voneinander segmentiert worden sind.



**Abbildung 2.8:** Segmentierungsergebnisse der Aortendissektion von Lee et al. (aus [70]).



**Abbildung 2.9:** Beispiel eines abdominalen Aortenaneurysma (Wikipedia)

### 2.2.2 Aortenaneurysma

Das Aneurysma, auch Arterienerweiterung oder umgangssprachlich arterielle Aussackung genannt, ist eine spindel- oder sackförmige, lokalisierte, permanente Erweiterung von Blutgefäßen infolge angeborener oder erworbener Wandveränderungen.

Unterschieden werden folgende Formen des Aneurysmas: das Aneurysma verum und Aneurysma spurium. Ein Aneurysma verum (“echtes Aneurysma”) entsteht meist als Folge einer Arteriosklerose und ist eine Erweiterung aller drei Schichten der Gefäßwand. Je größer das Aneurysma wird, desto größer ist die Gefahr einer Ruptur. Bei einem Aneurysma spurium werden zwei Schichten der Aortenwand, die Intima und die Media, getrennt und nur die *Adventia* bleibt erhalten. Um den Einriss entwickelt sich ein Hämatom, das sich nach einer langfristigen stabilen Tamponade zu einer Bindegewebskapsel entwickelt (vgl. [32]).

Weiterhin wird das Aneurysma entsprechend der Lage in das Thorax Aortenaneurysma (TAA), welches in der Höhe des Thorax liegt, und in das abdominale Aortenaneurysma (AAA) unterteilt, das sich in der Höhe des Bauchraumes befindet und damit nur die absteigende Aorta betrifft. Das abdominale Aortenaneurysma wird in der Abbildung 2.9 dargestellt.

Im Folgenden werden Segmentierungsverfahren des abdominalen Aortenaneurysmas vorgestellt, welche vorher erwähnten deformierbaren Modellen, die in den Abschnitten 2.1.1 bis 2.1.4 beschrieben werden, verwenden: die statistischen Verfahren, die impliziten, expliziten und geodätischen Aktiven Konturen.

### 2.2.2.1 Statistische Verfahren zur Segmentierung von abdominalen Aortenaneurysmen

De Bruijne et al. [20] verwenden für die Segmentierung von 3D CTA-Aufnahmen von abdominalen Aortenaneurysmen einen statistischen Ansatz, der auf einer Modifikation des *Active Shape Models* beruht. Für das Verfahren wurde eine Trainingsdatenbank von AAA generiert, die spezielle Formen und deren Eigenschaften gespeichert hat. Die Eigenschaften der CTA-Aufnahmen eines Aneurysmas werden mit den Aneurysmen der Datenbank verglichen und eine Kontur wird nach Vorlage des bekannten Aneurysmas in das Bild gesetzt. Die Segmentierung erfolgt Schicht für Schicht. De Bruijne et al. gehen davon aus, dass die aktuelle Schicht ähnlich der nachfolgenden Schicht ist, sodass nicht in jeder Schicht nach einer ähnlichen Kontur in der Trainingsdatenbank gesucht werden muss. Falls Fehler bei der Segmentierung auftauchen, kann der Benutzer diese nachträglich manuell korrigieren.

Die Problematiken dieses Verfahrens sind, dass die Testdatenbank auf Grund der vielen unterschiedlichen Formen, die das AAA annehmen kann, eine große Anzahl von Datensätzen enthalten muss, damit möglichst wenig Fehler bei der Segmentierung auftreten. Auch kann die Abweichung zur gesuchten Kontur immer größer werden, da das Verfahren die Kontur der vorherigen Schicht nimmt. Daher muss der Bereich der Abweichungen möglichst klein gehalten werden. Eines von sechs Ergebnissen weicht so stark von der gesuchten Objektkontur ab, dass eine manuelle Verbesserung notwendig ist, wobei größere Konturen weniger Fehler aufweisen als kleinere Konturen.

Greiner et al. [29] setzen das *Active Appearance Model* (AAM) zur Segmentierung der äußeren Kontur von Aortenaneurysmen in Schichten der CTA-Aufnahmen ein. Für die genaue Bestimmung der äußeren Kontur der Aortenaneurysmen werden dem Verfahren auch Informationen des Randbereichs zur Verfügung gestellt. Wie auch de Bruijne verwendet Greiner die Ähnlichkeit von benachbarten Bildern in CTA-Schichtaufnahmen. Daher wird das Aneurysma im ersten Schichtbild manuell segmentiert und das Ergebnis im benachbarten Bild als Initialisierungskontur verwendet. Für die Evaluierung wurden statistische Modelle aus Schichten von neun CTA-Datensätzen trainiert und mit Hilfe eines *Leave-One-Out* Testes überprüft. Auch hier kann das Problem auftreten, dass die beim Training gewonnenen Informationen zur Parameteroptimierung nicht ausreichend sind.

Olabarriaga et al. [73] verwenden zur Segmentierung der Oberfläche von Aortenaneurysmen und speziell der Thromben in CTA-Aufnahmen die *Snakes*, die mit einem zusätzlichen Energieterm, der durch ein nichtparametrisches statistisches *grey level appearance model* berechnet wird, bestimmt wird. Der Benutzer setzt die Startkontur und es wird eine Initialisierung durch ein

Grau-Level-Modell erstellt. Für die genaue Segmentierung wird entlang der Normalen die Initialisierungskontur berechnet, wie wahrscheinlich es ist, dass ein Punkt innerhalb oder außerhalb des Objektes liegt. Das verwendete Klassifikationsverfahren ist eine k-nächste-Nachbar Methode. Da man auch hier eine große Testdatenbank benötigt um alle Eventualitäten abzudecken, kann es sein, dass die Ergebnisse ungenau sind.

### 2.2.2.2 Implizite Aktive Konturen zur Segmentierung von abdominalen Aortenaneurysmen

Subašić et al. [85] verwenden für die Segmentierung von 3D CTA-Aufnahmen von abdominalen Aortenaneurysmen ein *Level Set* Verfahren. Subašić et al. haben versucht ein Verfahren zu entwickeln, dass die innere Aortenwand auf Grund eines hohen Kontrastes gute Segmentierungsergebnisse liefert, aber die äußere Aortenwand einen niedrigen Kontrast hat und damit schwierig zu erkennen und zu segmentieren ist. Im ersten Schritt wird die CTA-Aufnahme für die Segmentierung der äußeren Wand mit morphologischen Operatoren vorverarbeitet, damit die Initialisierung nahe der gesuchten Kontur gesetzt werden kann. Die weiteren Schritte werden für innere und äußere Aortenwand angewandt. Subašić et al. benutzen eine kantenbasierte *Level Set* Methode mit der Geschwindigkeitsfunktion

$$F = k(x, y, z)(v_0 - \varepsilon\kappa(x, y, z)) \quad (2.4)$$

wobei  $v_0$  eine konstante Geschwindigkeitskomponente ist, die auf eins gesetzt wird, damit die Kontur wächst.  $\kappa$  ist der Krümmungsfaktor und  $\varepsilon$  ein Gewichtungsfaktor.  $k$  ist ein Terminierungskriterium. Das Ergebnis der Segmentierung wird, falls Lücken in der Aufnahme innerhalb der Kontur des Objektes vorzufinden sind, mit morphologischen Operatoren verbessert. Da die Anwendung der *Level Sets* in 3D einen hohen Rechenaufwand hat, wird der Algorithmus mit zwei Techniken beschleunigt: *multiresolution image representation* und *motion tracking-based selective geometric deformable model updating*.

Die Initialisierung der Kontur muss nicht in der Nähe des gesuchten Objektes liegen und die Größe der kugelförmigen Initialisierung ist auch nicht wichtig, solange die Initialisierung innerhalb des Objektes ist. Die Ergebnisse vergleichen Subašić et al. mit einer Segmentierung eines Radiologen. Die Schlussfolgerung ist, dass die automatisch segmentierten Oberflächen signifikante Ähnlichkeiten mit den manuell segmentierten Oberflächen haben.

Zhuge et al. [99] haben ein voll automatisches Segmentierungsverfahren mit der *Level Set* Methode entwickelt, das um zwei Analysen erweitert wird. Mit dem Verfahren werden, wie auch schon in den vorherigen Verfahren, 3D

CTA-Aufnahmen von abdominalen Aortenaneurysmen segmentiert. Die Vorverarbeitung des Bildes erfolgt mit einem anisotropen Diffusionsfilter, der das Bild glättet und Kanten erhält. Danach wird eine globale Regionenanalyse und eine lokale Eigenschaftsanalyse durchgeführt. Die globale Regionenanalyse sucht das Lumen mit Hilfe von Informationen der Intensität, des Volumens und der Form. Anschließend wird untersucht, ob ein Aneurysma vorhanden ist. Die lokale Eigenschaftsanalyse wird verwendet um weitere Informationen über die Wahrscheinlichkeit, ob ein Konturpunkt zu dem Aneurysma gehört oder nicht, bereit zu stellen. Die Ergebnisse werden anschließend für das *Level Set* Verfahren angewendet.

Vorteil dieses Verfahrens ist, dass es ein voll automatisches Segmentierungsverfahren ist. Wie gut das Verfahren ist, können die Autoren schlecht einschätzen, da selbst die Ärzte bei einigen Bildpixeln nicht entscheiden können, ob der Pixel zum Aneurysma gehört oder nicht. Ein Nachteil ist, dass das Verfahren kein vollständiges 3D Verfahren ist, da die globale Regionenanalyse, die lokale Eigenschaftsanalyse und das Setzen der Initialisierung in den 2D Schichten stattfinden.

Kim et al. [44] verwenden zur Segmentierung des Aneurysmas ein implizites Aktives Konturen Modell mit einer morphologischen Gradientenkantenfunktion. Diese morphologische Gradientenkantenfunktion löst das Problem des "Auslaufens" der Kontur, da die Kontur an der Zielkontur stehenbleibt. Vorverarbeitet wird das Bild mit einem hybriden Medianfilter, der Rauschen glättet, aber Kanten verstärkt. Der Nachteil dabei ist, dass zu der hohen Berechnungszeit des *Level Set* Verfahrens die Berechnung der Vorverarbeitung kommt.

Demirci et al. [22] verwenden ein hybrides deformierbares Modell für die 3D Segmentierung von CTA-Aufnahmen des abdominalen Aortenaneurysmas. Das hybride deformierbare Modell beinhaltet sowohl lokale als auch globale Bildinformationen und kombiniert diese mit Form-Constraints. Für die Darstellung der Segmentierung werden NURBS-Oberflächen und Distanzfunktionen verwendet. Demirci et al. schreiben, dass die Methode gute Ergebnisse liefert. Trotzdem sind Nachbearbeitungen des Ergebnisses notwendig, die nach Aussagen von Ärzten akzeptabel sind.

Nakhjavanlo et al. [71] verwenden zur Segmentierung von 3D CTA-Aufnahmen des AAAs und des TAAs die *Level Set* und den anisotropen Diffusionsfilter, der die Aufnahmen glättet, um das Rauschen zu minimieren, und Kanten erhält. Die verwendeten kantenbasierten *Level Sets* wurden von Li et al. [56] entwickelt. Dieses Verfahren eliminiert die Reinitialisierung und verkürzt damit die Rechenzeit. Das Verfahren wird mit den klassischen und den regionenbasierten *Level Sets* verglichen. Dabei zeigt sich, dass das neue Verfahren

gegenüber Bildrauschen robuster ist und die Rechenzeit verkürzt. Doch auch in diesem Verfahren werden einige Kanten nicht erkannt und damit irrelevante Regionen mitsegmentiert.

### 2.2.2.3 Parametrische Aktive Konturen zur Segmentierung von abdominalen Aortenaneurysmen

Giachetti und Zanetti [27] verwenden zur Segmentierung von AAAs in CTA-Aufnahmen die *Fourier Snakes* (s. Abschnitt 3.1.7). Die Segmentierung der Datensätze erfolgt auf jeder Schicht der CTA-Aufnahmen und die Ergebnisse müssen anschließend interpoliert werden. Das Verfahren der *Fourier Snakes* wurde innerhalb der europäischen Studie AQUATICS entwickelt. Weniger als 5% der Ergebnisse benötigen eine manuelle Nachbearbeitung. Ein Nachteil dieses Verfahrens ist, dass die Segmentierung in 2D Schichten erfolgt.

Lu et al. [60] segmentieren sowohl die innere Aortenwand (Lumen) als auch die äußere Wand, die einen Thrombus enthält. Dafür werden CT-Datensätze mit thorakalen Aortenaneurysmen verwendet. Im ersten Schritt wird die Gefäßmittellinie bestimmt. Dafür werden vom Benutzer zwei Punkte gesetzt, die sich vor und hinter dem Aneurysma befinden, und ausgehend von den Startpunkten wird dann mit dem Dijkstra-Algorithmus, der zur Bestimmung eines kürzesten Pfades in einem gewichteten Graphen zuständig ist, die Mittellinie berechnet. Ausgehend von der Mittellinie wird die Kontur des Lumens mit Hilfe von radial nach außen führenden Strahlen ermittelt. Für die Segmentierung des Thrombus wird für die Initialisierung die Lumensegmentierung benutzt und vergrößert. Anschließend werden die klassischen *Snakes* verwendet, die in Abschnitt 3.1 genauer beschrieben werden. Probleme treten auf, wenn die äußere Aortenwand unterschiedlich weit von der inneren Aortenwand entfernt ist.

Kang et al. [39] verwenden zur Segmentierung von normalen Gefäßen, Aneurysmen und Stenosen die Erweiterung der *Snakes* und benennen ihr Modell als *Active Tube Model*. Die 3D Segmentierung wird auf *digital subtraction angiography* (DSA) Aufnahmen angewendet. Die Initialisierung erfolgt mittels zwei vom Benutzer gesetzten Startpunkten innerhalb des Gefäßes und einem nachfolgenden *Region Growing*. Ausgehend von der Initialisierung wird über die Mittellinie und die Normale entschieden, um welche Pathologie es sich handelt oder ob es ein normales Gefäß ist. Anschließend wird das *Active Tube Model* angewendet.

Ayyalassomayajula et al. [7] verwenden zur Segmentierung von AAAs und Thromben in CTA-Aufnahmen eine Erweiterung der klassischen *Snakes*, die 3D *GVF-Snakes*. Dabei werden das Aneurysma und der Thrombus separat

voneinander segmentiert und die Parameter der *GVF-Snakes* für das aktuelle Problem angepasst. So werden zur Segmentierung des Thrombus die Gewichtungparameter  $\alpha$  und  $\beta$ , die in Abschnitt 3.1.2.1 weiter erläutert werden, höher als die Einstellungen des Aneurysmas gesetzt, da ein schlechter Kontrast vorhanden ist. Das Verfahren ist eigentlich ein 2D Modell. Zwar bewegt sich die 3D Oberfläche in alle drei Dimensionen, aber das Verformungsmodell enthält keine Kraft in z-Richtung. Zur Glättung zu einem 3D Modell werden Support Vektor Maschinen verwendet. Das Verfahren segmentiert die inneren Wände des Aneurysmas gut und kann auch ungefähr den Thrombus segmentieren. Kleinere Details werden nicht mitsegmentiert.

Auer und Gasser [6] benutzen 2D und 3D deformierbare Modelle zur Segmentierung von AAA in CTA-Aufnahmen. Der Benutzer spezifiziert die Region und definiert dabei den Bereich, in dem das Aneurysma liegt. Im nächsten Schritt wird eine 2D Segmentierung mittels der klassischen *Snakes* durchgeführt und auf Grundlage dieser Initialisierung wird das 3D deformierbare Modell der *Balloon-Snakes* benutzt. Für die Optimierung der Energie wird die Methode der finiten Elemente verwendet. Nach Auer und Gasser ist ihre Methode zur Segmentierung von AAA ein schnelles und akkurates Verfahren, doch es weist bei komplizierten geometrischen Formen Probleme auf.

#### 2.2.2.4 Geodätische Aktive Konturen zur Segmentierung von abdominalen Aortenaneurysmen

Magee et al. [61] entwickelten ein Verfahren zur Segmentierung von 3D CTA-Aufnahmen, das im ersten Schritt das 3D geodätische Aktive Konturen Modell von Bulpitt et al. [10] verwendet, und im zweiten Schritt ein *Level Set* Verfahren. Dabei werden die Vorteile der beiden Verfahren kombiniert. Das geodätische Aktive Konturen Modell von Bulpitt et al. segmentiert die Aorta grob, sodass Feinheiten nicht beachtet werden. Dafür ist das Verfahren ressourcenschonend. Die Ergebnisse des geodätischen Verfahrens werden als Initialisierung für das *Level Set* Verfahren verwendet. Das *Level Set* Verfahren ist rechenintensiv und benötigt zur Segmentierung einige Stunden. Es segmentiert Feinheiten gut. In Kombination sind die beiden Verfahren schneller und können genauere Ergebnisse liefern. Das Verfahren wurde von den Autoren nicht evaluiert.

## 2.3 Vergleich der Verfahren

In der Tabelle 2.1 wurden alle beschriebenen Methoden aufgelistet. Vergleicht man die Ergebnisse der beiden Verfahren zur Segmentierung der Aortendissek-

tion, erkennt man, dass die Segmentierung von Kovács et al. [47] die Aorta insgesamt gut segmentiert, aber im zweiten Schritt die beiden Lumen nur trennt und nicht segmentiert (s. Abbildung 2.7). Lee et al. [70] im Gegensatz dazu segmentieren die beiden Lumen genau, haben aber das Problem bei stark veräuschten Bildern eine gezackte Wand des Lumens darzustellen. Daher werden die beiden Verfahren zur Segmentierung der Aortendissektion in dieser Arbeit nicht verwendet.

Die Segmentierung der Aortenpathologie Aortenaneurysma wurde auf unterschiedliche Weise realisiert. Dabei kann man allgemein feststellen, dass die Segmentierung mittels statistischer Verfahren das Problem hat, dass eine große Datenbank vorhanden sein muss. Da in dieser Arbeit nicht nur das Aortenaneurysma segmentiert werden soll, sondern auch die Aortendissektion, die noch mehr Formvariationen aufweisen kann, würde eine noch größere Datenbank benötigt werden. Außerdem werden die CTA-Aufnahmen in den Verfahren von de Bruijne et al. [20] und Greiner et al. [29] in 2D segmentiert und anschließend die Schichten interpoliert. Da es möglich sein sollte die CTA-Aufnahmen in 3D zu segmentieren, damit keine Bildinformationen verloren gehen, müsste das Verfahren auf 3D erweitert werden. Dies hätte zur Folge, dass eine Datenbank Formvariationen der Aorta, des Aortensaneurysmas und der Aortendissektion beinhalten müsste. Daher werden in dieser Arbeit keine statistischen Modelle zur Segmentierung der Aorta und der Aortenpathologien angewendet.

Die *Level Sets* haben eine hohe Rechenintensität. Sie segmentieren nach Angaben der Autoren die Aortenaneurysmen gut. Nakhjavanlo et al. [71] haben die Rechenzeit minimiert und die Segmentierungsergebnisse verbessert, da die *Level Sets* Probleme haben besonders die Kanten des Thrombus der Aorta mit einem schlechten Betrag des Gradienten zu segmentieren.

Vergleicht man die erwähnten *Level Set* Verfahren mit den *Snakes*, erkennt man, dass die *Snakes* Probleme haben komplizierte Formen zu segmentieren. Die Berechnungszeit ist aber um einiges kürzer als bei den *Level Sets*. Die Segmentierung mittel der *Snakes* erfolgt entweder durch die klassischen *Snakes* oder *Snakes* Varianten, deren Probleme mit Weiterentwicklungen gelöst worden sind.

Das letzte beschriebene Verfahren sind geodätische Aktive Konturen von Magee et al. [61]. Die geodätischen Aktiven Konturen haben den Vorteil, dass sich die Kontur während der Verformung topologisch verändern kann. Dieses Verfahren wird aber von Magee et al. [61] nicht weiter evaluiert.

Delingette und Montagnat [21] versuchen die bekannten Erweiterungen der expliziten und impliziten Aktiven Konturen zu vergleichen. Die verglichenen Eigenschaften sind in Tabelle 2.2 aufgezählt. Jeder Eigenschaft werden ein bis drei Sterne zugeteilt. Je mehr Sterne ein Verfahren zugewiesen bekommt, desto besser erfüllt das Verfahren die Eigenschaften. Dabei werden die Effizienz und die Schwierigkeit der Implementierung beurteilt. Da es in der Literatur eine

Methode	Autoren	Jahr	Dimension	Aufnahmen
<b>Segmentierungsmethoden der Aortendisektion</b>				
Hough Transformation und <i>GVF-Snakes</i>	Kovács et al. [47]	2006	3D	CTA
Multiskalen Wavelets	Lee et al. [70]	2008	3D	CTA
<b>Segmentierungsmethoden des Aortenaneurysmas</b>				
<b>Statistische Verfahren</b>				
<i>Snakes</i> und <i>Active Appearance Model</i>	Olabarriaga et al. [73]	2003	3D	CTA
<i>Active Shape Models</i>	de Bruijne et al. [20]	2004	2D/3D	CTA
<i>Active Appearance Model</i>	Greiner et al. [29]	2008	2D/3D	CTA
<b>Implizite Aktive Konturen</b>				
Morphologische Operatoren und <i>Level Set</i>	Subašić et al. [85]	2005	3D	CTA
<i>Level Set</i> mit <i>Analyzer</i>	Zhuge et al. [99]	2006	3D	CTA
<i>Level Set</i> mit morphologischer Gradientenkantenfunktion	Kim et al. [44]	2007	3D	CT
Hybrides defomierbares Modell	Demirci et al. [22]	2009	3D	CTA
<i>Level Set</i> mit anisotropen Diffusionsfilter	Nakhjavanlo et al. [71]	2011	3D	CTA
<b>Explizite Aktive Konturen</b>				
<i>Fourier Snakes</i>	Giachetti und Zanetti [27]	2004	3D	CTA
Klassische <i>Snakes</i> mit guter Initialisierung	Lu et al. [60]	2007	3D	CT
<i>Active Cube Model</i>	Kang et al. [39]	2009	3D	DSA
<i>GVF-Snakes</i>	Ayyalassomayajula et al. [7]	2010	2D/3D	CTA
Klassische <i>Snakes</i> und <i>Balloon Snakes</i>	Auer und Gasser [6]	2012	3D	CTA
<b>Geodätische Aktive Konturen</b>				
Geodätische Aktive Konturen	Magee et al. [61]	2001	3D	CTA

Tabelle 2.1: Auflistung aller erwähnten Methoden

	Parametrische Aktive Konturen	Implizite Aktive Konturen
Effizienz	***	*
Schwierigkeiten der Implementierung	***	**
Topologie Veränderungen	Nein	Ja
Offene Konturen	Ja	Nein
Möglichkeiten von Interaktionen	Viele	Wenige

**Tabelle 2.2:** Vor- und Nachteile der expliziten und der impliziten Aktiven Konturen (aus [21].)

Vielzahl von unterschiedlichen Verfahren gibt, fällt eine objektive Beurteilung schwer. Generell lässt sich sagen, dass die expliziten Aktiven Konturen bessere Ergebnisse bzgl. der Rechenzeit liefern als die impliziten Aktiven Konturen. Doch können implizite Aktive Konturen mit Beschleunigungs-Algorithmen wie dem *Fast-Marching* [80] oder dem *Narrow-Band* [75] vergleichsweise schnell die Objekte segmentieren.

Nach Delingette und Montagnat [21] ist der wichtigste Vorteil der impliziten Repräsentation die Möglichkeit, dass sich die Topologie während der Verformung verändern kann. Die Konturen können sich gegebenenfalls sowohl auftrennen als auch zu einer Kontur zusammenschließen. Normalerweise ist es nicht möglich die Topologie der expliziten Aktiven Konturen zu ändern, doch mit Erweiterungen, wie den adaptiven topologischen *Snakes* von McInerney und Terzopoulos [62], ist auch dieses möglich (s. Abschnitt 3.2.8). Als letzten Punkt erwähnen Delingette und Montagnat, dass die expliziten Aktiven Konturen viele Möglichkeiten zur Interaktion haben. Dies ist oft notwendig, da das Ergebnis stark von der Initialisierung abhängig ist. Delingette und Montagnat schreiben in ihrem Schlusswort, dass sie glauben, dass die Benutzerinteraktion eines der wichtigsten Vorteile der expliziten Aktiven Konturen sei.

Es gibt eine große Vielzahl von Erweiterungen sowohl bei den expliziten Aktiven Konturen als auch impliziten Aktiven Konturen. Die Erweiterungen lösen aber meistens nur ein Problem des vorherigen Modells und sind nur auf spezielle Bildaufnahmen oder Anatomien anwendbar. Im Allgemeinen haben die meisten Verfahren keine Probleme die innere Wand der Aorta in CTA-Aufnahmen zu segmentieren, falls die Wand auf Grund des Lumens einen hohen Kontrast zu dem umliegenden Gewebe hat. Probleme treten auf, wenn ein niedriger Kontrast im Bild vorliegt oder wenn nicht mehr die Aortenintima, sondern die äußere Wand der Aorta segmentiert werden soll. Desweiteren werden die Verfahren entweder nur auf das Aortenaneurysma oder auf die Aor-

tendissektion angewendet.

In dieser Arbeit werden die *Snakes* verwendet, da sich während der Segmentierung der Aortenpathologien die Topologie nicht ändern muss und da das Problem der Initialisierung durch Erweiterungen der *Snakes*, wie den *Dual* und den *GVF-Snakes*, gelöst werden können. Desweiteren ist es von Vorteil, dass bei CTA-Aufnahmen mit schlechten Kantenkontrasten die Segmentierung durch Benutzerinteraktionen beeinflusst werden kann.

## 2.4 Verwandte Arbeiten

Relevant für diese Arbeit sind auch noch die folgenden Arbeiten, die sich mit der Segmentierung von koronalen Arterien mittels deformierbarer Modelle beschäftigen.

In der Masterarbeit von Tung [90] werden die koronalen Arterien in CTA-Aufnahmen segmentiert und anschließend in Arterien mit Arteriosklerose mit Calcium Einlagerung und in Arterien ohne Befund klassifiziert. Die Initialisierung der inneren und äußeren Wand erfolgt durch das Setzen von Punkten durch den Benutzer innerhalb der Arterie. Schließlich wird mit Hilfe der *minimum cost path* Methode und einer Energiekostenfunktion die beiden Initialisierungen gesucht. Für die Segmentierung der inneren und äußeren Wand der koronalen Arterien werden die *Dual Snakes* verwendet und für die externen Kräfte wird ein elektronisches Kantenfeld (*EEF*) berechnet.

Wang et al. [91] entwickelten das Segmentierungsverfahren von Tung zu einem automatischen Verfahren weiter, sodass für die Initialisierung die Gefäßmittellinie mit einem *Region Growing* gesucht wird. Damit wird eine bessere Initialisierung verwendet.

Chen et al. [13] verwenden zur Segmentierung von Objekten in Ultraschallbildern wie Tung [90] und Wang et al. [91] die *Dual-Snakes*. Anstatt des *EEF* wird der *discrete gradient flow* für die Berechnung der externen Energie verwendet, sodass Konturen, die mit einer großen Entfernung zum Objekt initialisiert worden sind, durch diese Kräfte zu den gesuchten Konturen gezogen werden. Chen et al. zeigen, dass das Verfahren nicht nur Objekte, die weit von der Startkontur entfernt sind, segmentiert, sondern auch starke Kanten, die nicht zum Objekt gehören, überschreiten kann.

# Kapitel 3

## *Snakes*: Stand der Technik

Im vorherigen Kapitel wurde ein Einblick gegeben, welche Verfahren zur Segmentierung von Aortenpathologien Dissektion und Aneurysma geeignet sind. In diesem Kapitel werden die expliziten Aktiven Konturen genauer beschrieben. Dabei wird zunächst das klassische *Snakes* Modell erläutert. Da die klassischen *Snakes* aber einige Nachteile haben, wurde das Verfahren in verschiedene Richtungen weiterentwickelt. So werden in diesem Kapitel diverse Optimierungsverfahren der Energieminimierung beschrieben und gegenübergestellt und es wird ein Überblick über die existierenden *Snakes* Varianten gegeben.

### 3.1 Das klassische Aktive Konturen Modell

#### 3.1.1 Definition

Das klassische Aktive Konturen Modell, die *Snakes*, ist ein energieminimierender Spline, welcher durch interne und externe Kräfte verformt wird (vgl. [40]). Die interne Kraft beeinflusst dabei die Deformation der Kontur, indem Vorwissen wie die Kantlänge und Kantenglattheit in das Modell mit einbezogen werden, und die externe Kraft bewegt die Kontur zu Bildinformationen, wie helle und dunkle Regionen, Kanten und Abgrenzungen. Nach dem Setzen einer Initialisierung nahe des gesuchten Objektes wird die Kontur verformt und bewegt sich zu den Kanten des gesuchten Objektes. Die Kontur ist in der  $xy$ -Ebene eines 2D Bildes als parametrische Kurve definiert:

$$\mathbf{v}(s) = \begin{pmatrix} x(s) \\ y(s) \end{pmatrix} \quad (3.1)$$

wobei  $s$  ein Konturparameter ist und im Bereich von 0 bis 1 liegt. Mit den klassischen *Snakes* können sowohl offene Konturen als auch geschlossene Konturen segmentiert werden. Für die geschlossene Kontur gilt die folgende Bedingung:  $\mathbf{v}(0) = \mathbf{v}(1)$ . Eine Anpassung der Kontur an die Bildinformationen erfolgt

über die Minimierung einer Energie  $E_{snake}^*$  (s. [46]). Die Energiefunktion kann allgemein beschrieben werden als:

$$E_{snake}^* = \int_0^1 E_{Snake}(\mathbf{v}(s)) = \int_0^1 (E_{int}(\mathbf{v}(s)) + E_{image}(\mathbf{v}(s)) + E_{con}(\mathbf{v}(s))) ds \quad (3.2)$$

Dabei repräsentiert  $E_{int}$  die interne Energie,  $E_{image}$  die Bildenergie und  $E_{con}$  die Einschränkungenergie (vgl. [40]). Die Gesamtenergie beschreibt den momentanen Zustand (vgl. [42]). Im Folgenden werden die einzelnen Energiefunktionale weiter erläutert.

## 3.1.2 Energiefunktionale

### 3.1.2.1 Interne Energie

Die interne Spline-Energie lässt sich folgendermaßen beschreiben:

$$E_{int} = \frac{1}{2} \cdot (\alpha(s) \cdot |\mathbf{v}'(s)|^2 + \beta(s) \cdot |\mathbf{v}''(s)|^2) \quad (3.3)$$

Die interne Energie besteht aus der ersten und zweiten Ableitung der Kurve  $\mathbf{v}(s)$  nach  $s$ . Die erste Ableitung beschreibt die Glattheit bzw. Starrheit der Kontur und verhält sich daher wie eine Membran. Die zweite Ableitung beschreibt die Krümmungsresistenz der Kontur. Gewichtet werden die beiden Ableitungen mit den Gewichtungsparemtern  $\alpha(s)$  und  $\beta(s)$ .

### 3.1.2.2 Externe Energie

Die externe Energie leitet sich aus den Kräften ab, die auf Bildinformationen basieren, wie z. B. die Intensität, der Gradient, die Randpunkte eines Liniensegmentes und Eckpunkte. Kass et al. [40] definieren dabei  $E_{ext} = E_{image} + E_{con}$ . Die klassischen *Snakes* verwenden die Bildinformationen der Intensität, des Gradienten und der Terminierung von Liniensegmenten und Ecken:

$$E_{image} = \omega_{line} \cdot E_{line} + \omega_{edge} \cdot E_{edge} + \omega_{term} \cdot E_{term} \quad (3.4)$$

Die zusätzliche Energie  $E_{con}$  wird in Abschnitt 3.1.4.1 erläutert.

**Linienbildenergie ( $E_{line}$ )** Die einfachste Bildenergie ist die Bildintensität  $I$  selbst.

$$E_{line} = I(x, y) \quad (3.5)$$

Die Linienbildenergie wird mit dem Parameter  $\omega_{line}$  gewichtet, der bestimmt, zu welcher Art von Bildlinie die Kontur angezogen wird. So wird die Kontur

bei positivem  $\omega_{line}$  zu dunklen Linien und bei negativem  $\omega_{line}$  zu hellen Linien im Verhältnis zu dem Grauwert des Bildhintergrundes gezogen.

**Kantenbildenergie** ( $E_{edge}$ ) Bildkanten sind schwieriger zu extrahieren als Bildlinien. Um Bildkanten zu extrahieren, wird der Betrag des Bildgradienten verwendet. Durch diesen und die Bildfunktion werden die Kanten in helle Bildlinien umgerechnet. Da die Kontur während der Minimierung der Energie von hellen Linien angezogen werden sollte, wird das Vorzeichen des Funktionsterms umgedreht. Die Gleichung lautet daher:

$$E_{edge} = - |\nabla I(x, y)|^2 \quad (3.6)$$

**Terminierungsfunktional** ( $E_{term}$ ) Um eine Terminierung an Liniensegmenten und Ecken zu erreichen, benutzen Kass et al. [40] die Krümmung einer Levellinie im schwach geglätteten Bild. Dabei sei  $C(x, y) = G_\sigma(x, y) * I(x, y)$  eine schwach geglättete Version des Bildes.  $\theta = \tan^{-1}(C_y/C_x)$  ist der Gradientenwinkel mit der Ableitung der Funktion  $C(x, y)$  nach  $x$  und  $y$  und  $\mathbf{n} = (\cos(\theta), \sin(\theta))$  und  $\mathbf{n}_\perp = (-\sin(\theta), \cos(\theta))$  sind die Einheitsvektoren entlang und rechtwinklig zur Gradientenrichtung. Die Energiefunktion sieht folgendermaßen aus:

$$E_{term} = \frac{\partial \theta}{\partial n_\perp} = \frac{C_{yy}C_x^2 - 2C_{xy}C_xC_y + C_{xx}C_y^2}{(C_x^2 + C_y^2)^{3/2}} \quad (3.7)$$

### 3.1.3 Energieminimierung durch Variationsrechnung

Zum Finden der Kontur des gesuchten Objektes muss die Energie der Kontur  $\mathbf{v}(s)$  minimiert werden. Die Energie ist aber ein komplexes Funktional, das analytisch nicht gelöst werden kann (s. [42]). Auch stellt das nicht-konvexe Energiefunktional ein sogenanntes *ill-posed* Problem dar. Das heißt, dass neben einem globalen Minimum auch mehrere lokale Minima vorhanden sind (vgl. [42]). Ursprünglich wurde die Minimierung der *Snakes-Energie* mit Hilfe der Variationsrechnung durchgeführt. Falls die Gewichtungparameter konstant sind, also  $\alpha(s) = \alpha$  und  $\beta(s) = \beta$ , kann (3.2) mit der Euler-Lagrange Differentialgleichung gelöst werden:

$$\alpha \mathbf{v}_i'' + \beta \mathbf{v}_i'''' + \frac{\partial E_{ext}}{\partial \mathbf{v}} = 0 \quad (3.8)$$

#### 3.1.3.1 Diskretisierung

In den vorherigen Abschnitten ist die Kontur als kontinuierliche Funktion beschrieben. Um diese Funktion in einer endlichen Zeit und mit endlichem Spei-

cherplatz lösen zu können, wird die Kontur in eine diskrete Funktion umgeschrieben. Die kontinuierliche Kurve  $\mathbf{v}(s)$  wird daher in eine Serie von Konturpunkten  $\mathbf{v}_i = (x_i, y_i)^T$  mit  $i = 1, \dots, n$  approximiert und auch der Raum, in dem sich die einzelnen Knoten bewegen, wird diskretisiert. Die Funktionsterme können zum Beispiel mit der finiten Differenzen-Methode diskretisiert werden. Die Energieberechnung sieht dann folgendermaßen aus:

$$E_{snake}^* = \sum_{i=1}^n (E_{int}(\mathbf{v}_i) + E_{ext}(\mathbf{v}_i)) \quad (3.9)$$

Kass et al. [40] approximieren die Ableitung mit finiten Differenzen und der diskrete Fall der Euler-Lagrange Differentialgleichung wird folgendermaßen berechnet

$$\begin{aligned} 0 = & \alpha_i(\mathbf{v}_i - \mathbf{v}_{i-1}) - \alpha_{i+1}(\mathbf{v}_{i+1} - \mathbf{v}_i) \\ & + \beta_{i-1}[\mathbf{v}_{i-2} - 2\mathbf{v}_i + \mathbf{v}_i] \\ & - 2\beta_i[\mathbf{v}_{i-1} - 2\mathbf{v}_i + \mathbf{v}_{i+1}] \\ & + \beta_{i+1}[\mathbf{v}_i - 2\mathbf{v}_{i+1} + \mathbf{v}_{i+2}] \\ & + f_v(i) \end{aligned} \quad (3.10)$$

wobei die Euler-Lagrange Gleichung auch als Matrixform geschrieben werden kann,

$$\mathbf{A}\mathbf{v}_i + f_v(i) = 0 \quad (3.11)$$

wobei  $\mathbf{A}$  die Pentadiagonal-Bandmatrix der internen Energie und die Kraft  $f_v(i) = \frac{\partial E_{ext}}{\partial \mathbf{v}}$  ist. Die Gleichung wird iterativ gelöst, indem  $\mathbf{v}_i$  als Veränderliche der Zeit  $t$  angenommen wird. Die partielle Ableitung von  $\mathbf{v}_i$  nach  $t$  wird mit einer negativen Schrittweite  $\gamma$  multipliziert.

$$-\gamma \frac{\partial \mathbf{v}}{\partial t} = \mathbf{A}\mathbf{v}_t + f_{v_t} \quad (3.12)$$

Auch ist es notwendig, dass die Zeit diskretisiert wird mit

$$\frac{\partial \mathbf{v}_t}{\partial t} \approx (\mathbf{v}_t - \mathbf{v}_{t-1}) \quad (3.13)$$

Zur Vereinfachung wird die externe Energie während der Zeit nicht verändert. Die partielle Ableitung (3.12) sieht dann folgendermaßen aus:

$$-\gamma(\mathbf{v}_t - \mathbf{v}_{t-1}) = \mathbf{A}\mathbf{v}_t + f_v(\mathbf{v}_{t-1}) \quad (3.14)$$

Durch die Berechnung der Inversen der Matrix  $\mathbf{A}$  kann (3.14) gelöst werden:

$$\mathbf{v}_t = -\frac{1}{\gamma}((\mathbf{A} + \gamma\mathbf{I})^{-1}(\mathbf{v}_{t-1} + f_v(\mathbf{v}_{t-1}))) \quad (3.15)$$

### 3.1.3.2 Vor- und Nachteile der Variationsrechnung

Das oben beschriebene Verfahren ist effizient bezüglich der Rechenzeit, da die Berechnung der Inversen der Matrix der rechenintensivste Schritt des Verfahrens ist. Die Inverse der Matrix  $\mathbf{A}$  muss aber im Allgemeinen nur einmal berechnet werden. Alle weiteren Schritte benötigen kaum Rechenzeit. Der Nachteil ist aber, dass die vierte Ableitung  $\mathbf{v}_i$  in der Euler-Gleichung verwendet wird. Die Ableitungen der Kurve werden auf Grund der Diskretisierung durch finite Differenzen abgeschätzt, was bedeutet, dass mit einem hohen Grad der Ableitung der Fehler der Abschätzung steigt (vgl. [42]). Ein weiterer Nachteil wird von Cohen und Cohen [17] geschildert. Auf Grund der Diskretisierung der Kurve können Konturpunkte durch zu starke Kräfte große Positionsveränderungen machen, sodass die Kontur das globale Minimum überspringt und nicht mehr zu diesem zurückkehrt.

Im Abschnitt 3.1.6 werden vier oft verwendete Energieminimierungsverfahren erläutert und miteinander verglichen.

## 3.1.4 Weitere Energiefunktionale

### 3.1.4.1 Zusätzliche Energien $E_{con}$

Die zusätzlichen externen Energien erlauben es globale Kräfte und Zwänge auf die *Snakes* auszuüben und damit die Entwicklung zu steuern. Beispielsweise können Kräfte wie die *spring forces* [40] und *volcano forces* [40] verwendet werden, die die Kontur von einem vom Benutzer gesetzten Punkt anziehen oder wegdrücken. Dadurch bleibt die Kontur  $\mathbf{v}$  nicht in einem lokalen Minimum stehen (vgl. [43]).

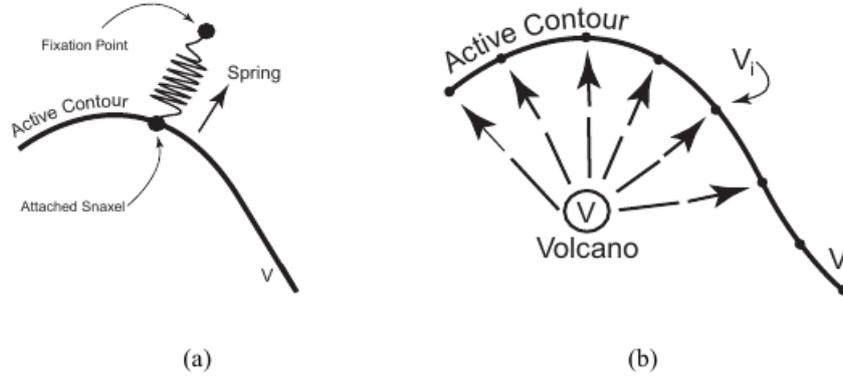
**Spring Forces** Wie in Abbildung 3.1a zu erkennen ist, beeinflussen die *spring forces* nur einen Konturpunkt, der zu dem vom Benutzer gesetzten Fixierungspunkt hingezogen wird. Der Konturpunkt ist normalerweise der Punkt, der am nächsten an dem gesetzten Punkt liegt. Berechnet wird die Kraft nach Leymarie [53] folgendermaßen:

$$\mathbf{f}_{spring} = -k_{spring}(\mathbf{v}_{spring} - \mathbf{v}_i) \quad (3.16)$$

wobei  $k_{spring}$  ein Gewichtungsparemeter ist,  $\mathbf{v}_{spring}$  der vom Benutzer gesetzte Punkt, von dem die Kraft ausgeht, und  $\mathbf{v}_i$  der Punkt ist, auf den die Kraft wirkt.

Die Berechnung der *spring* Energie, die beschreibt, wie gut die Kontur  $\mathbf{v}$  diese zusätzlichen Kräfte berücksichtigt hat, erfolgt folgendermaßen:

$$E_{spring} = k(\mathbf{v}_{spring} - \mathbf{v}_i)^2 \quad (3.17)$$



**Abbildung 3.1:** Die *spring forces* werden zu dem gesetzten Punkt hingezogen und die *volcano forces* stoßen die Kontur weg (aus [68]).

**Volcano Forces** Im Gegensatz zu den *spring forces* beeinflussen die *volcano forces* die ganze Kontur (vgl. [53]) und werden folgendermaßen berechnet

$$f_{volcano} = -\sum_{i=1}^n \frac{k_{volcano}}{r^2} = -\sum_{i=1}^n \frac{k_{volcano}}{(\mathbf{v}_i - \mathbf{v}_{volcano})} \quad (3.18)$$

wobei  $k_{volcano}$  ein Gewichtungsparmeter ist und  $r$  die Distanz zwischen dem vom Benutzer hinzugefügten Punkt und den davon beeinflussten Punkten.

In (3.19) wird die Berechnung der *volcano* Energie dargestellt.

$$E_{volcano} = \sum_{i=1}^n k_{volcano} \frac{1}{|\mathbf{v}_i - \mathbf{v}_{volcano}|} \quad (3.19)$$

### 3.1.4.2 Distanz Energie

Existiert kein vordefinierter Abstand zwischen den benachbarten Punkten der Kontur  $\mathbf{v}_i$ , dann kann es zur Anhäufung von Punkten an einem Bildpixel kommen. Um dieses vorzubeugen, wird die Distanzenergie hinzuaddiert. So wird für jeden Konturpunkt die Differenz zweier benachbarter Punkte  $\mathbf{v}_i$  und  $\mathbf{v}_{i-1}$  hinsichtlich des durchschnittlichen Abstandes berechnet (vgl. [33]). Die Distanzenergie sieht wie folgt aus

$$E_{dist} = \left| \frac{|\mathbf{v}_i - \mathbf{v}_{i-1}|}{\frac{1}{n-1} \sum_{j=2}^n |\mathbf{v}_j - \mathbf{v}_{j-1}|} - 1 \right| \quad (3.20)$$

wobei  $n$  die Anzahl der Punkte ist. Diese Energie ist minimal, wenn alle Konturpunkte den gleichen Abstand zu den benachbarten Konturpunkten haben.

### 3.1.5 Vor- und Nachteile der klassischen *Snakes*

Die Idee der klassischen Aktiven Konturen war ein Fortschritt in der Bildverarbeitung. Durch diese wurde es möglich, dass Lücken in Kurven überbrückt werden konnten, was mit Merkmalsextraktionsverfahren nicht möglich war. Im Gegensatz zur manuellen Segmentierung werden bei dem klassischen Aktiven Konturen Modell vom Benutzer nur die Gewichtungen der Energien angegeben und je nachdem, welches Verfahren zur Generierung der Initialisierung verwendet wird, werden nur wenige bis gar keine Punkte gesetzt. Bei dem nachfolgenden automatischen Auswertungsprozess kann der Anwender durch Setzen von zusätzlichen externen Kräften die *Snakes* beeinflussen. Auf Grund der Kombination der Energieterme ist das Modell relativ robust gegenüber Rauschen und kleineren Störungen.

Trotzdem weist das klassische Aktive Kontur Modell einige Schwächen auf, die immer wieder in der Literatur erwähnt werden:

- Die Gesamtenergiefunktion kann in einem lokalen Minimum konvergieren. Daher sollte die Initialisierung relativ nahe an der Zielkontur liegen.
- Es treten Probleme beim Segmentieren von konkaven Objekten auf.
- Die Methode ist sensitiv beim Setzen der Gewichtungparameter.
- Die *Snakes* können während der Minimierung ihre Topologie nicht ändern.
- Die interne Energie verhindert, dass die *Snakes* starke Krümmungen annehmen können, weshalb keine schlauch- oder röhrenförmigen Strukturen segmentiert werden können (s. [65]).

Seit der Veröffentlichung von Kass et al. [40] wurde das Verfahren in unterschiedliche Richtungen weiterentwickelt. Meist wurden die *Snakes* aber nur für die Lösung eines speziellen Problems weiterentwickelt. In Abschnitt 3.2 werden Varianten der Erweiterung der *Snakes* aufgelistet und kurz beschrieben.

### 3.1.6 Energieminimierungsverfahren

Im Folgenden werden vier oft verwendete Minimierungsverfahren zum Lösen des Optimierungsproblems vorgestellt.

#### 3.1.6.1 Erweiterte Variationsrechnung

Im Abschnitt 3.1.3 wurden die Minimierung der Energie mittels Variationsrechnung vorgestellt und ihre Vor- und Nachteile erwähnt. Cohen und Cohen

[17] haben sich Gedanken gemacht, wie die Optimierung über die Variationsrechnung verbessert werden kann. Sie haben bei den *Balloon Snakes* (s. Abschnitt 3.2.1) eine Finite-Elemente-Methode (FEM) anstatt der finiten Differenzen verwendet. Durch diese Methode kann die Komplexität des Algorithmus verringert werden, da weniger diskretisierte Punkte erforderlich sind. Da die externe Kraft genauer berechnet wird, sind die Ergebnisse genauer.

### 3.1.6.2 Dynamische Programmierung

Kritisch bei der Minimierung mit der Euler-Lagrange Gleichung ist, dass es sich bei der Gleichung um eine notwendige Bedingung handelt. „Amini et al. [4] weisen darauf hin, dass bei Verwendung der Euler-Lagrange Gleichung möglicherweise ein Maximum anstatt eines Minimums gefunden wird. Weitere Kritikpunkte betreffen die Konvergenz und Stabilität des Verfahrens“ [33].

Amini et al. [4] benutzen zur Energieminimierung die dynamische Programmierung, die über einen stufenweisen Entscheidungsprozess mit jeweils einer begrenzten Menge der zulässigen Entscheidungen ein Minimum findet. Das Optimierungsproblem kann nur dann mit dynamischer Programmierung gelöst werden, wenn es eine endliche Menge an möglichen Lösungen gibt. Daher wird das im kontinuierlichen Raum beschriebene Problem durch Formulierung im diskreten Raum ersetzt (vgl. [42]). Die diskrete Formulierung der Gesamtenergie sieht dann folgendermaßen aus:

$$E_{Snake}^* = \sum_{i=0}^{n-1} (E_{ext}(\mathbf{v}_i) + \frac{1}{2}(\alpha_i |\mathbf{v}_i - \mathbf{v}_{i-1}|^2 + \beta_i |\mathbf{v}_{i+1} - 2\mathbf{v}_i + \mathbf{v}_{i-1}|^2)) \quad (3.21)$$

Dabei ist zu erkennen, dass die Berechnung von der aktuellen Position und den Positionen der Punkte, die in der Punkteliste vor und nach dem aktuellen Punkt liegen, abhängig ist. Um die Ableitungen verwenden zu können, werden wiederum finite Differenzen angewandt. Im Unterschied zu der Variationsrechnung wird nur die finiten Differenzen der ersten und zweiten Ableitung benötigt.

Die dynamische Programmierung kann man in zwei Teile unterteilen: in den *forward decision process* und den eigentlichen Entscheidungsschritt *backward decision process*. Im *forward decision process* wird für jeden Knoten  $\mathbf{v}_i$  bestimmt, welche Position der Knoten  $\mathbf{v}_{i-1}$  einnehmen muss, damit der Energieanteil von  $\mathbf{v}_i$  minimal ist. Voraussetzung ist, dass die Position der beiden Knoten  $\mathbf{v}_i$  und  $\mathbf{v}_{i+1}$  bekannt ist. Unbekannt ist aber, wo  $\mathbf{v}_i$  und  $\mathbf{v}_{i+1}$  nach der Optimierung positioniert werden. Daher muss das Teilproblem gelöst und anschließend in einer Gesamtlösung berechnet werden (vgl. [42]). Im weiteren Verlauf des Abschnittes wird beschrieben, wie die Verbindung zwischen der

Minimierung der totalen *Snakes-Energie* und der Minimierung der folgenden Funktion berechnet werden kann:

$$E(\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n) = E_1(\mathbf{v}_1, \mathbf{v}_2) + E_2(\mathbf{v}_2, \mathbf{v}_3) + \dots + E_{n-1}(\mathbf{v}_{n-1}, \mathbf{v}_n) \quad (3.22)$$

wobei jedes  $\mathbf{v}_i$  nur  $m$  verschiedene Werte annehmen kann. Mit „einer Kostenfunktion werden schrittweise die minimalen Gesamtkosten berechnet“ [33]. Im Folgenden wird ein Beispiel der Energieminimierung mit  $n = 5$  dargestellt:

$$\begin{aligned} s_1(\mathbf{v}_2) &= \min_{\mathbf{v}_1} E_1(\mathbf{v}_1, \mathbf{v}_2) \\ s_2(\mathbf{v}_3) &= \min_{\mathbf{v}_2} (s_1(\mathbf{v}_2) + E_2(\mathbf{v}_2, \mathbf{v}_3)) \\ s_3(\mathbf{v}_4) &= \min_{\mathbf{v}_3} (s_2(\mathbf{v}_3) + E_3(\mathbf{v}_3, \mathbf{v}_4)) \end{aligned} \quad (3.23)$$

$$\min_{\mathbf{v}_1, \dots, \mathbf{v}_4} E(\mathbf{v}_1, \mathbf{v}_2, \mathbf{v}_3, \mathbf{v}_4, \mathbf{v}_5) = \min_{\mathbf{v}_4} (s_3(\mathbf{v}_4) + E_4(\mathbf{v}_4, \mathbf{v}_5))$$

Verallgemeinert sieht die Kostenfunktion wie folgt aus

$$s_k(\mathbf{v}_{k-1}) = \min_{\mathbf{v}_k} \{s_{k-1}(\mathbf{v}_k) + E_k(\mathbf{v}_k, \mathbf{v}_{k+1})\} \quad (3.24)$$

Der Algorithmus der dynamischen Programmierung sieht folgendermaßen aus: Es werden iterativ immer wieder der *forward decision process* und der im Folgenden beschriebene *backward decision process* durchgeführt. Für den *forward decision process* wird jede Stufe der oben beschriebenen Kostenfunktion in einer Tabelle gespeichert. Über den *backward decision process* kann über die Tabelle die minimale Energie  $E_{snake}^*(t) \approx \min_{\mathbf{v}_n} S_{n-1}(\mathbf{v}_n)$  zum aktuellen Zeitpunkt  $t$  berechnet werden. Die optimalen Positionen für die neuen Konturpunkte werden ausgehend von dem ersten und dem letzten Konturpunkt berechnet. Die Schritte des *forward decision process* und des *backward decision process* können solange wiederholt werden, bis die Veränderungen der Gesamtenergien vernachlässigbar klein sind.

Die „dynamische Programmierung lässt sich dann einsetzen, wenn nicht alle Variablen eines komplexen Optimierungsproblems simultan voneinander abhängen“ [42]. Nachteil dieses Verfahrens ist eine hohe Komplexität  $O(nm^3)$ . Desweiteren liefert diese Methode nicht das globale Minimum des Bildes, sondern nur das globale Minimum unter den untersuchten Lösungen. Nach Kerschner [42] ist ein Vorteil dieser Methode, dass weiche und harte Restriktionen leicht berücksichtigt werden können. Er definiert die harte Restriktionen als zusätzliche Bedingungen, die nicht Teil der Energiefunktion sind und unbedingt erfüllt sein müssen. Im Gegensatz dazu beschreibt er weiche Restriktionen als Kriterien, die in der Energiefunktion vorhanden sind und gemeinsam optimiert werden.

### 3.1.6.3 Greedy Algorithmus

Zur Vereinfachung der Methode der dynamischen Programmierung und zur Reduzierung der Komplexität des Verfahrens benutzen Williams und Shah [93] einen Greedy Algorithmus. Auch für diesen Algorithmus wird die Energie der Kontur diskretisiert. Die Optimierung lässt sich in zwei Hauptprozesse aufteilen. Im ersten Schritt wird die Gesamtenergie der aktuellen Lage der Kontur  $\mathbf{v}_i$  und die Gesamtenergie von jedem benachbarten Punkt berechnet. Die Lokalisation mit der geringsten Energie wird als neue Kontur  $\mathbf{v}_i$  verwendet. Im nächsten Schritt wird die Krümmung an jedem Punkt auf der neuen Kontur  $\mathbf{v}_i$  bestimmt. Die Energiefunktion des Algorithmus sieht folgendermaßen aus:

$$E_{snake}^* = \int_0^1 (\alpha(s)E_{cont}(\mathbf{v}_i) + \beta(s)E_{curv}(\mathbf{v}_i) + \gamma(s)E_{image}(\mathbf{v}_i))ds \quad (3.25)$$

wobei die Gewichtungparameter  $\alpha$ ,  $\beta$  und  $\gamma$  den Einfluss der einzelnen Energien ausgleichen. Der Spannungsterm  $E_{cont}(\mathbf{v}_i)$  wird durch die Distanz des aktuellen und des vorherigen Punktes der Kontur berechnet:  $|\mathbf{v}_i - \mathbf{v}_{i-1}|^2$ . Da dieser Term aber dafür verantwortlich ist, dass die Kontur auf Grund der Minimierung der Distanz der beiden Punkte schrumpft, wird von den Autoren vorgeschlagen, dass vom durchschnittlichen Abstand  $\bar{d}$  aller Punkte der Betrag der Distanz der beiden Punkte abgezogen wird (vgl. [51]).

$$E_{cont}(\mathbf{v}_i) = \bar{d} - |\mathbf{v}_i - \mathbf{v}_{i-1}| \quad (3.26)$$

Der Krümmungsterm wird folgendermaßen berechnet:

$$E_{curv}(\mathbf{v}_i) = |\mathbf{v}_{i-1} - 2\mathbf{v}_i + \mathbf{v}_{i+1}|^2 \quad (3.27)$$

Die Bildenergie eines Konturpunktes wird durch den Betrag des Gradienten an der Position des Konturpunktes und des Betrages des minimalen und des maximalen Gradienten in der Nachbarschaft des Konturpunktes berechnet.

$$E_{image}(\mathbf{v}_i) = (|\nabla I|_{min} - |\nabla I|)/(|\nabla I|_{max} - |\nabla I|_{min}) \quad (3.28)$$

Vorteile dieses Verfahrens sind, dass die Laufzeit nur noch  $O(nm)$  beträgt und das Verfahren daher auch für Real-Time-Systeme (vgl. [45]) verwendet werden kann. Nachteilig ist nach Kiser [45], dass das Verfahren anfällig für lokale Minima ist. Liu [58] beschreibt, dass die Kontur in vermeintlichen Objektkonturen von verrauschten Bildern ein lokales Minimum findet, da "verrauschte" Pixel einen hohen Gradientenbetrag haben. Das Ergebnis ist eine falsche Segmentierung der Kontur.

#### 3.1.6.4 *Simulated Annealing*

*Simulated Annealing*, was übersetzt simulierte Abkühlung heißt, ist ein heuristisches Optimierungsverfahren und wird von Trinder et al. [89] verwendet um die Gesamtenergie zu minimieren. Die Grundidee ist, den Abkühlungsprozess eines Stoffes zu simulieren, wobei durch einen physikalischen Prozess ein Kristall entsteht. Der Zustand verändert sich von flüssig zu fest. Ausgehend von der Kontur  $\mathbf{v}$  wird mit der Energie  $E_{snake}^*$  eine neue Kontur  $\mathbf{v}'$  berechnet. Falls sich durch die Berechnung die Energie der neuen Kontur verringert, wird die Kontur  $\mathbf{v}'$  übernommen, ansonsten wird die neue Kontur mit einer Wahrscheinlichkeit von  $p = \exp(-\frac{E_{snake'}^* - E_{snake}^*}{T})$  als aktuelle Kontur gesetzt, wobei  $E_{snake'}^*$  die Gesamtenergie der neuen Kontur ist. Dabei ist  $T$  die zu dem Zeitpunkt aktuelle Temperatur. Der Vorteil dieses Verfahrens ist nach Kerchner [42], dass Zustandsänderungen, die die Energie der Kontur erhöhen, nicht von vornherein verworfen werden, sondern diese Zustandsänderungen mit einer gewissen Wahrscheinlichkeit eintreten können. Die *Snakes* bleibt dadurch während der Verformung nicht in einem lokalen Minimum. Nachteile sind, dass es viele Iterationen in den einzelnen Temperaturstufen geben kann, da die Schwierigkeit darin besteht zu erkennen, wann die Temperatur gesenkt werden darf. "Die Wahl dieser Abkühlungsgeschwindigkeit entscheidet darüber, ob die *Snakes* von einem lokalen Minimum gefangen wird." (s. [42]). Die Autoren selbst weisen darauf hin, dass es schwierig ist ein Objekt zu segmentieren, wenn in der Region, in der das Objekt gesucht wird, mehrere Objekte mit ähnlichen Eigenschaften enthalten sind.

#### 3.1.6.5 Vergleich der Optimierungsverfahren

Alle hier aufgeführten Verfahren haben ihre Vor- und Nachteile. Kerchner [42] hat die Variationsrechnung, die dynamische Programmierung, das *Simulated Annealing* und die *Level Set* Optimierung miteinander verglichen und ist zu dem Resultat gekommen, dass durch die Optimierungsverfahren immer nur ein Teil der Probleme zum Segmentieren des gesuchten Objektes gelöst werden kann. Der Benutzer muss selbst entscheiden, welches Optimierungsproblem für sein Problem am besten geeignet ist. Wird ein Verfahren benötigt, das möglichst schnell das gesuchte Objekt segmentieren kann, das aber Fehler beinhalten kann, dann ist für dieses Minimierungsproblem der Greedy-Algorithmus prädestiniert. Die Minimierung mittels der dynamischen Programmierung hat den Nachteil, dass das Verfahren eine hohe Komplexität hat. Es wird das gesuchte globale Minimum gefunden, falls sich das globale Minimum unter den untersuchten Lösungen befindet. Die Lösung mittels des *Simulated Annealing* hat Probleme bei der Segmentierung von Objekten, falls sich in der näheren Umgebung andere Objekte befinden.

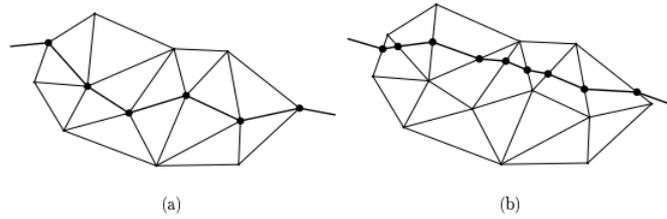
### 3.1.7 3D-Snakes

Die Segmentierung von dreidimensionalen Objekten kann man auf unterschiedliche Weise realisieren. Eine Möglichkeit besteht darin, dass mit einem 2D schichtbasierten Verfahren die einzelnen Schichten segmentiert und diese anschließend in einem 3D Modell verrechnet werden. In das 3D Modell fließen in den einzelnen Schichten aber keine Informationen über die Zwischenbeziehungen der Schichten ein. Um keine Artefakte bei der 3D Rekonstruktion zu haben, werden diese geglättet. Dies ist aber nur mit einem Informationsverlust zu realisieren. Aus den vorher erwähnten Gründen wurde von vielen Forschern versucht das schichtbasierte Modell in ein echtes 3D-Modell zu überführen. Die Aktiven Konturen der Ebene  $\mathbf{v}(s) = (x(s), y(s))^T$  werden um eine dritte Dimension erweitert, sodass die Kurve durch  $\mathbf{v}_{3D}(s) = (x(s), y(s), z(s))^T$  definiert ist. Dabei muss aber sichergestellt werden, dass sich die Kurve innerhalb einer stetigen Oberfläche mit den zulässigen Parameterdarstellung befindet (vgl. [50]). Bei den diskreten Aktiven Konturen „entsteht bei Modellen für triangulierte Oberflächen aus dem Polygon ein im Allgemeinen nicht planarer, gegebenenfalls geschlossener Polygonzug  $\mathbf{v}_i = (x_i, y_i, z_i)$ , wobei sowohl  $\mathbf{v}_i$  als auch die Punkte zwischen  $\mathbf{v}_i$  und  $\mathbf{v}_{i+1}$  ( $\mathbf{v} = \lambda\mathbf{v}_i(1 - \lambda)\mathbf{v}_{i+1}$ ; ( $\lambda \in [0, 1]$ )) innerhalb der diskreten Oberfläche liegen“[50].

Speziell bei den parametrischen Aktiven Konturen wird ein 3D Modell mit der diskretisierten Funktion erstellt. Die Realisierungsmöglichkeiten werden in Abbildung 3.2 in einem triangulierten 3D-Netz dargestellt. Im ersten Fall können Punkte, an denen die Dreiecke zusammenlaufen, direkt als Konturpunkte verwendet werden, wobei sich die Verbindungen der Konturpunkte auf den Netzkanten befinden, und im anderen Fall befinden sich die Konturpunkte auf den Kanten der Dreiecke des 3D-Netzes, wobei dort die Verbindungen zwischen den Konturpunkten innerhalb der Dreiecke verlaufen. Nach Kux [50] hat die zweite Methode den Nachteil, dass Eigenschaften wie die Krümmung und die Normalenrichtung nicht aus dem 3D-Netz abgelesen, sondern durch lineare Interpolation berechnet werden müssen. Die *Snakes*-Energiegleichung muss je nach *Snakes* Variation an das 3D-Netz angepasst werden. Nach Kux [50] sind nur einige Erweiterungen der *Snakes* dafür geeignet, auf triangulierte 3D-Netze angewandt zu werden. Darunter gehören unter anderem die *Balloon Snakes* (s. Abschnitt 3.2.1), die *GVF-Snakes* (s. Abschnitt 3.2.12.1), die *Ziplock Snakes* (s. Abschnitt 3.2.6) und die *T-Snakes* (s. Abschnitt 3.2.8).

## 3.2 Snakes Varianten

Es wurde eine Vielzahl von Varianten/Erweiterungen der klassischen *Snakes* entwickelt. Abbildung 3.3 zeigt einen (unvollständigen) Überblick. Im Folgenden werden die wichtigsten Varianten vorgestellt.



**Abbildung 3.2:** Realisierungsmöglichkeiten für Aktive Konturen auf 3D-Netzen (aus [50])

### 3.2.1 *Balloon Snakes*

Die klassischen *Snakes* haben das Problem, dass sie nahe an dem gesuchten Objekt initialisiert werden müssen, da die Kontur ansonsten nicht von der gesuchten Kontur angezogen wird. Das Modell der *Balloon Snakes*, welches von Cohen [16] entwickelt wurde, verhält sich wie ein Ballon, der von einer zusätzlichen Kraft aufgeblasen wird. Dadurch kann die verformbare Kontur schwache Kanten überschreiten und bleibt nur bei starken Kanten stehen.

Die *balloon forces* der *Balloon Snakes* geben die Richtung an, in der sich die Kontur verformt. Gewichtet werden die *balloon forces* durch den Parameter  $k_{pressure}$ . Bei einem negativen Wert von  $k_{pressure}$  wird das globale Minimum im Inneren der Kontur gesucht und die Kontur schrumpft zusammen und bei einem positiven  $k_{pressure}$  wird die Kontur nach außen gezogen.  $\mathbf{n}(\mathbf{v})$  ist die Normale der Kontur und das Potenzial  $P(\mathbf{v}(s))$  wird mit  $k$  gewichtet (vgl. [17]). Das Potenzial wird mit dem Betrag des Gradienten berechnet:

$$P(\mathbf{v}(s)) = -|\nabla I|^2 \quad (3.29)$$

Die *balloon forces* werden folgendermaßen berechnet:

$$f_{balloon} = k_{pressure} \mathbf{n}(v) - k \frac{\nabla P}{\|\nabla P\|} \quad (3.30)$$

### 3.2.2 *Fuzzy Snakes*

*Fuzzy Snakes* wurden von Höwing et al. [35] entwickelt um mit Hilfe von *Fuzzy-Logik* unsicheres a priori Wissen in die Energieminimierungsgleichung zu integrieren. Der Algorithmus unterteilt die Kontur in Segmente, die mit Hilfe der *Fuzzy-Logik* unterschiedliche Eigenschaften zugewiesen bekommen. Der Vorteil ist, dass damit Objekte in Bildern mit starkem Rauschen segmentiert werden können (z.B. MRT-Aufnahmen). Zur Minimierung der Gesamtenergie wird die dynamische Programmierung verwendet. Die Energiefunktion der *Fuzzy Snakes* wird über die *Fuzzy-Repräsentation* berechnet. Dabei werden linguistische

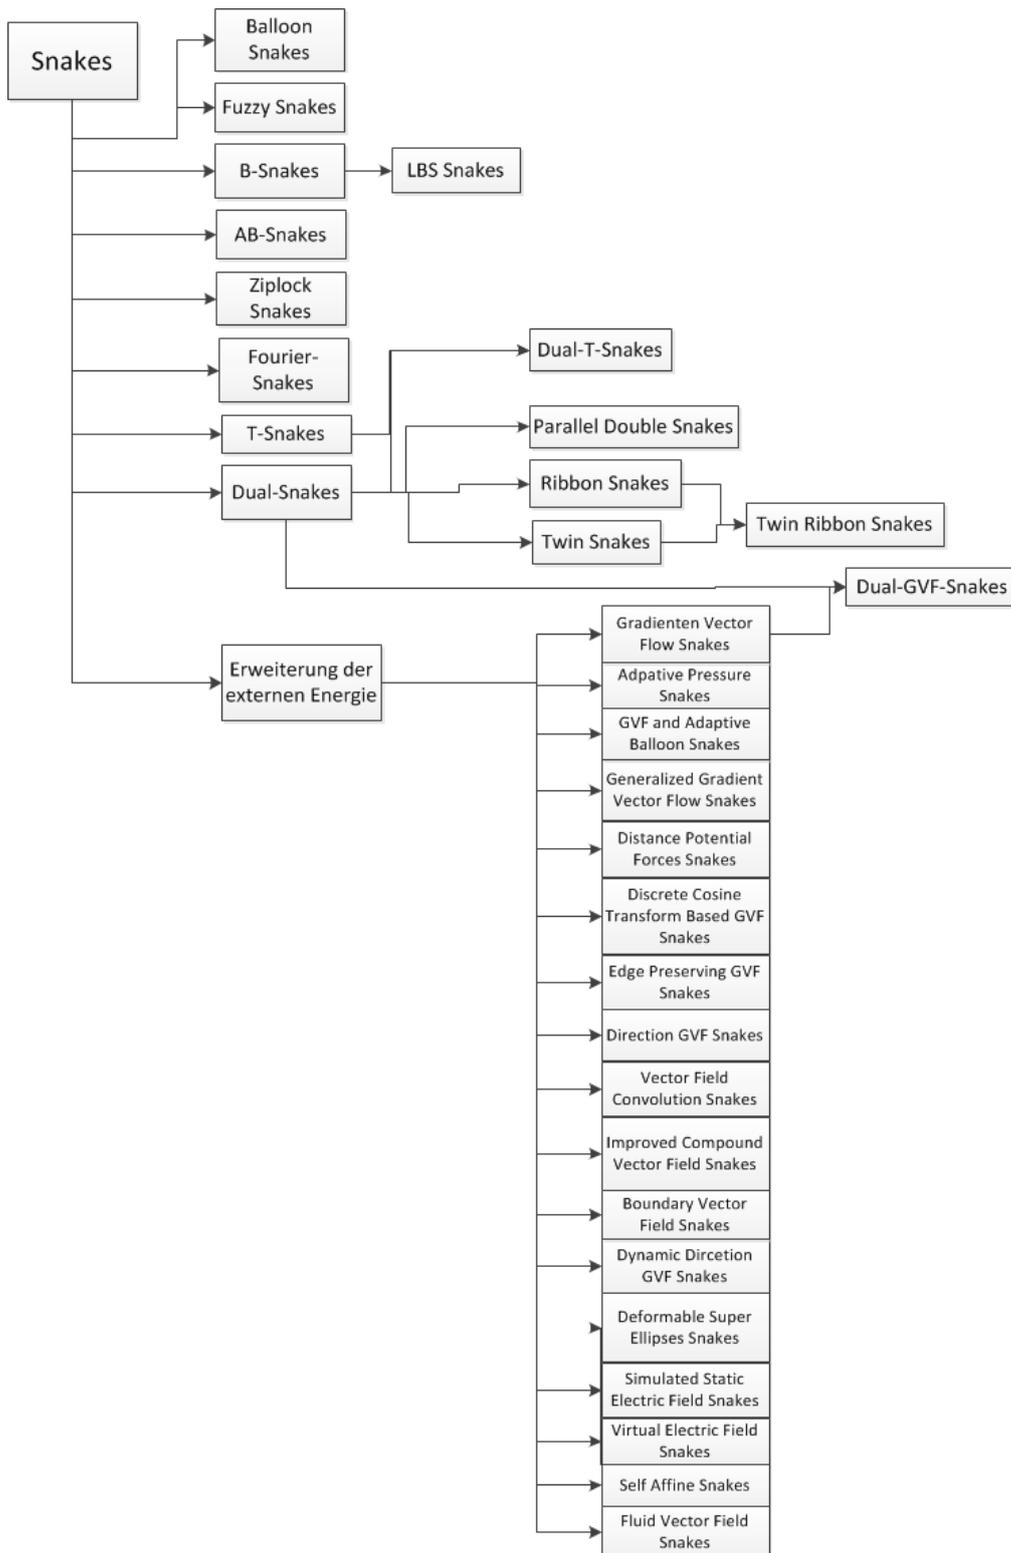


Abbildung 3.3: Snakes Varianten

a:	c:
IF <i>edge falling</i> very weak	IF <i>edge falling</i> medium
AND <i>curvature</i> medium right	AND <i>curvature</i> strong right
THEN <i>quality</i> very good	THEN <i>quality</i> very good
b:	d:
IF <i>edge falling</i> weak	IF <i>edge falling</i> medium
AND ( <i>curvature</i> flat left	AND ( <i>curvature</i> flat left
OR <i>curvature</i> flat right)	OR <i>curvature</i> flat right)
THEN <i>quality</i> very good	THEN <i>quality</i> very good

**Abbildung 3.4:** Regeln zur Berechnung der externen Energie der *Fuzzy Snakes* (aus [35])

Variablen vom Benutzer eingegeben (s. Abbildung 3.4) und die externen Energien der Segmente werden berechnet. Die Regeln eines Objektes können auch auf ähnliche Objekte angewendet werden.

Auf Grund der Abstraktion des Verfahrens schildern die Autoren, dass das Verfahren intuitiver für den Benutzer ist. So muss er sich bei vielen anderen *Snakes* erst in die Einstellung der Gewichtungparameter der Energiefunktionale einarbeiten. Je komplexer die Beschreibung ist, desto komplexere Objekte und Bilder mit schlechterer Qualität können segmentiert werden. Ein Nachteil des Verfahrens ist, dass es rechenintensiv ist.

### 3.2.3 *B-Snakes*

Entwickelt wurden die *B-Snakes* von Menet et al. [66]. Die *B-Snakes* werden von einer Annäherung der initialen Kurve mit parametrischen B-Splines und der Minimierung der Energie gebildet. Die Annäherung wird in Kurvensegmente unterteilt. Jedes Kurvensegment wird stückweise durch eine Polynomfunktion, welche die Basisfunktion  $\mathbf{B}_i$  und die Kontrollpunkte  $\mathbf{c}_i = (x_i, y_i)$  beinhaltet, angenähert.

$$q(u) = \sum_{i=0}^m (\mathbf{c}_i \mathbf{B}_i(u)) \quad (3.31)$$

Dabei ist  $u$  die Parameterbeschreibung der approximierten Kurve. Die *B-Snakes* Energie wird berechnet, indem in (3.2) der Vektor  $\mathbf{v}$  zu  $q(u)$  ersetzt wird, und die Energiefunktion wird durch die Kontrollpunkte minimiert (vgl. [66]). Durch die Interpolationsmöglichkeit können die ursprünglichen Daten minimiert und damit bessere Konvergenzen erreicht werden. Auch können über die Kontur Knicke modelliert werden (vgl. [9]). Desweiteren wird die Chamfer Distanz von Barrow et al. (s. [8]) verwendet, die die Richtung der nächsten Kanten angibt und bei der Konvergenz bei weit entfernten Kanten hilft. Trotz-

dem kann es vorkommen, dass ein lokales oder kein Minimum gefunden wird. Im zweiten Fall verformt sich die Kontur solange, bis alle Punkte an einem Bildpixel zusammengelaufen sind.

### 3.2.4 *LSB Snakes*

Die Optimierung der *LSB Snakes* (*Least Squares B-Spline Snakes*) wurde von Gruen und Li [30] entwickelt, die dabei die *B-Snakes* (s. Abschnitt 3.2.3) von Menet et al. [66] mit der Ausgleichsrechnung der kleinsten Quadrate kombiniert haben. Die *LSB-Snakes* verwenden dabei drei Komponenten:

1. “die Möglichkeit für eine interne Qualitätskontrolle durch die Berechnung der Kovarianzmatrix der geschätzten Parameter
2. das Ausnutzen von sämtlichen a priori bekannten geometrischen und radiometrischen Informationen um die Lösung einzuschränken
3. das gleichzeitige Verwenden einer beliebigen Anzahl von Bildern” (s. [57])

Durch die Auswertung der Kovarianzmatrix mit der Methode der Kleinsten-Quadrate kann die Genauigkeit und die Zuverlässigkeit des geschätzten 3D-Merkmals beurteilt werden. Auf Grund der Abschätzung der Genauigkeit des Ergebnisses ist eine Selbstdiagnose möglich. So kann die Methode in einem autonomen System eingesetzt werden. Auf der anderen Seite muss die Initialisierung der *LSB-Snakes* nahe an der gesuchten Kontur liegen, da die Ausgangslage bei jeder Iteration die Konturpunkte der Ausgangslage miteinbezieht.

### 3.2.5 *AB-Snakes*

Andrey und Bourdier [5] benutzen zur Segmentierung von biologischen Bildern *adaptive Snakes*, welche sie *AB-Snakes* genannt haben. Nach Angaben der Autoren können *AB-Snakes* sowohl konkave und als auch dünne und komplexe Objekte segmentieren und sie sind robust gegenüber Rauschen. Die *AB-Snakes* ersetzen die interne Energie der klassischen *Snakes* mit folgender interner Energie:

$$E_{int} = \sum_{i=1}^n (\alpha_i |\mathbf{m}_i - \mathbf{m}_{i-1}|^2) \quad (3.32)$$

Jeder Punkt der Kontur  $\mathbf{v}_i$  wird entlang der Normalen zum Bildpunkt mit dem größten Gradienten gezogen, der durch den Canny-Derive Operator berechnet wird. Der Abstand zwischen dem Punkt mit dem größten Gradienten und dem Konturpunkt ist  $\mathbf{d}_i$ . Die neue Position  $\mathbf{m}_i$  des Punktes  $\mathbf{v}_i$  wird folgendermaßen berechnet:

$$\mathbf{m}_i = \mathbf{v}_i + \mathbf{d}_i \quad (3.33)$$

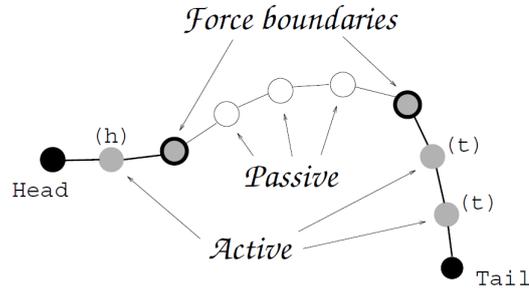


Abbildung 3.5: *Ziplock Snakes* Algorithmus schematisch (aus [72])

Der Gewichtungparameter  $\alpha_i$  wird dafür verwendet, dass eine Balance zwischen der Glattheit der Kurve und der Nähe von Ecken entsteht. Die Besonderheit des Gewichtungsparmeters ist, dass jeder Punkt einzeln gewichtet wird. Er wird folgendermaßen berechnet:

$$\alpha_i = \frac{\lambda}{1 + \mu \mathbf{d}_i} \quad (3.34)$$

Dabei sind  $\mu$  und  $\lambda$  die Koeffizienten, die den Wertebereich der  $\alpha_i$ -Parameter regularisieren.  $\mathbf{d}_i$  wird normiert.

### 3.2.6 *Ziplock Snakes*

Die *Ziplock Snakes* (reißverschlussartige *Snakes*) wurden von Neuenschwander et al. [72] entwickelt. Es ist eine offene Kontur, bei der Endpunkte vom Benutzer gesetzt werden, die sich möglichst nahe an einer gut sichtbaren Kante befinden. Durch Initialisierungspunkte und Gradientenbeträge des Bildes werden die Befestigungspunkte der Kontur neu berechnet, damit diese Punkte eine gute Initialisierung aufweisen. Anschließend werden zwischen den Befestigungspunkten weitere Punkte interpoliert. Die Punkte, die am nächsten an den Befestigungspunkten liegen, werden als aktive Abschnitte (s. Abbildung 3.5) bezeichnet und werden mit den Bildkräften  $\mathbf{f}_v = \mathbf{K} \cdot \mathbf{v}$  bei jeder Iteration verschoben. Dabei ist  $\mathbf{v}$  der Vektor von allen x- und y-Koordinaten des Bildes,  $\mathbf{K}$  eine Starrheitsmatrix und  $\mathbf{f}_v$  die abgeleitete Bildkraft. Auch werden die passiven Punkte bei jedem Iterationsschritt verschoben. Um die homogene Euler-Lagrange-Gleichung lösen zu können werden Kantenkräfte und aktive Punkte benötigt.

Bei den klassischen *Snakes* muss die Startkontur nahe an dem gesuchten Objekt platziert werden. Ist dies nicht der Fall, kann es dazu kommen, dass die Kontur die gesuchte Objektkontur nicht erkennt und an einem anderen Minimum stehenbleibt. Die *Ziplock Snakes* benötigen nur wenige Punkte, die nahe an der Kontur liegen sollten. Die Kontur formt sich wie ein Reißverschluss an

die Kontur, da sich die Kontur ausgehend von den gut gesetzten Endpunkten dem gesuchten Objekt durch Energieminimierung annähert. Mit dem Verfahren können auch Objekte in Bildern segmentiert werden, bei denen ähnliche Bildeigenschaften nahe nebeneinander liegen (vgl. [72]).

### 3.2.7 *Fourier Snakes*

Staib und Duncan [83] benutzen zur Segmentierung von 3D Objekten in medizinischen Bilddaten eine 3D Oberflächenmodell, welches auf geometrische Oberflächen angepasst wird. Die *Fourier Snakes* ist ein probabilistisches deformierbares Modell und basiert auf einer Fourierzerlegung der Oberfläche in Summen der sinusoidalen Basisfunktion. Staib und Duncan [83] haben unterschiedliche Oberflächentypen entwickelt, wie die offene Oberfläche, die geschlossene Oberfläche und die Röhrenoberfläche. Dabei wurde die Oberflächenfindung als ein Optimierungsproblem formuliert, der die Kontur zu den starken Bildgradientenbeiträgen zieht. Ein Vorteil ist, dass eine Vielfalt der Glättungsoberflächen erlaubt ist und dass das Modell damit mit einer kleinen Anzahl von Parametern beschrieben werden kann (vgl. [88]). Die *Fourier Snakes* sind von Staib und Duncan [83] auf 3D erweitert worden.

### 3.2.8 *T-Snakes*

Die impliziten Aktiven Konturen können topologische Änderungen während der Verformung durchführen, die klassischen *Snakes* können dieses nicht. Daher haben McInerney und Terzopoulos [63] eine geschlossene elastische 2D Kontur entwickelt, die aus einer Anzahl von Knoten besteht, die wiederum durch anpassungsfähige Energien verbunden sind. Diese elastische Kurve ist eine diskrete Annäherung der klassischen *Snakes* und enthält alle *Snakes* Eigenschaften. Kombiniert werden die parametrischen *Snakes* mit einer Triangulierung, die den Bildraum in affine Simplexe zerlegt. Die affine Simplexzerlegung teilt den Bildraum  $R^2$  in zusammenhängende 2D Zellen auf. Während der Verformung des Modells unter dem Einfluss der externen und internen Kräfte wird das Modell bei jeder Iteration mit einer neuen Anzahl von Knoten und einer neuen Berechnung von Kräften neu reparametrisiert. Die Knoten können durch die Interaktion der Punkte des Modells mit Triangulation effizient berechnet werden. Dieses erlaubt dem Modell, relativ unabhängig von der Initialisierung zu sein und komplexe Topologien segmentieren zu können. Außerdem können topologische Transformationen durchgeführt werden, das heißt, dass Konturen auseinanderbrechen oder verschmelzen können (vgl. [63]). Von denselben Autoren [64] wurden die *T-Snakes* zu einem 3D Verfahren erweitert, welches T-Surfaces genannt wurde.

### 3.2.9 Überblick von *Snakes* Varianten mit zwei Startkonturen

Wie im Abschnitt 3.1.5 erwähnt, haben die klassischen *Snakes* Probleme beim Finden einer Zielkontur, wenn eine schlechte Initialisierung gesetzt wird. Außerdem ist es für den Benutzer schwierig die richtigen Parameter einzustellen. Gunn und Nixon [31] haben die Wahrscheinlichkeit, dass die Kontur bei einer schlechten Initialisierung während der Minimierung nur ein lokales Minimum findet, verringert, indem sie für die Initialisierung zwei Konturen setzen, die mit lokalen Forminformationen auch das Parametrisierungsproblem lösen. Diese *Snakes* Variation wurde *Dual Snakes* genannt. Bei diesem Verfahren werden zwei Startkonturen gesetzt: eine Startkontur, die sich von außen an das gesuchte Objekt annähert und eine weitere Startkontur, die sich von innen an das gesuchte Objekt annähert. Die beiden Konturen sind durch einen Zusatz der externen Energie miteinander verbunden und ziehen sich damit gegenseitig aus möglichen lokalen Minima heraus. Wenn beide Konturen dasselbe Equilibrium gefunden haben, befinden sie sich in einem globalen Minimum und die Kontur hat die Zielkontur erreicht. Weitere Erläuterungen der *Dual Snakes* sind in Abschnitt 3.2.10 und der *Dual-T-Snakes* in Abschnitt 3.2.11 nachzulesen.

Die klassischen *Snakes* haben Probleme schlauchförmige und röhrenförmige Objekte zu segmentieren. Mit einer Abwandlung der *Dual Snakes* ist es möglich Objekte mit naheliegenden parallelen Objektgrenzen zu segmentieren. Dafür wurden die *Twin-Snakes* von Kerschner [41] entwickelt. Bei den klassischen *Snakes* springt die Kontur bei Objektgrenzen, die nahe aneinander liegen, von einer Grenze zur anderen. Durch gemeinsame Anziehungskräfte, die ähnlich wie die *spring forces* wirken, wird die Kontur bis zu einem gewissen Abstand angezogen, ansonsten abgestoßen. Die externe Energie wird folgendermaßen berechnet:

$$E_{ext}(\mathbf{v}(s)) = \delta(s)(d(s) - d_0)^2 \quad (3.35)$$

wobei  $\delta(s)$  ein Gewichtungssparameter ist,  $d(s)$  die aktuelle Distanz zwischen einem Punkt auf der einen Kontur und dem korrespondierenden Punkt auf der anderen Kontur und  $d_0$  ist der vom Benutzer gewünschte Abstand (vgl. [26]). Die Distanz zwischen den beiden Konturen muss aber bekannt und möglichst konstant sein.

Als letztes sind noch die *Ribbon Snakes* [52] und die *Twin Ribbons Snakes* [1] zu erwähnen. Die *Ribbon Snakes* gehen von einer Mittellinie  $\mathbf{v}(s)$  aus, die mit der Hälfte der Breite  $w(s)$  des aktuellen Objektes assoziiert wird und damit die beiden Grenzen  $\mathbf{v}_L(s)$  und  $\mathbf{v}_R(s)$  berechnet. Die Bildenergie wird dabei folgendermaßen berechnet:

$$E_{image}(\mathbf{v}(s)) = (\nabla I(\mathbf{v}_L(s)) - \nabla I(\mathbf{v}_R(s))) \cdot \mathbf{n}(s) \quad (3.36)$$

wobei  $\mathbf{n}(s)$  die Normale der Mittellinie  $\mathbf{v}(s)$  ist und  $\nabla I$  beschreibt den

Bildgradienten. Nachteil dieses Verfahrens ist, dass der Benutzer keine Breite angeben kann.

Bei den *Twin Ribbon Snakes* werden zwei Startkonturen innerhalb der Kontur gesetzt, die von innen das gesuchte Objekt segmentieren, und zwei Startkonturen, die sich von außen an das Objekt annähern. Dadurch ist das Verfahren robust gegenüber Rauschen und Lücken im Objekt. Das Verfahren weist aber eine hohe Rechenzeit auf.

Ghorbel et al. [26] haben die *parallel double Snakes* entwickelt um dünne Schichten der Retina des Auges zu segmentieren. Der Algorithmus geht von einer vom Benutzer gesetzten Mittellinie  $\mathbf{v}(s) = (x(s), y(s))$  aus. Durch Iterationen und das immer wieder neue Setzen des lokalen halben Abstandes  $b(s)$  zwischen den beiden Konturen werden die beiden Konturen berechnet. Die *parallel double Snakes* reduzieren die Komplexität und die Anzahl der Parameter. Im Vergleich zu einer manuellen Segmentierung liefert der Algorithmus sehr ähnliche Ergebnisse (vgl. [26]).

Zur Segmentierung von Lumen der Aorta wird nur eine Kontur gesucht und daher werden die *Dual Snakes* verwendet. Ein Spezialfall ist aber bei der Aortenpathologie Dissektion vorzufinden, da sich zwischen dem wahren und dem falschen Lumen eine Membran befindet. Im Abschnitt 4.5.4 wird beschrieben, wie dieses Problem gelöst werden kann.

### 3.2.10 *Dual Snakes*

Die *Dual Snakes* gehen von zwei parametrischen *Snakes* aus, wovon sich eine innerhalb des gesuchten Objektes und eine außerhalb befindet.

#### 3.2.10.1 Algorithmus

Im ersten Schritt werden die beiden Konturen solange verformt, bis beide ein Minimum erreicht haben. Verformt werden sie durch Formeinschränkung der internen Kräfte und Eigenschaften des Bildes, die durch die externen Kräfte gegeben sind. Wenn beide Konturen stationär werden, also sich nicht mehr bewegen, dann werden folgende Schritte durchgeführt (vgl.[31]):

1. Es wird berechnet, welche Kontur die größte Gesamtenergie hat. Diese Kontur hat ein lokales Minimum gefunden und wird weiterverarbeitet.
2. Die Kontur, die sich in einem lokalen Minimum befindet, wird mit zusätzlichen Kräften, den sogenannten *adaptiven driving forces* aus dem lokalen Minimum in Richtung der anderen Kontur gezogen. Die Verformung der Kontur wird dabei mit "bergsteigenden" Eigenschaften ausgestattet.

$$f_{driving}(t) = g(t) \cdot \frac{\mathbf{u}_i - \mathbf{v}_i^t}{|\mathbf{u}_i - \mathbf{v}_i^t|} \quad (3.37)$$

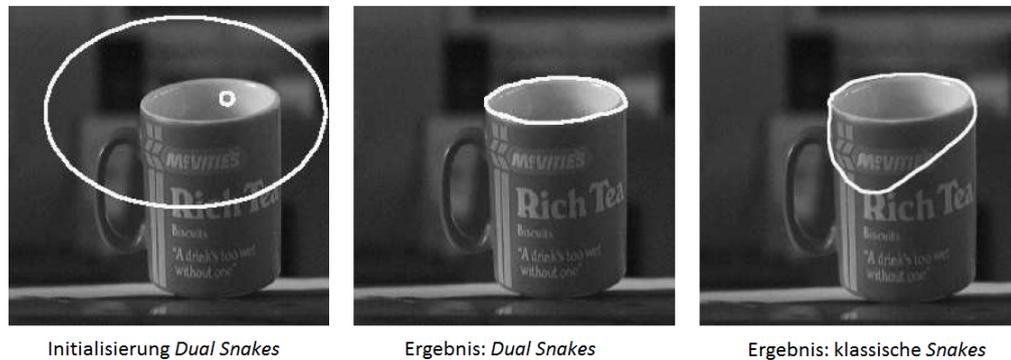
In der Formel ist zu erkennen, dass die innere Kontur  $\mathbf{u}$  und die äußere Kontur  $\mathbf{v}$  in dieser Kraft miteinander verbunden sind. Die Berechnung der korrespondierenden Punkte  $\mathbf{v}_i$  und  $\mathbf{u}_i$  erfolgt mittels der *arc length correspondence*, welche mit Hilfe der Länge der unregelmäßigen Abstände der Konturpunkte die nächsten Konturpunkte der anderen Kontur berechnet. Gewichtet wird die Formel durch die Funktion  $g(t)$ . Je größer Funktion  $g(t)$  ist, desto stärker zieht diese die Kontur an die korrespondierenden Punkte.

3. Wenn die Energie der Kontur kleiner als die Energie der anderen Kontur ist, werden die *adaptiven driving forces* auf Null gesetzt und die Kontur wird solange weiterverformt, bis sie stationär wird und sie folglich ein besseres Minimum gefunden hat.
4. Die Schritte 1-3 werden solange wiederholt, bis beide Konturen das gleiche Equilibrium gefunden haben.

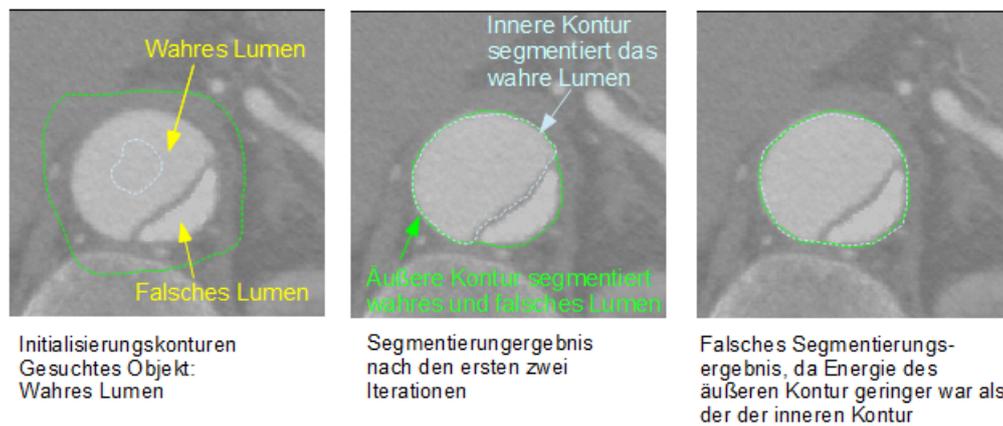
### 3.2.10.2 Vor- und Nachteile

Auf Grund der *adaptiven driving forces* findet die Kontur während der Energieminimierung kein lokales Minima und daher kann die Startkontur weiter entfernt vom Objekt gesetzt werden. In Abbildung 3.6 wird die Trinköffnung einer Tasse einmal mit den *Dual Snakes* und einmal mit den klassischen *Snakes* segmentiert. Dabei ist zu erkennen, dass die *Dual Snakes* die Trinköffnung segmentieren können, aber die klassischen *Snakes* ein lokales Minimum in der Nähe der Beschriftung der Tasse finden. Desweiteren haben die klassischen *Snakes* Schwierigkeiten eine offene Kontur auf Grund der internen Kräfte zu segmentieren. Bei der internen Energie der *Dual Snakes* wird das Problem gelöst, indem die beiden Endpunkte keine interne Energie erhalten (vgl. [31]). Auf der anderen Seite benötigt die Methode mehr Rechenzeit, da zwei Konturen verformt werden. Auch müssen die Parameter sowohl für die innere als auch für die äußere Kontur separat gesetzt werden.

**Schwierigkeiten bei der Segmentierung des wahren und falschen Lumens mit *Dual Snakes*** Für die *Dual Snakes* werden, wie schon erwähnt, zwei Konturen gesetzt, eine innerhalb und eine außerhalb der Kontur. Im Falle der Segmentierung einer Dissektion bei einer Aorta haben eigene initiale Experimente gezeigt, dass keine zwei Startkonturpaare in das wahre und falsche Lumen gesetzt werden können. Die Problematik besteht darin, dass die äußere Kontur vom Benutzer zu groß gewählt wird und das Ergebnis der Segmentierung eine Zielkontur ist, die sowohl das wahre als auch das falsche Lumen beinhaltet. Dieser Fall tritt ein, wenn die äußere Kontur, die sowohl das wahre



**Abbildung 3.6:** Segmentierung einer Tasse mittels der *Dual Snakes* und der klassischen *Snakes* (aus [31]).



**Abbildung 3.7:** Schwierigkeiten bei der Segmentierung einer Aortendisektion

als auch das falsche Lumen segmentiert hat, eine geringere Gesamtenergie als die innere Kontur hat, die nur eins von den beiden Lumen segmentiert hat. Die innere Kontur wird von der äußeren Kontur angezogen und es werden beide anstatt des wahren Lumens segmentiert (s. Abbildung 3.7). In Abschnitt 4.5.3.2 wird eine Lösung des Problems beschrieben.

### 3.2.11 *Dual-T-Snakes*

Eine wichtige Erweiterung der *T-Snakes* sind die *Dual-T-Snakes*, die von Giralardi et al. [28] entwickelt wurden. Es werden wie bei den *Dual Snakes* (s. Abschnitt 3.2.10) eine Kontur außerhalb und eine Kontur innerhalb des gesuchten Objektes initialisiert. Bei den *Dual-T-Snakes* können sogar mehrere Objekte gleichzeitig segmentiert werden, sodass die äußere Kontur ihre Initialisierung außerhalb von mehreren Objekten und jeweils eine Startkontur innerhalb der

Objekte gesetzt wird. Zur Segmentierung mehrerer Objekte werden normalisierte externe Kräfte und eine affine Abgrenzung verwendet. Für den Benutzer ist es vorteilhaft, dass die topologischen Eigenschaften der *T-Snakes* verwendet werden können und dass die Kontur über lokale Minima geschoben wird. Da kein Mindestabstand zwischen zwei Objekten definiert ist, kann es bei der Anwendung auf Aortendissektionen sein, dass die Membran zwischen den beiden Lumen nicht erkannt wird.

### 3.2.12 Erweiterung der externen Kräfte der *Snakes*

Einige Probleme der klassischen *Snakes*, wie die Initialisierung, die Bestimmung der Stoppkriterien und die Segmentierung von konkaven Objekten, können gelöst werden, indem die externen Kräfte modifiziert werden. Die externen Energien werden so angepasst, dass der Einzugsbereich der deformierbaren Modelle und die Kräfte in Richtung der Bildränder verbessert werden.

Amarapur und Kulkarni [2] beschreiben 19 Erweiterungen der externen Kräfte der Kontur und vergleichen die Ergebnisse der Verfahren mit Bildern des gleichen Aufnahmeverfahrens. Auf Grund der Vielzahl an Methoden, die Amarapur und Kulkarni in ihrer Arbeit beschrieben haben, wird in dieser Arbeit nur auf die Methoden eingegangen, die auf CTA- und MRT-Aufnahmen angewendet worden sind. Ausgeschlossen wurden die Verfahren, die speziell Ultraschall-Aufnahmen segmentieren, da diese Aufnahmen stark verrauscht sind und dadurch andere externe Energien benötigen. In Abbildung 3.3 sind alle weiteren Verfahren aufgelistet.

#### 3.2.12.1 Gradient vector flow (GVF) *Snakes*

Xu und Prince [97] haben 1998 die *GVF-Snakes* entwickelt um Probleme der klassischen *Snakes*, wie der Initialisierung nahe der Objektkontur und einer schlechten Annäherung an konkave Objektgrenzen, zu minimieren. Zurückzuführen sind diese Probleme auf die schlechten Eigenschaften der externen Energien, die auf Grundlage des Bildes oder des Gradienten Kantenfeldes berechnet werden. Xu und Prince entwickelten eine neue externe Kraft, welche sie *gradient vector flow* nannten.

**Minimierung** Bei den *GVF-Snakes*, genauer bei den externen Kräften der *GVF-Snakes*, existieren auf Grund deren Definition keine negativen Gradienten der Potenzialfunktion. Daher kann das standardisierte Minimierungsverfahren nicht eingesetzt werden. Die Minimierung erfolgt direkt aus den Bedingungen des Kräftegleichgewichtes

$$f_{int}(\mathbf{v}(s)) + f_{ext}(\mathbf{v}(s)) = 0 \quad (3.38)$$

wobei  $f_{int}(\mathbf{v}(s)) = \alpha \mathbf{v}''(s) - \beta \mathbf{v}''''(s)$  und  $f_{ext}$  die Kraft des *gradient vector flow* ist (vgl. [97]).

**Edge Map** Zur Berechnung des *gradient vector flow* wird eine *image edge map* Funktion  $e(x, y)$  verwendet. Diese Funktion besitzt hohe Werte in der Nähe von Kanten und geringe Werte bei Regionen mit einer homogenen Intensität (vgl. [7]).

Die *edge map* sieht folgendermaßen aus:

$$e(x, y) = -E_{ext}^{(i)}(x, y) \quad (3.39)$$

Bei der Wahl des *edge map* müssen drei generelle Eigenschaften bei den *GVF-Snakes* erfüllt sein (vgl. [97]).

1. Der Gradient einer *edge map* hat Vektoren, die zu den Kanten zeigen.
2. Die Vektoren haben große Werte in der Nähe von Kanten und geringere Werte in homogenen Regionen.
3. In homogenen Regionen, in denen  $I(x, y)$  nahezu konstant ist, ist  $e(x, y)$  nahe des Wertes Null.

**Gradient Vector Flow** Das *gradient vector flow field* wird definiert als Vektorfeld  $\mathbf{w}(x, y) = (u(x, y), w(x, y))^T$  und wird minimiert durch folgende Energiefunktion:

$$E_{snake}(\mathbf{w}(x, y)) = \iint (\mu(u_x^2 + u_y^2 + w_x^2 + w_y^2) + |\nabla e|^2 |\mathbf{w} - \nabla e|^2) dx dy \quad (3.40)$$

Der Parameter  $\mu$  steuert den Ausgleich des ersten Terms und sollte auf das Rauschen abgestimmt sein. Die *GVF-Snakes* werden von Xu und Prince [97] mit einem Variationsansatz gelöst. Dabei wird folgende Euler-Lagrange-Gleichung gelöst:

$$\mu \nabla^2 u - (u - e_x)(e_x^2 + e_y^2) = 0 \quad (3.41)$$

$$\mu \nabla^2 w - (w - e_x)(e_x^2 + e_y^2) = 0 \quad (3.42)$$

bei denen  $\nabla^2$  der Laplace-Operator ist.

**3D GVF-Snakes** Bei den *GVF-Snakes* ist eine Erweiterung in 3D möglich. Dabei ist zu beachten, dass in einem Vorverarbeitungsschritt mittels der Krümmungswerte an den Netzpunkten eine bevorzugte Entwicklungsrichtung der Kontur berechnet werden muss (vgl. [50]). Die Energiefunktion wird folgendermaßen berechnet:

$$E_{snake}(\mathbf{w}(x, y)) = \int \int \int (\mu(u_x^2 + u_y^2 + u_z^2 + w_x^2 + w_y^2 + w_z^2) + |\nabla e|^2 |\mathbf{w} - \nabla e|^2) dx dy dz \quad (3.43)$$

**Vor- und Nachteile** Die *GVF-Snakes* haben auf Grund des *gradient vector flow* einen großen Einzugsbereich, wodurch die Initialisierung der Kontur nicht nahe bei der Zielkontur liegen muss. Auch können die *GVF-Snakes* konkave Objekte segmentieren. Die besten Ergebnisse liefern die *Snakes* in binären Bildern. Der Anwender der *GVF-Snakes* muss nicht darauf achten, ob er die Initialisierung der Kontur nur innerhalb oder nur außerhalb des gesuchten Objektes setzt, die Kontur kann sowohl wachsen als auch schrumpfen. Die Minimierung des Initialisierungsproblems sollte man aber nicht überschätzen, da die *GVF-Snakes* bei einer schlechten Initialisierung mehr Zeit zum Konvergieren benötigen und es außerdem sein kann, dass die Kontur in einer homogenen Region ein Minimum findet (vgl. [50]).

Probleme sind auch, dass das Verfahren sensitiv gegenüber Rauschen ist und dass es keine langen und dünnen Objekte segmentieren kann. Die Kontur bewegt sich zu dem Ort im Bild, bei dem die externen Kräfte am geringsten sind. Es ist aber nicht immer der Fall, dass alle Pixel, die sich in einem Energieminimum befinden, wirkliche Kanten im Bild sind. Es können auch homogene Regionen sein, in denen die Kontur steckenbleibt (s. Abschnitt 4.5.5.1). Weiterhin hat der Ansatz eine hohe Rechenzeit. Üblicherweise werden die *GVF-Snakes* mittels der Variationsrechnung realisiert. Die Integration in eine andere Optimierungsmethode ist theoretisch möglich (vgl. [50]).

### 3.2.12.2 Veränderungen der externen Energien

Die *GVF-Snakes* wurden von Xu und Prince zu einer Verallgemeinerung des *gradient vector flow*, zu den *general gradient vector field Snakes* [96], weiterentwickelt. Die wünschenswerten Eigenschaften der *GVF-Snakes* bleiben in dem Verfahren erhalten und liefern desweiteren auch gute Ergebnisse bei ver-rauschten medizinischen Bildern. Die Energiefunktion wird für den 2D Fall folgendermaßen berechnet:

$$E_{GVF}(\mathbf{w}(x, y)) = \int \int (g(|\nabla e|)(u_x^2 + v_x^2 + w_y^2 + w_y^2) + (h(|\nabla e|))(\mathbf{w} - \nabla e)^2) dx dy \quad (3.44)$$

Xu and Prince [96] ersetzen  $\mu$  und  $|\nabla e|^2$  durch zwei räumlich variierende Gewichtungsfunktionen  $g(\cdot)$  und  $h(\cdot)$ , welche zur Verbesserung der Konvergenz der Konturen bei langen, dünnen Objekten führen. Berechnet werden die Gewichtungsfunktionen folgendermaßen:  $g(|\nabla e|) = \exp\left(-\left(\frac{|\nabla e|}{k}\right)\right)$  und  $h(|\nabla e|) = 1 - g(|\nabla e|)$ . Der Parameter  $k$  wird vom Benutzer gesetzt und kontrolliert die Härte der Glattheit des Kraftfeldes.

Gao und Chen [25] haben sich damit beschäftigt das Kantenfeld zu verbessern, indem sie das Bild mit einem Verfahren der generalisierten *Fuzzy-Theorie* bearbeiten. Dabei ersetzen sie das *gradient vector field* durch das *compound*

vector field wie folgt:

$$f_{ext} = p(\nabla e)V(x, y) + \psi(\nabla e)\nabla e \quad (3.45)$$

Dabei ist  $p(\nabla e) = \exp(-\nabla e)/k$  eine dynamische Gewichtungsfunktion, welche sicherstellt, dass das Kraftfeld eine wichtige Rolle spielt, und  $\psi(\nabla e) = 1 - \exp(-\nabla e)/k$  kontrolliert die Gradientenkraft, die die Bewegung der Kurve steuert. Die Autoren schreiben, dass der Algorithmus nicht nur gut die gesuchten Bildeigenschaften in größerer Entfernung findet, sondern auch konkave Regionen segmentieren kann.

Die externe Kraft der *GVF-Snakes* wurde auch von Sum und Cheung [86] weiterentwickelt, da sie die hohe Rechenzeit als Problem sahen. Das Verfahren wird *boundary vector field Snakes* genannt und erweitert den Erfassungsbereich durch Interpolation auf das gesamte Bild. Die *boundary map* basiert auf der bekannten externen Kraft und wird normalisiert:

$$f_B(x, y) = -|\nabla [G_\sigma(x, y) * I(x, y)]|^2 \quad (3.46)$$

Durch einen gesetzten Grenzwert wird die *boundary map* binarisiert, die verwendet wird um die vier Potenzialfunktionen  $\Psi_x, \Psi_y, \Psi_{xy}, \Psi_{yx}$  unabhängig voneinander zu berechnen. Dabei werden vier unabhängige „Scans“, die horizontal, vertikal und in den zwei Diagonalen entlang des zu segmentierenden Bildes führen, zur Berechnung der Linieninterpolation verwendet. Für den nächsten Schritt werden zwei 2D *boundary vector fields* (BVF), die auf den Gradienten der Potenzialfunktionen  $\Psi_x, \Psi_y, \Psi_{xy}, \Psi_{yx}$  basieren, definiert:

$$\phi_1 = [\nabla\Psi_x, \nabla\Psi_y] \quad (3.47)$$

$$\phi_2 = \left[ \frac{1}{\sqrt{2}}(\nabla\Psi_{xy} + \nabla\Psi_{yx}), \frac{1}{\sqrt{2}}(\nabla\Psi_{xy} - \nabla\Psi_{yx}) \right] \quad (3.48)$$

Die externe Energie wird durch die Anwendung der beiden BVFs berechnet. Nach Wang et al. [92] hat das Verfahren den Nachteil, dass es wie die *GVF-Snakes* keine stark konkaven Objekte segmentieren kann, da das externe Kraftfeld statisch ist.

Das letzte Verfahren, das auf MRT Aufnahmen angewendet worden ist, ist die *fluid vector flow Snakes* (*FVF Snakes*). Diese wurden von Wang et al. [92] entwickelt. Sie verbessern ebenfalls den Erfassungsbereich der externen Energie. Die *boundary map*  $M_B(x, y) = |\nabla(-G_\sigma(x, y) * I(x, y))|$  basiert wiederum auf den konventionellen externen Kräften und wird durch folgende Normalisierung berechnet:

$$M_{NB}(x, y) = \frac{M_B(x, y) - \min(M_B(x, y))}{\max(M_B(x, y)) - \min(M_B(x, y))} \quad (3.49)$$

Es wird genauso wie bei den *FVF Snakes* eine *binary boundary map* erstellt:

$$M_{BB}(x, y) = \begin{cases} 1, & \text{wenn } M_{NB}(x, y) > T \\ 0, & \text{sonst.} \end{cases} \quad (3.50)$$

Die externe Energie wird folgendermaßen berechnet:

$$E_{FVF}(x, y) = \begin{cases} \chi(f_x + \delta \cos \phi, f_y + \delta \sin \phi), & \text{wenn } M_{BB}(x, y) = 0 \\ 0, & \text{sonst.} \end{cases} \quad (3.51)$$

Dabei ist  $\chi$  der Normalisierungsoperator und  $\delta = \pm 1$  bestimmt die Richtung, in der nach dem Minimum im Bild gesucht wird.  $(f_x, f_y) = \chi(\nabla I(x, y))$  und

$$\phi = \begin{cases} \arctan\left(\frac{y-y_c}{x-x_c}\right), & \text{wenn } x \neq x_c \\ \frac{\pi}{2}, & \text{wenn } x = x_c \text{ und } y > y_c \\ \frac{3\pi}{2}, & \text{wenn } x = x_c \text{ und } y < y_c \end{cases} \quad (3.52)$$

wobei  $\phi \in [0, 2\pi]$ . Die externe Energie hat eine Gradientenbetrags- und eine Richtungskomponente. Das Charakteristische an den *FVF Snakes* sind die Richtungskomponenten, die dominieren, wenn die Kontur weit von dem Objekt entfernt ist. Wenn sich die Kontur nahe an einer Kante befindet, dann wirken die Gradientenkräfte und die Kontur findet ein Minimum. Auf Grund der binären *boundary map* des *FVF* ist der Erfassungsbereich auf das ganze Bild erweitert worden. Trotzdem kann es sein, dass die Kontur das falsche Minimum findet, falls sich die Startkontur zu weit weg von dem gesuchten Objekt befindet.

Wang et al. [92] vergleichen den Erfassungsbereich des *BVFs* mit dem des *FVFs* und haben dabei festgestellt, dass der Erfassungsbereich der *FVF* effektiver ist als der der *BVFs*. Die *FVF* benötigen keine Interpolation, da sie im Gegensatz zu den *BVF* richtungsinvariant sind. Das Verfahren wurde nur in 2D implementiert.

Xiaoping et al. [95] haben das Verfahren der *Deformable super ellipses Snakes* entwickelt und haben es unter anderem zur Segmentierung von Objekten in CT-Aufnahmen angewendet. Die Superellipse ist eine flexible Repräsentation von natürlich generalisierten Ellipsen, die verschiedene Formen annehmen können. Die Parameter für die Segmentierung mittels der Kontur werden durch die statistische Analyse der Trainingsdaten berechnet. Mit Hilfe des *Hybrid Genetic Optimization* Algorithmus wird die optimale Superellipse berechnet und das *Snakes*-Verfahren segmentiert das Objekt mit Hilfe der Forminformationen der optimalen Superellipse, die in die externe Energie bzw. Kräfte des *Snakes*-Verfahrens eingearbeitet ist. Der Vorteil dieses Verfahrens ist, dass die Initialisierung im Vergleich zu anderen Verfahren weniger sensitiv und robuster gegenüber Lücken in Kanten ist.

### 3.2.12.3 Alternative externe Kräfte

In Abbildung 3.3 werden noch folgende alternative Weiterentwicklungen der externen Kräfte der Kontur aufgeführt: die *Adaptive Pressure Snakes* [12], *Merging deformable Snakes* [78], *Discrete cosine transform based GVF-Snakes* [87], *Edge Preserving Gradient Vector Flow Snakes (EPGVF)* [55], *Directional Gradient Vector Flow Snakes (DGVF)* [77], *Dynamic Directional Gradient Vector Flow Snakes (DDGVF)* [14], *Vector Field Convolution Snakes (VFC)* [54], *Improved Compound Vector Field Snakes* [25], *Deformable super ellipses Snakes* [95], *Simulated Static Electric Field Snakes (SSEF)* [98], *Virtual electric field Snakes* [76] und *Self-Affine Snakes* [79].

### 3.2.13 Vergleich der Verfahren

Die bekannteste Erweiterung der klassischen *Snakes* ist das *Balloon* Modell (s. Abschnitt 3.2.1). Es ist dafür entwickelt worden, dass die Kontur schwache Objektkanten ignoriert und zu stärkeren Kanten gezogen wird. Die Kontur kann aber zum Finden der Objektkonturen entweder nur wachsen oder schrumpfen. Da das Verfahren ansonsten alle anderen Probleme der klassischen *Snakes* aufweist und da es sein kann, dass der Anwender die Kontur nicht genau innerhalb oder außerhalb des gesuchten Objektes setzt, ist dieses Verfahren zur Segmentierung der Aortenpathologien ungeeignet.

Die *Fuzzy Snakes* (s. Abschnitt 3.2.2) erscheinen als eine für die Aortenpathologiesegmentierung passende Problemlösung. Die unterschiedlichen Formen und Bildhelligkeiten können vom Benutzer durch linguistische Variablen eingegeben werden und die Kontur wird in Segmente mit unterschiedlichen Kräften unterteilt. Ein Vorteil ist, dass sich die Beschreibungen auf Bildern mit ähnlichen Objekten und Bildeigenschaften anwenden lässt. Da die CTA-Aufnahmen der Aortenpathologien meist große Unterschiede aufzeigen, kann es jedoch sein, dass Beschreibungen der Objekte häufig angepasst oder neu erstellt werden müssen.

Die *B-Snakes* (s. Abschnitt 3.2.3) haben den Vorteil gegenüber den klassischen *Snakes*, dass sie eine geringe Anzahl von Koeffizienten benötigen und dadurch weniger rechenintensiv sind. Durch einen Glättungsparameter kann auch die Glattheit der Kontur angepasst werden. Der Nachteil dieses Verfahrens ist, dass die Kontur anstatt eines globalen Minimums ein lokales Minimum oder gar kein Minimum findet.

Die *AB-Snakes* (s. Abschnitt 3.2.5) werden von den Entwicklern als ein Verfahren beschrieben, das dünne und komplexe Objekte segmentieren kann und robust gegenüber Rauschen ist. Doch eigene initiale Versuche haben gezeigt, dass ohne eine Vorverarbeitung, z.B. mit einem Gaußfilter, Objekte in Bildern mit schwachem Rauschen nicht segmentiert werden können.

Die *Ziplock Snakes* (s. Abschnitt 3.2.6) könnten die unterschiedlichen Aortenpathologien in CTA-Aufnahmen segmentieren. Sie haben den Vorteil, dass sich die Kontur ausgehend von den Endpunkten wie ein Reißverschluss an das gesuchte Objekt heranbewegt. Da bei den Aufnahmen andere Strukturen häufig nahe des gesuchten Objektes liegen, die ähnliche Bildeigenschaften wie das gesuchte Objekt haben, könnte diese Kontur das Objekt segmentieren. Die Frage ist, wie sich die Kontur verhält, wenn sich Kanteneigenschaften ändern. Desweiteren ist zu berücksichtigen, dass dieses Verfahren die Energie nur offene *Snakes* minimiert.

Die *T-Snakes* (s. Abschnitt 3.2.8) können Objekte segmentieren, bei denen die Topologie vorher noch nicht bekannt ist und mehrere Objekte gleichzeitig segmentieren. Da mit dem Verfahren sowohl ein Aortenaneurysma als auch eine Aortendissektion möglichst automatisch und genau segmentiert werden soll, könnte dieses Verfahren zur Segmentierung eingesetzt werden. Problematisch ist, dass nicht definiert ist, welchen Mindestabstand die Objekte voneinander haben müssen, damit sich die äußere Kontur in zwei Teile aufteilen kann. Da die Wand zwischen dem wahren und falschen Lumen dünn ist, könnte es sein, dass diese nicht erkannt wird und sich vielleicht sogar die beiden inneren Konturen zu einer Kontur zusammenschließen. Dieses Problem ist auch bei den *Dual-T-Snakes* (s. Abschnitt 3.2.11) vorhanden.

Auch die in dieser Arbeit benutzten *Dual Snakes* (s. Abschnitt 3.2.10) und *GVF-Snakes* (s. Abschnitt 3.2.12.1) weisen einzeln Probleme auf. So haben die *Dual Snakes* das Problem, dass für beide Konturen unterschiedliche Parameter gesetzt werden müssen. Die *GVF-Snakes* sind sensitiv gegenüber Rauschen und es ist nicht gewährleistet, dass ein globales Minimum gefunden wird. Durch die Kombination der beiden Verfahren werden die Konturen aus lokalen Minima gezogen, da sich die beiden Konturen gegenseitig anziehen.



# Kapitel 4

## Methode

In diesem Kapitel wird das hier entwickelte Verfahren der *Dual-GVF-Snakes* für die Segmentierung der Aortenpathologien Aortenaneurysma und Aortendissektion erläutert. Dabei wird sowohl darauf eingegangen, wie das Modell umgesetzt worden ist, als auch beschrieben, wie das Modell der *Dual-GVF-Snakes* kombiniert und erweitert worden ist um die Aortenpathologien segmentieren zu können.

### 4.1 Motivation

Ziel dieser Arbeit ist es ein Verfahren zu entwickeln, das die Lumen der Aorta und der Aortenpathologien der Aortendissektion und des Aortenaneurysmas möglichst automatisch in CTA-Aufnahmen segmentieren kann. In Abbildung 4.1 werden beispielhaft axiale Schichtaufnahmen einer Aorta, eines Aortenaneurysmas und mehrerer Aortendissektionen dargestellt. Die Schwierigkeit der Segmentierung von Lumen in CTA-Aufnahmen ist, dass besonders die Formen der Lumen der Aortendissektion variabel sind. Der Kontrast im Bild ist in verschiedenen Regionen unterschiedlich und Strukturen mit stärkeren oder ähnlichen Kanten sind in der Nähe des gesuchten Objektes vorzufinden. Jedes Bild ist mit Rauschen überlagert. Desweiteren sollte das Verfahren möglichst automatisch die Segmentierung durchführen können und falls nötig sollen Benutzerinteraktionen hinzugefügt werden.

In Kapitel 2 wurden die folgenden drei Klassen der deformierbaren Modelle vorgestellt: implizite und explizite Aktive Konturen und die *Active Shape Models*. Dabei stellte sich heraus, dass für die *Active Shape Models* eine geeignete Menge von Formvariationen des Aortenaneurysmas und der Aortendissektion in einer Datenbank gespeichert sein muss, damit gute Segmentierungsergebnisse erreicht werden können. Da aber die Form der Aortendissektion viele unterschiedliche Formen annehmen kann, ist dieses Verfahren für die Segmentierung der Aortendissektion nur mit großem Aufwand einsetzbar. Eine Segmentierung

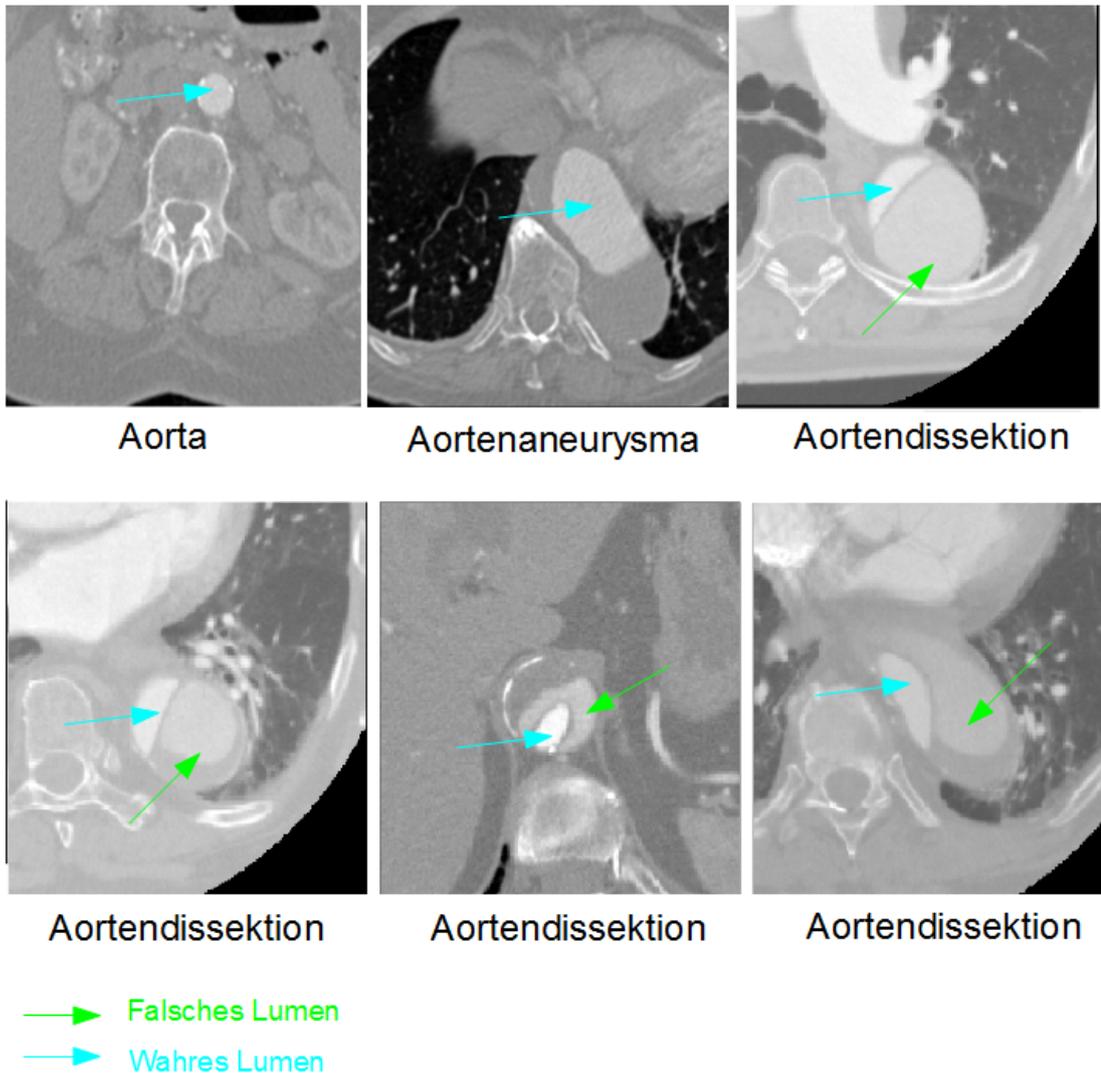


Abbildung 4.1: CTA-Aufnahmen der Aorta

mittels der *Level Set* Methode ist prinzipiell möglich, hat aber den Nachteil, dass das Verfahren zur Auffindung der Aortenpathologie selbst mit den Erweiterungen der *Fast-Marching-Methode* [80] oder der *Narrow-Band-Methode* [75] viel Zeit benötigt und dass keine zusätzlichen Benutzerinteraktionen hinzugefügt werden können. Die *Snakes* haben den Nachteil, dass die Initialisierung nahe an dem gesuchten Objekt gesetzt werden muss und dass keine topologischen Veränderungen während der Iterationen möglich sind. Da sich während der Segmentierung der Aortenpathologien die Topologie nicht ändern muss und da das Problem der Initialisierung durch Erweiterungen der *Snakes*, wie den *Dual* und den *GVF-Snakes*, gelöst werden können, wurden die *Snakes* für die Realisierung des Algorithmus verwendet.

Initiale Experimente mit den klassischen *Snakes*, den *GVF-Snakes* und den *AB-Snakes* haben gezeigt, dass besonders die klassischen *Snakes* und die *AB-Snakes* Probleme haben Bilder mit Rauschen zu segmentieren. Die Optimierungsverfahren finden meistens nur ein lokales Minimum. Die *GVF-Snakes* werden auf Grund des *gradient vector flow* von weitem zu der gesuchten Kontur gezogen und daher tritt seltener das Problem auf, dass die Kontur ein lokales Minimum findet. Untersuchungen in Kapitel 3 haben gezeigt, dass auch die *Balloon Snakes*, die *Fuzzy Snakes*, die *B-Snakes*, die *Ziplock Snakes* und die *T-Snakes* eher ungeeignet sind die Aortenpathologien in CTA-Aufnahmen zu segmentieren. Eine Kombination zwischen den *Dual* und *GVF-Snakes* ist vielversprechend, da die *Dual Snakes* das Problem der *GVF-Snakes* löst, dass ein lokales Minimum anstatt eines globalen Minimums gefunden wird. Versuche mit den *Dual Snakes* haben gezeigt, dass die Kontur viele Iterationsschritte benötigt um das globale Minimum zu finden. Das liegt daran, dass die Kontur auf Grund von Rauschen immer wieder ein lokales Minimum findet. Um die Anzahl der Iterationsschritte zu verringern müssten die Initialisierungen der beiden Kurven nahe an das gesuchte Objekt gesetzt werden. Daher wird in dieser Arbeit das *gradient vector field* genutzt um die externen Kräfte und Energie zu berechnen und um damit den Einzugsbereich zu vergrößern.

In dem hier vorgestellten neuen Verfahren werden erstmalig die *Dual Snakes* mit den *GVF-Snakes* kombiniert. Zusätzlich können mehrere Objekte gleichzeitig segmentiert werden. Um dies zu realisieren wird die Kontur in Segmente unterteilt. Eine Aufteilung der Kontur in Segmente wurde schon bei den *Ziplock Snakes* (s. Abschnitt 3.2.6) realisiert, die die Kontur in mehrere Segmente unterteilen und den Segmenten unterschiedliche Kräfte zuweisen. Damit kann die Kontur ein besseres Energieminimum finden. In dieser Arbeit wurde die Kontur in Segmente aufgeteilt, damit eine Segmentierung mit zwei oder mehreren Startkonturen möglich ist. Es wird ein Abstand zwischen den beiden Kontursegmenten benötigt, der die Membran zwischen den beiden Lumen darstellt. Dafür werden die *adaptive driving forces* (s. Abschnitt 3.2.10) modifiziert, indem für die aktuelle innere Kontur die korrespondierenden Punkte der anderen inneren Konturen versetzt werden. Anschließend erfolgt die Mini-

mierung. Damit wird die Kontur, die verformt wird, zwar in die Richtung der anderen Kontur gezogen, wird aber durch die Anziehungskräfte der korrespondierenden Punkte davon abgehalten, das Energieminimum an derselben Kante zu finden.

## 4.2 Übersicht über das Verfahren

Die *Dual-GVF-Snakes* gehen von einer äußeren und einer inneren oder einer äußeren und mehreren inneren Startkontur/-en aus. Nach der Initialisierung und dem Setzen der Parameter wird das *gradient vector field* berechnet. Die *Snakes* mit zwei oder drei Konturen werden prinzipiell gleich verformt, doch auf Grund der Segmenteinteilung und der Entscheidung, welche der zwei oder drei Konturen verformt wird, wird die Energieminimierung in zwei separate Prozesse eingeteilt (s. Abbildung 4.2). Für die Energieminimierung von drei Konturen werden die Konturen in Segmente unterteilt und mit Hilfe dieser Segmente werden die korrespondierenden Punkte der einen Kontur mit der anderen Kontur berechnet. Da zwischen den beiden inneren Konturen eine Membran liegt, werden die korrespondierenden Punkte der Segmente, die an der Membran liegen, für die Minimierung der anderen Kontur verschoben. Dieser Schritt hilft der Kontur bei der Minimierung einen Abstand zwischen den beiden Segmentabschnitten zu definieren. Die Energieminimierung erfolgt wie bei den *Dual Snakes* (s. Abschnitt 3.2.10.1). Der Unterschied besteht darin, dass die externen Kräfte mit Hilfe des *gradient vector flow* berechnet werden. Zur Energieminimierung werden die Variationsrechnung angewendet. Die Verformungen von zwei und drei Konturen wird in Abbildung 4.2 als Teilprozesse dargestellt, die in Abschnitt 4.5 erläutert werden.

## 4.3 *GVF-Snakes*

### 4.3.1 Externe Energie: *GVF-Snakes*

Eine Beschreibung der Methode und der Vor- und Nachteile der *GVF-Snakes* wurde in Abschnitt 3.2.12.1 gegeben. In diesem Abschnitt wird die Berechnung der externen Energie nach Xu und Prince [97] dargestellt. Wie schon erwähnt, wird das *gradient vector flow field* als ein Vektorfeld  $\mathbf{w}(x, y) = (u(x, y), w(x, y))^T$  und die *edge map* als  $e(x, y) = -E_{ext}(x, y)$  definiert, wobei  $i = 1, 2, 3$  oder  $4$ . Minimiert wird folgendes Energiefunktional:

$$E_{snake}(\mathbf{w}(x, y)) = \iint (\mu(u_x^2 + u_y^2 + w_x^2 + w_y^2) + |\nabla e|^2 |\mathbf{w} - \nabla e|^2) dx dy. \quad (4.1)$$

Der Parameter  $\mu$  ist ein Regularisierungsparameter, der den Ausgleich zwischen dem ersten und zweiten Term steuert. Je mehr Rauschen ein Bild ent-

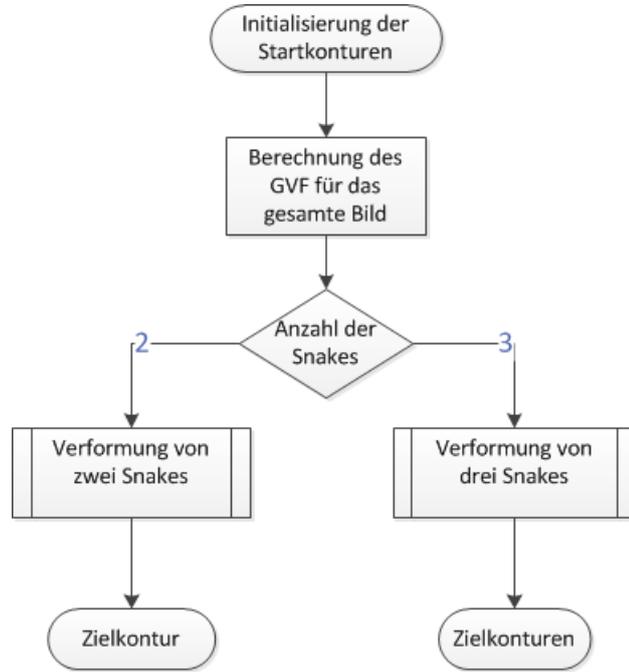


Abbildung 4.2: Allgemeiner Überblick des *Dual-GVF-Snakes* Verfahrens

hält, desto größer wird  $\mu$  gewählt. Die Indizes  $x$  und  $y$  bezeichnen die erste partielle Ableitung, so ist z. B.  $u_x = \frac{\partial u(x,y)}{\partial x}$ . Zur Berechnung wird die Variationsrechnung verwendet und folgende Euler-Lagrange-Gleichungen müssen gelöst werden:

$$\mu \nabla^2 u - (u - e_x)(e_x^2 + e_y^2) = 0 \quad (4.2)$$

$$\mu \nabla^2 w - (w - e_y)(e_x^2 + e_y^2) = 0 \quad (4.3)$$

wobei  $\nabla^2$  der Laplace-Operator ist.  $u$  und  $w$  werden durch die Laplace-Gleichung bestimmt und das resultierende *gradient vector field* wird aus den Regionengrenzen interpoliert.

**Numerische Implementierung** (4.2) und (4.3) werden gelöst, indem  $u$  und  $w$  als Funktionen der Zeit betrachtet und gelöst werden:

$$u_t(x, y, t) = \mu \nabla^2 u(x, y, t) - [u(x, y, t) - e_x(x, y)] \cdot [e_x(x, y)^2 + e_y(x, y)^2] \quad (4.4)$$

$$w_t(x, y, t) = \mu \nabla^2 w(x, y, t) - [w(x, y, t) - e_y(x, y)] \cdot [e_x(x, y)^2 + e_y(x, y)^2] \quad (4.5)$$

Diese Gleichungen werden *generalized diffusion equations* genannt und beinhalten die wünschenswerten Eigenschaften der externen Energie. Als Vereinfachung werden (4.4) und (4.5) folgendermaßen umgeschrieben:

$$u_t(x, y, t) = \mu \nabla^2 u(x, y, t) - b(x, y)u(x, y, t) + c_1(x, y) \quad (4.6)$$

$$w_t(x, y, t) = \mu \nabla^2 w(x, y, t) - b(x, y)w(x, y, t) + c_2(x, y) \quad (4.7)$$

wobei

$$b(x, y) = e_x(x, y)^2 + e_y(x, y)^2 \quad (4.8)$$

$$c_1(x, y) = b(x, y)e_x(x, y) \quad (4.9)$$

$$c_2(x, y) = b(x, y)e_y(x, y) \quad (4.10)$$

Zur Berechnung der iterativen Lösung korrespondieren die Indizes  $i, j$  und  $m$  mit den Indizes  $x, y$  und  $t$ . Der Abstand zwischen den Pixeln ist  $\Delta x$  und  $\Delta y$  und der Zeitschritt für jede Iteration ist  $\Delta t$ . Die notwendigen partiellen Ableitungen können durch folgende Diskretisierung angenähert werden:

$$u_t = \frac{1}{\Delta t}(u_{i,j}^{m+1} - u_{i,j}^m) \quad (4.11)$$

$$w_t = \frac{1}{\Delta t}(w_{i,j}^{m+1} - w_{i,j}^m) \quad (4.12)$$

$$\nabla^2 u = \frac{1}{\Delta x \Delta y}(u_{i+1,j} + u_{i,j+1} + u_{i-1,j} + u_{i,j-1} - 4u_{i,j}) \quad (4.13)$$

$$\nabla^2 v = \frac{1}{\Delta x \Delta y}(w_{i+1,j} + w_{i,j+1} + w_{i-1,j} + w_{i,j-1} - 4w_{i,j}) \quad (4.14)$$

Durch den Austausch der Diskretisierung(4.11, 4.12, 4.13 und 4.14) sehen (4.6) und (4.7) folgendermaßen aus:

$$\begin{aligned} u_{i,j}^{m+1} &= (1 - b_{i,j}\Delta t)u_{i,j}^m + r(u_{i+1,j}^m + u_{i,j+1}^m + u_{i-1,j}^m + u_{i,j-1}^m - 4u_{i,j}^m) \\ &\quad + c_{i,j}^1 \Delta t \end{aligned} \quad (4.15)$$

$$\begin{aligned} w_{i,j}^{m+1} &= (1 - b_{i,j}\Delta t)w_{i,j}^m + r(w_{i+1,j}^m + w_{i,j+1}^m + w_{i-1,j}^m + w_{i,j-1}^m - 4w_{i,j}^m) \\ &\quad + c_{i,j}^1 \Delta t \end{aligned} \quad (4.16)$$

wobei

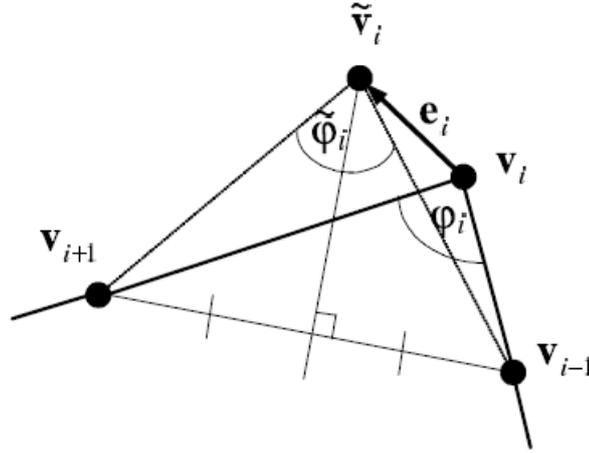
$$r = \frac{\mu \Delta t}{\Delta x \Delta y} \quad (4.17)$$

Xu und Prince [97] erwähnten, dass die Konvergenz des beschriebenen iterativen Verfahrens durch das Ergebnis der numerischen Methode von Ames [3] garantiert wird. Da  $\Delta x$ ,  $\Delta y$  und  $\mu$  auf Grund von  $r$  in (4.17) festgelegt werden, muss folgende Gleichung für den Zeitschritt  $\Delta t$  eingehalten werden.

$$\Delta t \leq \frac{\Delta x \Delta y}{4\mu} \quad (4.18)$$

## 4.4 Dual Snakes

Eine Beschreibung der Methode und der Vor- und Nachteile der *Dual Snakes* von Gunn und Nixon [31] wurde in Abschnitt 3.2.10 gegeben. In diesem Abschnitt wird die Berechnung der internen Energie dargestellt.



**Abbildung 4.3:** *Local shape model* für die Berechnung der internen Kräfte (aus [31])

#### 4.4.1 Interne Energie: *Dual Snakes*

Die diskreten Konturen sind jeweils gegeben durch  $\mathbf{v}_i = (x_i, y_i)$ , wobei  $i = 1, \dots, n - 1$  und  $n$  die Anzahl der Konturpunkte sind. Die Konturpunkte sind gegen die Richtung des Uhrzeigers angeordnet. Desweiteren ist für das Verfahren wichtig, dass die Konturen folgende zwei Bedingungen erfüllen (s. auch Abbildung 4.3):

1. Die Konturpunkte sollten auf der Kontur möglichst äquidistant verteilt sein. Es muss folgende Bedingung gelten:

$$|\mathbf{v}_{i-1} - \mathbf{v}_i| = |\mathbf{v}_{i+1} - \mathbf{v}_i| \quad (4.19)$$

2. Der Winkel  $\varphi$  (s. Abbildung 4.3) muss auf die Form des gesuchten Objektes angepasst werden. Für die Segmentierung von den Aortenpathologien mit einer geschlossenen Kontur werden folgende Winkel benötigt:

$$\varphi_i = \frac{n-2}{n}\pi \quad (4.20)$$

Diese beiden Bedingungen sind dafür da, dass die Konturpunkte  $\mathbf{v}_i$  zu den Punkten  $\tilde{\mathbf{v}}_i$ , die als die Punkte des gesuchten Objektes geschätzt werden, gezogen werden. Die Kraft  $\mathbf{e}_i$ , die die Kontur zu dem Punkt  $\tilde{\mathbf{v}}_i$  zieht, wird durch die Nachbarpunkte von  $\mathbf{v}_i$  berechnet:

$$\mathbf{e}_i = \tilde{\mathbf{v}}_i - \mathbf{v}_i = \frac{1}{2}(\mathbf{v}_{i-1} + \mathbf{v}_{i+1}) - \mathbf{v}_i + \theta_i \frac{1}{2} \mathbf{R}(\mathbf{v}_{i-1} - \mathbf{v}_{i+1}) \quad (4.21)$$

wobei  $\mathbf{R}$  die Rotationsmatrix mit  $\alpha = 90^\circ$  ist. Der Parameter  $\theta_i$  wird durch den lokalen Winkel berechnet:

$$\theta_i = \cot\left(\frac{\varphi_i}{2}\right) \quad (4.22)$$

Die internen Energien beider Konturen müssen, um die Konturen vergleichen zu können, invariant gegenüber Skalierung, Rotation und Translation sein. Die in (4.23) dargestellte Energie hat diese Eigenschaften, wird mit der Kraft  $\mathbf{e}_i$  berechnet und normalisiert mit dem durchschnittlichen Abstandsschritt  $h = v_i - v_{i-1}$ .

$$E_{int}(\mathbf{v}_i) = \frac{1}{2} \left( \frac{|\mathbf{e}_i|}{h} \right)^2 \quad (4.23)$$

Die interne Energie integriert damit Informationen über die Kontur. Die Gesamtenergie einer einzelnen Kontur wird folgendermaßen berechnet:

$$E_{snake}(v_i) = \frac{1}{n} \sum_{i=0}^{n-1} (\lambda E_{int}(\mathbf{v}_i) + (1 - \lambda) E_{ext}(\mathbf{v}_i)) \quad (4.24)$$

Der Regulierungsparameter  $\lambda$  liegt zwischen 0 und 1. Falls  $\lambda = 1$  ist, dann wird die Kontur nur noch durch die internen Kräfte verformt und nimmt die Form an, die durch die zwei Bedingungen (4.19) und (4.20) gegeben ist. Falls  $\lambda = 0$  ist, wird die Kontur nur von den externen Kräften bewegt. Die Berechnung von  $E_{ext}(v_i)$  wird in Abschnitt 4.5.5.1 weiter erläutert.

**Implementierung der *Dual Snakes*** Der Minimierungsprozess wird mit dem Gradientenabstiegsverfahren durchgeführt. Während der Minimierung ist es wichtig, dass sich die Konturpunkte nicht mehr als einen Pixel je Iteration bewegen. Dieses hilft das Verfahren stabiler zu machen und es werden alle wichtigen Bilddaten betrachtet.  $\mathbf{F}_i$  ist der Vektor der externen Kräfte und wird bei den *Dual Snakes* mit der Ableitung des kantenbasierten Bildfunktionals  $-|\nabla I(x, y)|$  berechnet. In Abschnitt 4.5.5.1 wird erläutert, wie  $\mathbf{F}_i$  bei den *Dual-GVF-Snakes* berechnet wird. Die Konturpunkte werden mit Hilfe folgender Gleichung zu einem Energieminimum bewegt:

$$\mathbf{v}_i^{t+1} = \mathbf{v}_i^t + \frac{1}{2} (\lambda \frac{\mathbf{e}_i}{h} + (1 - \lambda) \mathbf{F}_i) + g(t) \frac{\mathbf{u}_i - \mathbf{v}_i^t}{|\mathbf{u}_i - \mathbf{v}_i^t|} \quad (4.25)$$

wobei  $t$  die Anzahl der durchgeführten Iterationen ist und  $g(t) \frac{\mathbf{u}_i - \mathbf{v}_i^t}{|\mathbf{u}_i - \mathbf{v}_i^t|}$  die Berechnung der *adaptive driving forces* (s. Abschnitt 3.2.10), die mit der Funktion  $g(t)$  gewichtet werden und  $\mathbf{u}_i$  und  $\mathbf{v}_i$  die beiden Konturen sind. In dieser Arbeit wird  $g(t) = 0.2t$  als lineare Funktion definiert.

## 4.5 Kombination

In diesem Abschnitt wird beschrieben, wie die Kombination der *Dual Snakes* mit den *GVF-Snakes* realisiert wurde und welche Erweiterungen notwendig waren.

### 4.5.1 Verformung zweier Konturen

Im ersten Schritt der Verformung von zwei Konturen werden die korrespondierenden Punkte von  $\mathbf{u}$  und  $\mathbf{v}$ , wie in Abschnitt 4.5.3 erläutert, berechnet. Im nächsten Schritt erfolgt die Optimierung der einen Kontur mittels der *GVF-Snakes*. Anschließend werden die korrespondierenden Punkte neu berechnet und der Minimierungsprozess der anderen Kontur wird durchgeführt. Im besten Fall haben beide Konturen das globale Minimum gefunden, welches mit der Berechnung der mittleren quadratischen Abweichung des Abstandes der beiden Kurven beurteilt wird. Damit ist die Zielkontur gefunden. Ist dieses nicht der Fall und eine oder beide Konturen befinden sich in einem lokalen Minimum, werden die *adaptive driving forces* erhöht und die Kontur mit der höchsten Gesamtenergie wird weiter verformt. Es werden wiederum die korrespondierenden Punkte berechnet und die Kontur verformt. Nach der Verformung wird abgefragt, ob sich die Konturen im selben Minimum befinden. Dieses wird solange durchlaufen, bis das globale Minimum gefunden wird. In Abbildung 4.4 wird der Verformungsprozess von zwei Konturen schematisch dargestellt. In Abschnitt 4.5.5 wird genauer erläutert, wie die Berechnung der Verformung der Konturen erfolgt, bis ein stationärer Zustand gefunden wird.

### 4.5.2 Verformung dreier Konturen

Die Verformung von drei Konturen erfolgt analog zu der Verformung von zwei Konturen. Der Unterschied besteht darin, dass erst alle drei Konturen verformt werden und dann entschieden wird, welche der drei Konturen weiter verformt wird. Der Verformungsprozess mit drei Konturen wird in Abbildung 4.5 dargestellt.

### 4.5.3 Berechnung der korrespondierenden Punkte

#### 4.5.3.1 Berechnung der korrespondierenden Punkte mit zwei Konturen

Die korrespondierenden Punkte werden dafür benötigt, dass die Konturpunkte mit den in Abschnitt 3.2.10 erläuterten *adaptive driving forces* in die Richtung der Konturpunkte der anderen Kontur gezogen werden können. Gunn

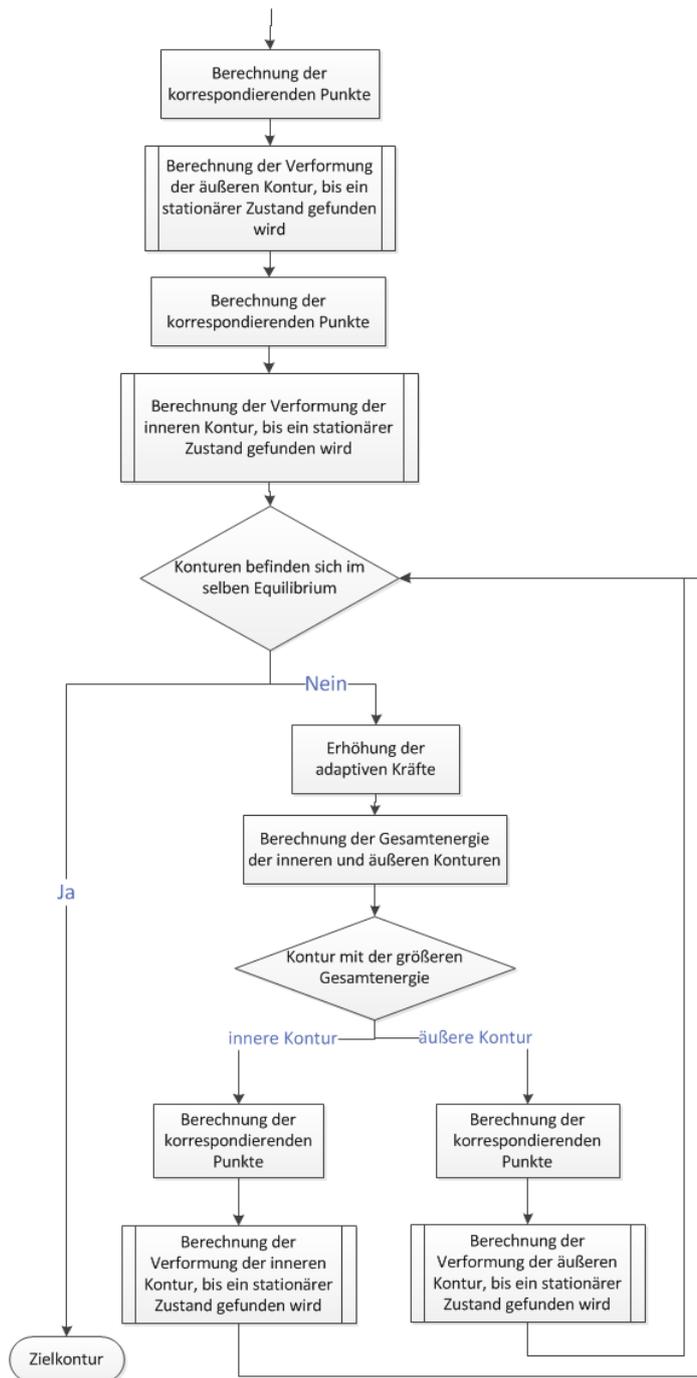


Abbildung 4.4: Übersicht über den Verformungsprozess von zwei Konturen

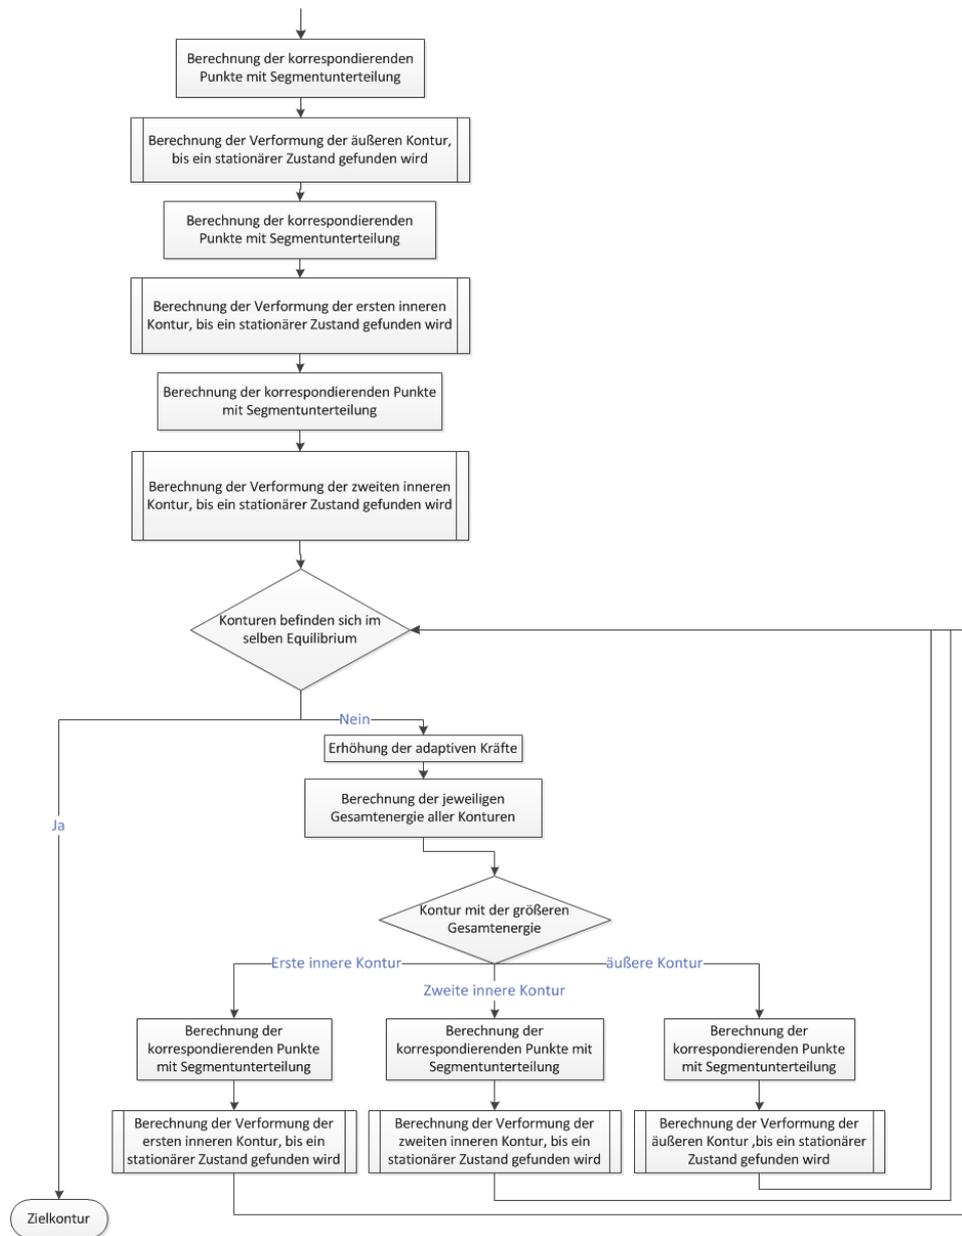


Abbildung 4.5: Übersicht über den Verformungsprozess von drei Konturen

und Nixon [31] verwenden bei den *Dual Snakes* die *arc length correspondence*, erläutern diese aber nicht weiter. Für die Berechnung der korrespondierenden Punkte von zwei Konturen gibt es mehrere unterschiedliche Möglichkeiten.

Ist eine schnelle Laufzeit erwünscht und ist bekannt, dass die Konturpunkte in einer Liste im Uhrzeigersinn angeordnet sind und die Anzahl der Konturpunkte der inneren und äußeren Kontur identisch sind, dann wird ein beliebiger Konturpunkt gewählt. Für diesen Konturpunkt wird der Punkt auf der anderen Kontur gesucht, der am nächsten an diesem Konturpunkt liegt. Die weiteren Punkte werden nach der Auflistung in der Konturliste den Punkten der anderen Liste zugeordnet. Dabei ist aber nicht gewährleistet, dass auch alle anderen Punkte auf der Kontur den nächsten Punkt auf der anderen Kontur als korrespondierenden Punkt zugewiesen bekommen.

Tung [90] beschreibt ein Verfahren, das mit der symmetrischen k-nächsten-Nachbar-Methode jedem Konturpunkt einen korrespondierenden Konturpunkt zuordnet, der sowohl für den einen Konturpunkt als auch für den anderen Konturpunkt der nächste Konturpunkt auf der anderen Kontur ist. Dieses Verfahren ist aber rechenintensiv, da mehrfach die Listen der Konturpunkte durchlaufen und weitere neue Punkte berechnet werden müssen. Auch ist es problematisch, dass sich die Anzahl der Konturpunkte während jedes Durchlaufes erhöhen kann. So kann dieses Verfahren nur mit größeren Schwierigkeiten auf das Modell der drei Startkonturen angewendet werden.

Eine andere Methode berechnet die Länge der Konturen mit der *arc length* Methode und setzt die korrespondierenden Konturpunkte immer im gleichen Abstand auf die Konturen. Damit ist zwar nicht gewährleistet, dass der Punkt der einen Kontur den nächsten Konturpunkt der anderen Kontur als korrespondierenden Konturpunkt zugewiesen bekommt, aber die Punkte werden auf der Kontur mit gleichem Abstand verteilt und die korrespondierenden Konturpunkte ziehen die Kontur in die richtige Richtung. Die korrespondierenden Punkte werden nicht für den Verformungsprozess der anderen Kontur verwendet. Dies hätte zur Folge, dass das Ergebnis der Segmentierung verfälscht wird. Die in diesem Abschnitt beschriebenen Verfahren lassen sich auf die Aortenpathologie Aneurysma anwenden, jedoch nicht auf die Aortendissektion. Während der Verformung von zwei Konturen wird das erste Verfahren verwendet.

#### 4.5.3.2 Berechnung der korrespondierenden Punkte mit drei Konturen

Für die Segmentierung der Aortendissektion werden drei Initialisierungen gesetzt: eine Kontur möglichst außerhalb und zwei Konturen möglichst innerhalb der beiden Lumen. Für die Berechnung der korrespondierenden Punkte auf den jeweils anderen Konturen werden die Konturen in Segmente unterteilt (s. Abbildung 4.6), damit die Konturen von den richtigen Abschnitten der anderen Kontur angezogen werden. Für die Segmententeilung werden zwei

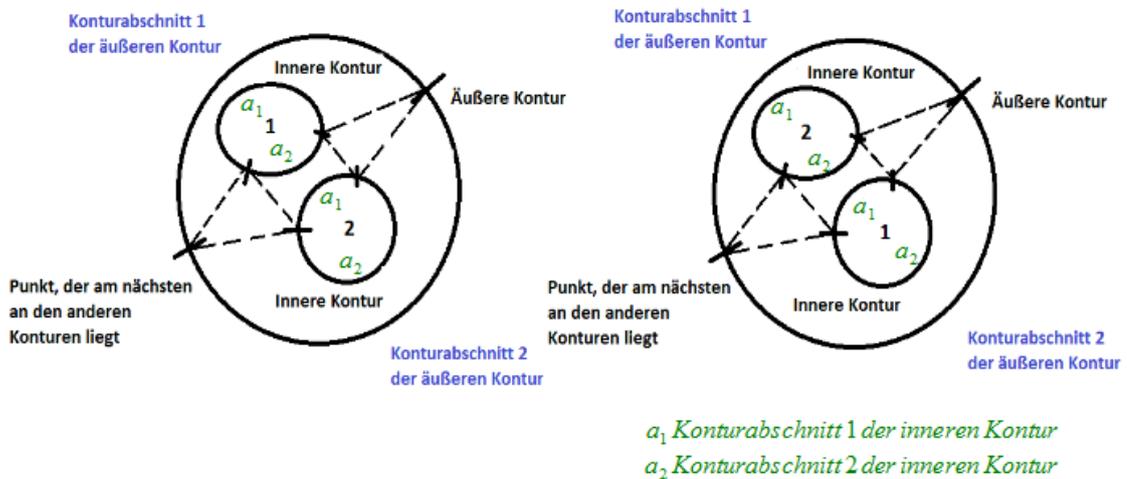


Abbildung 4.6: Segmenteinteilung und Anordnung von zwei inneren Konturen

Punkt-Tripel benötigt, die die beiden kleinsten Dreiecke bilden und bei der die Eckpunkte jeweils auf einer anderen Kontur liegen. Diese zwei Tripel werden ermittelt, indem für die Punkte der äußeren Kontur jeweils der am nächsten liegende Punkt der inneren Konturen berechnet wird. Befindet sich der nahe liegendste Konturpunkt des vorherigen Punktes der äußeren Kontur auf einer anderen inneren Kontur, dann ist ein Tripel gefunden worden. Das andere Tripel wird genauso berechnet. Die restlichen korrespondierenden Konturpunkte werden mit Hilfe der zwei Tripel gefunden, indem die Segmente, wie in Abbildung 4.6 dargestellt, aneinander gesetzt werden. Da die Konturen nach dem Uhrzeigersinn angeordnet sind, können die Konturpunkte, wie im ersten Verfahren des Abschnittes 4.5.3.1 beschrieben, ihre korrespondierenden Punkte berechnen. Dabei ist zu beachten, dass die korrespondierenden Punkte der beiden inneren Konturen im Uhrzeigersinn angeordnet sind und somit die Anordnung der Konturpunkte einer der beiden Konturen gegen den Uhrzeigersinn in der Liste umsortiert wird. Eine weitere Schwierigkeit ist, dass die inneren Konturen, die in Abbildung 4.6 als „1“ und „2“ benannt sind, auf zwei unterschiedliche Weisen angeordnet sein können. Wie in Abbildung 4.6 müssen die Kontursegmente aneinander gesetzt werden.

#### 4.5.3.3 Berechnung der korrespondierenden Punkte mit mehr als drei Konturen

Es ist prinzipiell möglich die *Dual-GVF-Snakes* so zu erweitern, dass auch drei und mehr Konturen gleichzeitig segmentiert werden können. Dafür muss die Anzahl der Segmente angepasst und überlegt werden, wie die Objekte

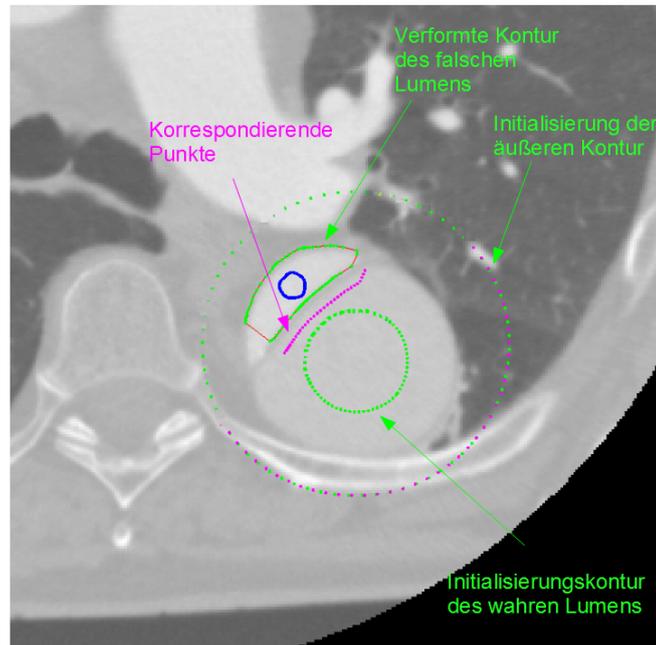


Abbildung 4.7: Korrespondierende Punkte

angeordnet sein können.

#### 4.5.4 Abstand zwischen beiden inneren Konturen

In Abbildung 4.7 ist eine Aortendissektion abgebildet. Die Aortenwand Intima ist bei dieser Aortenpathologie meist zwischen dem falschen und wahren Lumen vorzufinden. Um die Dicke der Wand zu berücksichtigen, muss ein gewisser Abstand zwischen den beiden inneren Konturen vorhanden sein. Desweiteren ist zu berücksichtigen, dass die Dicke der Membran zwischen den beiden Lumen nicht durchgängig konstant ist. In dieser Arbeit wurde ein neues Verfahren verwendet, das verhindert, dass eine Kontur an die falsche Seite der Aortenintima gezogen wird. Benutzt werden dafür die *adaptive driving forces*, die in Abschnitt 3.2.10 beschrieben wurden. Die korrespondierenden Punkte der beiden inneren Konturen werden mit einem vordefinierten Abstand in Richtung der jeweils anderen Kontur gesetzt. Die Konturpunkte der aktuellen Kontur werden mit den *adaptive driving forces* daher nicht mehr zu den Konturpunkten der anderen Kontur gezogen, sondern zu den neu berechneten Punkten. In Abbildung 4.7 werden in der Farbe rosa die korrespondierenden Punkte der Kontur, die das wahre Lumen segmentieren sollen, dargestellt.

### 4.5.5 Verformungsprozess

Im ersten Schritt des Verfahrens wird abgefragt, ob die Kontur, die verformt werden soll, in Kontursegmente aufgeteilt wurde oder nicht. Wurde die Kontur in Segmente unterteilt, werden die korrespondierenden Konturpunkte, so wie in Abschnitt 4.5.4 beschrieben, versetzt. Zur Berechnung der Kontur nach einem Iterationsschritt wird die folgende Gleichung benötigt:

$$\begin{aligned} \mathbf{v}_i^{t+1} = & \mathbf{v}_i^t + \frac{1}{2}(\lambda \frac{\mathbf{e}_i}{h} + (1 - \lambda)f_{extgvf}) + g(t)f_{driving} + \xi f_{driving} \quad (4.26) \\ & + \sum_{spring=1}^x (k_{spring}f_{spring}) + \sum_{volcano=1}^y (k_{volcano}f_{volcano}) \end{aligned}$$

Dabei ist  $\xi$  die Gewichtung der *adaptive driving forces*  $f_{adaptive}$  (s. Abschnitt 3.37) der verschobenen Punkte,  $x$  die Anzahl der gesetzten *spring forces* (s. Abschnitt 3.16), die den gesetzten Radius  $k_{spring}$  haben, und  $y$  ist die Anzahl der gesetzten *volcano forces* (s. Abschnitt 3.18), die einen gesetzten Radius von  $k_{volcano}$  haben. Falls sich ein Konturpunkt dadurch mehr als ein Pixel bewegt, wird die Bewegung auf ein Pixel reduziert. Der Grund dafür ist, dass keine globalen Minima übersprungen werden sollen. Die Gewichtung der *adaptive driving forces* wird bei jeder Iteration erhöht, falls diese Kräfte einen Gewichtungswert größer als 0,1 haben. Die *adaptive driving forces* sind dafür da, dass die Kontur aus dem lokalen Minimum herausgezogen wird. Bewegt sich die Kontur mehr als 0,8 px, ändert sich der Wert des Gewichtungsparameters der *adaptive driving forces* nicht und wird erst dann wieder verringert, wenn die Energie der Kontur wieder geringer wird. Der Prozess der Verformung endet, wenn ein stationärer Zustand erreicht worden ist (s. Abbildung 4.8).

#### 4.5.5.1 Gesamtenergie

Der originale *Dual Snakes* Algorithmus benötigt zur Bestimmung, welche der Konturen weiter verformt wird, die Kontur mit der geringsten Gesamtenergie. Die Berechnung der Gesamtenergie erfolgt folgendermaßen:

$$\begin{aligned} E_{snake}(v_i) = & \frac{1}{n} \sum_{i=0}^{n-1} (\lambda E_{int}(\mathbf{v}_i) + (1 - \lambda)E_{ext}(\mathbf{v}_i) + E_{driving}(v_i)) \quad (4.27) \\ & + \sum_{spring=1}^x k_{spring}E_{spring}(v_i) + \sum_{volcano=1}^y k_{volcano}E_{volcano}(v_i) \end{aligned}$$

In (4.27) ist  $E_{ext}$  das externe Gradientenfeld der originalen *Dual Snakes*. Da die externe Energie aber bei den *Dual-GVF-Snakes* nicht über das Gradientenfeld, sondern über das *gradient vector field* berechnet wird, ist es naheliegend, dass die externe Energie auch von diesem *gradient vector field* berechnet wird. Bei

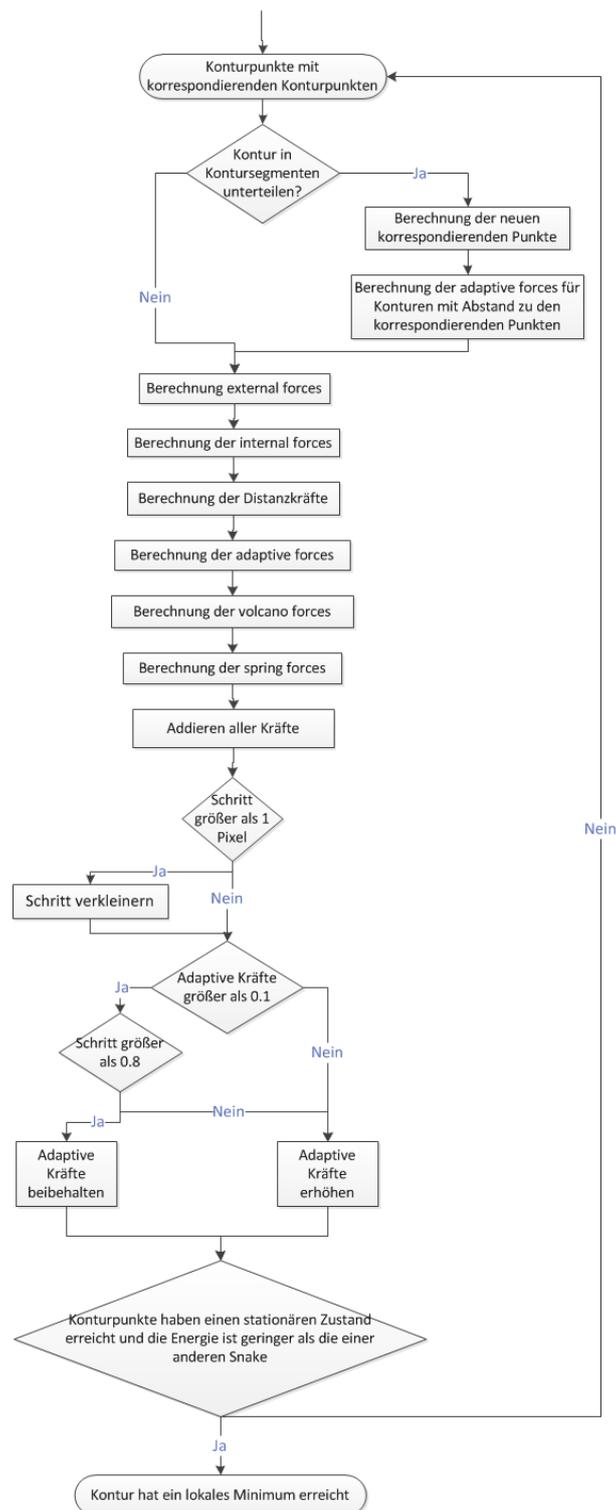
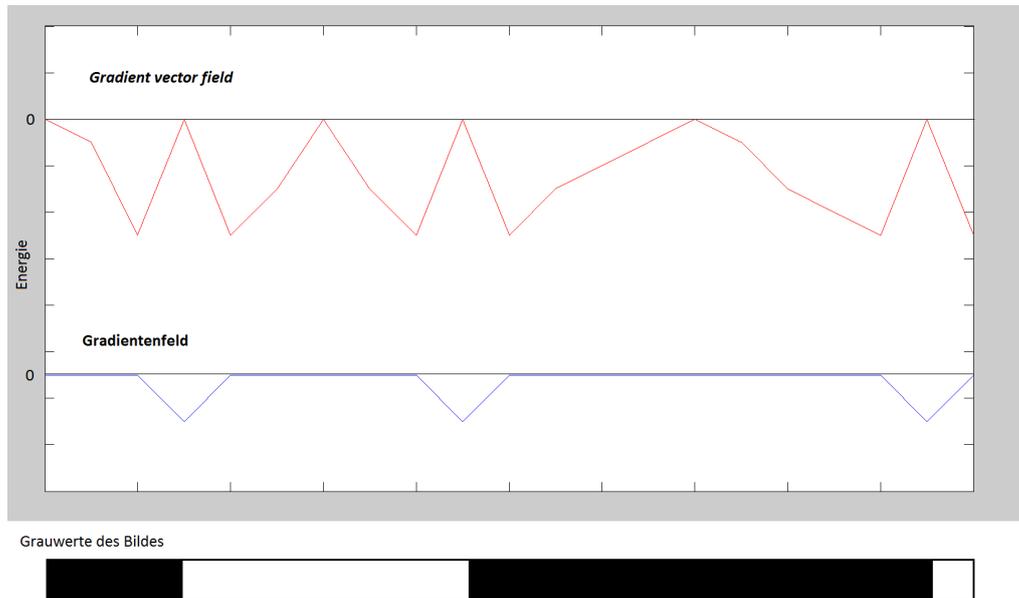


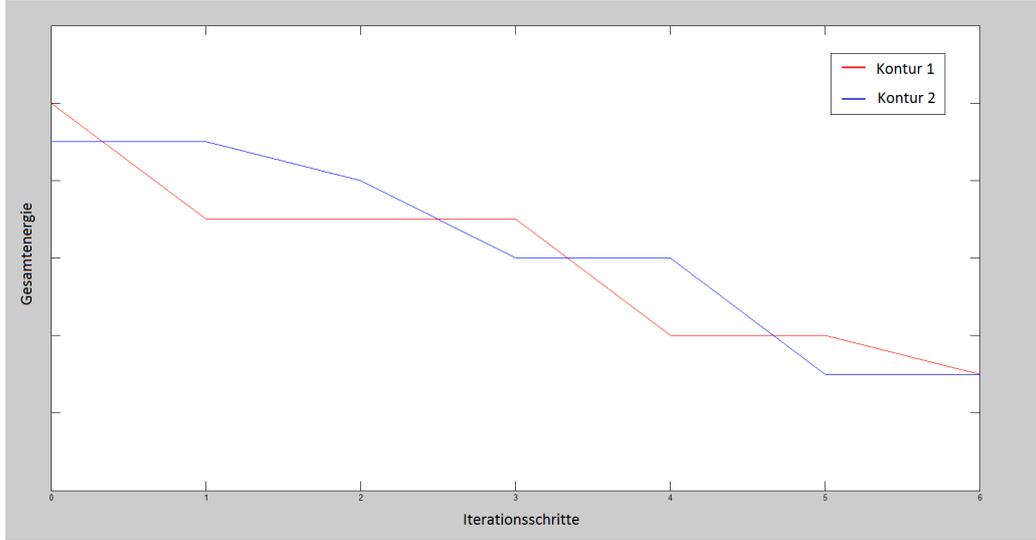
Abbildung 4.8: Verformungsprozess einer Kontur



**Abbildung 4.9:** Energie des Gradientenfeldes und des *gradient vector field* für die unten abgebildeten Grauwerte eines Bildes

der Berechnung der Energie über das *GVF* ist die Energie Null, wenn sich die Kontur in einem Gebiet ohne Kanten befindet. Befindet sich die Kontur in der Nähe von Kanten, fällt der Wert der Energie zunächst ins Negative und steigt wieder auf Null, wenn die Kontur in der Nähe oder an der Kante ist (s. Abbildung 4.9). Daher ist es nicht möglich zu bestimmen, ob sich die Kontur an einer Kante oder in einem Bereich mit geringen oder keinen Bildintensitätsschwankungen befindet. Vergleicht man dies mit der Energie des Gradientenfeldes, erkennt man, dass die Energie an den Kanten am geringsten ist. Daher wird zur Berechnung der Gesamtenergie das Gradientenfeld verwendet.

In Abbildung 4.10 wird in einem Beispiel dargestellt, wie sich die Energie von zwei Konturen nach jedem abgeschlossenen Verformungsprozess (s. Abschnitt 4.5.5) verhält. Die Gesamtenergie beider Konturen sinkt im jeweils ersten Schritt, da die *GVF-Snakes* die Energie minimieren. In den nächsten Verformungsprozessen wird jeweils die Kontur mit der höheren Energie weiterentwickelt und die Kontur verlässt das lokale Minimum. Dabei kann es sein, dass die Energie steigt, da die Kontur von einem lokalen Minimum in ein anderes lokales Minimum gezogen wird. Die Kontur wird solange weiterverformt, bis die Gesamtenergie der Kontur geringer ist als die der anderen Kontur. Damit fällt die Gesamtenergie beider Konturen kontinuierlich. Falls die Gesamtenergie beider Konturen dieselbe ist, kann es sein, dass sich die Konturen im selben Minimum befinden. Da die Energie aber auch durch Zufall dieselbe sein kann, werden nicht die Gesamtenergien, sondern die Abstände der Kon-



**Abbildung 4.10:** Energie der *Dual Snakes* in Abhängigkeit der Iterationsschritte

turen als Abbruchkriterium verwendet. Zur Beurteilung der Lage der beiden Konturen  $\mathbf{u}$  und  $\mathbf{v}$  zueinander wird die mittlere quadratische Abweichung des euklidischen Abstandes  $d$  von den korrespondierenden Konturpunkten von  $\mathbf{u}$  und  $\mathbf{v}$  berechnet:

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (d_i - \bar{d})^2 \quad (4.28)$$

#### 4.5.5.2 Verringerung der *adaptive driving forces*

Die *adaptive driving forces* werden folgendermaßen berechnet:

$$f_{driving} = g(t) \cdot \frac{\mathbf{u}_i - \mathbf{v}_i^t}{|\mathbf{u}_i - \mathbf{v}_i^t|} \quad (4.29)$$

Diese Kräfte werden bei den *Dual-GVF-Snakes* zu einem anderen Zeitpunkt als bei den *Dual Snakes* verringert. Bei den *Dual-GVF-Snakes* wird zur Berechnung der Gesamtenergie das *gradient vector field* verwendet. Daher ist zu beachten, dass man die *adaptive driving forces* nicht wie bei den originalen *Dual Snakes* verwenden kann. Bei den *Dual Snakes* werden die *adaptive driving forces* solange erhöht, bis die Bewegung der Kontur größer als ein gesetzter *threshold* ist. Wenn die Gesamtenergie abnimmt, also die Kontur nicht mehr von den externen Kräften in das globale Minimum gezogen wird, werden die *adaptive driving forces* verringert.

In Abbildung 4.9 wird die Energie des *gradient vector field* eines 1D Bildes dargestellt. Diese Energie lässt Rückschlüsse auf das Verhalten der Kräfte der

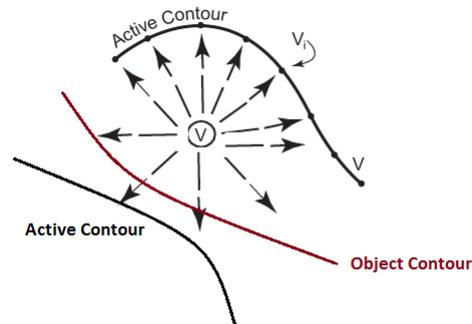


Abbildung 4.11: Wirkung der *volcano forces*

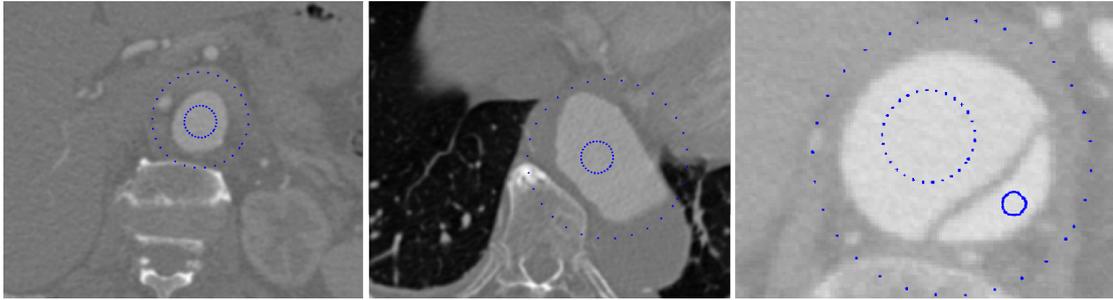
*GVF-Snakes*, die die Kontur verformen, ziehen. Die Kräfte des *GVF* ziehen die Kontur von weitem zu einer Kante. Am stärksten ist die Anziehungskraft, wenn die *Snake* nahe der Kante ist. An der Kante selbst ist die Anziehungskraft Null. So müssen die *adaptive driving forces* wie bei den originalen *Dual Snakes* erhöht werden, dürfen aber nicht entfernt werden, wenn sich die Gesamtenergie der Kontur verringert. Ansonsten tritt der Fall ein, dass die Kontur wieder von der Kante angezogen wird und zu dem vorherigen globalen Minimum zurückkehrt. Erst wenn sich die Kontur nicht mehr in dem Einzugsbereich der Kräfte, die die Kontur wieder zu dem vorherigen Minimum ziehen, befindet, werden die *adaptive driving forces* entfernt. Die Kontur befindet sich nicht mehr in dem Einzugsbereich, wenn die Gesamtenergie wieder steigt.

#### 4.5.5.3 *Spring forces* und *volcano forces*

So wie bei den klassischen *Snakes* können durch Benutzerinteraktionen *volcano* und *spring forces* verwendet werden. Die *spring forces* werden in ihrer klassischen Form angewendet. Bei den *volcano forces* treten aber Probleme auf, sobald der Ausgangspunkt der *volcano forces* zwischen der äußeren und der inneren Kontur gesetzt wird (s. Abbildung 4.11). Die *volcano forces* drücken die innere Kontur von der äußeren Kontur weg. Daher dürfen die *volcano forces* nur auf eine Kontur wirken, die vom Anwender definiert wird.

## 4.6 Initialisierung

Für die Initialisierung werden Kreise verwendet, die sich innerhalb und außerhalb des gesuchten Objektes bzw. der gesuchten Objekte befinden. Falls ein Aortenaneurysma oder eine Aorta ohne Pathologie vorliegt, wird mit zwei Startkonturen initialisiert und falls eine Aortendissektion vorliegt, wird eine Kontur außerhalb und zwei weitere Konturen innerhalb des falschen und des wahren Lumens gelegt (vgl. Abbildung 4.12).



**Abbildung 4.12:** CTA Aufnahmen der Aorta, Aortenaneurysma und der Aortendissektion mit Initialisierung

## 4.7 Übersicht über Parametereinstellungen

In der folgenden Tabelle werden alle Parametereinstellungen für die *Dual-GVF-Snakes* aufgelistet.

Parameter	Beschreibung	Formel	Defaultwert
Externe Kräfte/Energien			
$\sigma_1$	Die Standardabweichung $\sigma_1$ wird für die Berechnung von $E_{line}$ benötigt, da das Bild mit einem Gaußfilter geglättet wird.	-	1
$\sigma_2$	Die Standardabweichung $\sigma_2$ wird zur Berechnung der Gradienten des Kantenenergiebildes $\nabla I$ benutzt, welches die Bildkräfte dargestellt.	-	1
$\sigma_3$	Die Standardabweichung $\sigma_3$ wird zur Berechnung des Laplace-Operators benutzt.	-	0,5
$E_{edge}$	Je höher der Wert des Gewichtungsparmeters, desto stärker wird die Kontur an Kanten gezogen.	(3.6)	6
$E_{line}$	Falls der Wert positiv ist, wird die Kontur an weiße Kanten angezogen, ansonsten an schwarze.	(3.5)	0
$E_{term}$	Je höher der Wert des Gewichtungsparmeters, desto stärker wird die Kontur zu Ecken gezogen.	(3.7)	0
$G_{iter}$	Anzahl der iterativen Neuberechnungen des <i>GVF</i> s, welches das <i>GVF</i> verbreitert.	(4.4) und (4.5)	1

Parameter	Beschreibung	Formel	Defaultwert
$\mu$	Der Gewichtungparameter $\mu$ muss auf die Stärke des Rauschens abgestimmt werden.	(4.4) und (4.5)	0,6
Interne Kräfte/Energie			
$\lambda$	$\lambda$ liegt zwischen 0 und 1 und gewichtet bei einem niedrigeren Wert als 0,5 die externe Energie stärker, ansonsten die interne Energie.	(4.24)	0,5
Weitere Parameter			
Iterationen	Anzahl der Iterationen während einer Minimierung.	-	500
$\xi$	Gewichtung der <i>adaptive driving forces</i> zwischen den beiden inneren Kontursegmenten.	$\xi f_{driving}$	0,9
$d$	$d$ ist die Distanz der korrespondierenden Punkte zur aktuellen Kontur.	(4.28)	5
Initialisierung			
$R_o$	Radius der äußeren Kontur	-	10
$R_{i1}$	Radius der ersten inneren Kontur	-	10
$R_{i2}$	Radius der zweiten inneren Kontur	-	10
Zusätzliche Kräfte			
$k_{spring}$	Gewichtungparameter der <i>spring forces</i>	(4.27) und (4.26)	5
$k_{volcano}$	Gewichtungparameter der <i>volcano forces</i>	(4.27) und (4.26)	5
<i>volcano</i> Kontur	Der Parameter gibt an, welche der drei Konturen von den <i>volcano forces</i> beeinflusst werden.	-	-

### 4.7.1 Matlab-Implementierung von *GVF-Snakes*

In dieser Arbeit wird zur Berechnung des *gradient vector field* die Matlab-Implementierung der *GVF-Snakes* von Kroon [49] benutzt. Die *GVF-Snakes* verwenden die interne Energie der klassischen *Snakes* und das externe *gradient vector field* für die externe Energie. Kroon hat die externen Energien mit den *balloon forces* von Cohen [16] erweitert. Die *balloon forces* werden bei den *Dual-GVF-Snakes* nicht benötigt, da die *adaptive driving forces* (s. Abschnitt 3.2.10.1) die Kontur aus einem lokalen Minimum ziehen.



# Kapitel 5

## Evaluation und Ergebnisse

In diesem Kapitel werden zunächst die Kriterien definiert, nach denen die *Dual-GVF-Snakes* beurteilt werden. Danach werden sowohl die Segmentierungsergebnisse der synthetischen als auch der klinischen Bilder mit den *Dual-GVF-Snakes* beschrieben und diskutiert. Verglichen werden die Segmentierungsergebnisse der *Dual-GVF-Snakes* mit denen der *GVF-Snakes* und der *AB-Snakes*.

### 5.1 Evaluationsziel und Evaluationsmethode

Zur Evaluierung werden Objekte in Bildern segmentiert, die in den Abbildungen 4.1 und 5.1 dargestellt sind. Die Bilder beinhalten unterschiedliche Schwierigkeiten. So sind in der Abbildung 5.1 synthetisch hergestellte Bilder eines parametrischen Modells dargestellt, dessen Form konkave und konvexe Elemente beinhalten. Es gibt drei verschiedene Hintergründe (HG), einen mit einem konstanten homogenen Grauwert, einen mit einem linearen und einen mit einem sinusförmigen Grauwertverlauf. Die Bilder sind mit unterschiedlich starkem additiven Gaußrauschen versehen. Je größer die Standardabweichung  $\sigma_n$  der Gaußverteilung ist, desto stärker ist das Bild verrauscht. Zusätzlich wird ein weiteres synthetisches Bild (Abbildung 5.2) mit zwei Objekten für die Evaluation verwendet. Dieses synthetische Bild beinhaltet das gleiche Objekt wie die anderen Bilder, hat kein Rauschen und einen linearen Grauwertverlauf. Zusätzlich existiert ein ovales Objekt mit Kanten, die einen höheren Gradientenbetrag haben als das andere Objekt.

In Abbildung 4.1 sind axiale CTA-Aufnahmen von der Aorta und verschiedene Aortenpathologien abgebildet. Die Schwierigkeit, die Objekte in diesen Bildern zu segmentieren, liegt darin, dass alle Bilder verrauscht sind und dass in der Umgebung der Aorta Strukturen vorhanden sind, die die gleichen Intensitäten und ähnliche Formen haben wie die Aorta. Die Aortendissektion kann außerdem noch deutlich unterschiedliche Intensitäten zwischen den bei-

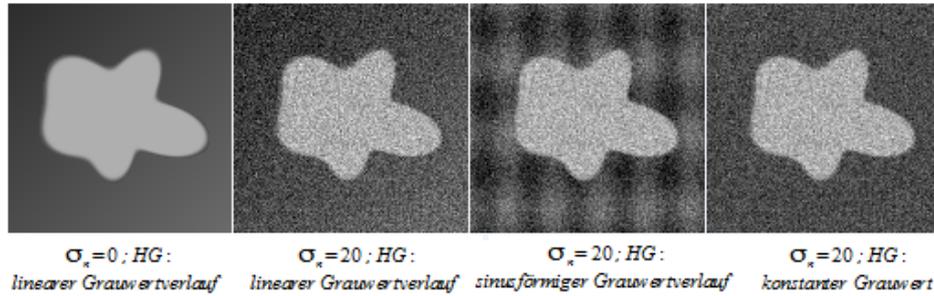


Abbildung 5.1: Testbilder mit unterschiedlichem Rauschen



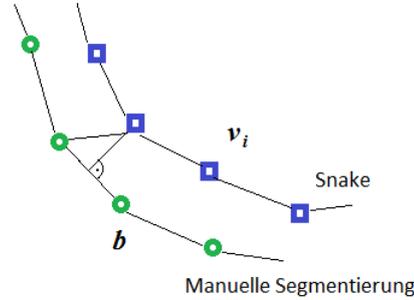
Abbildung 5.2: Synthetisch erstelltes Bild mit zwei Objekten

den Lumen aufweisen und es kann sein, dass die Membran zwischen den Lumen schwer erkennbar ist, da ein fließender Übergang zwischen einem Lumen und der Membran existiert. Die Form der Aortendissektion kann stark variieren, sodass die *Snake* unter anderem konvexe und konkave Objekte segmentieren muss.

Zur Auswertung wird der Abstand zwischen den Segmentierungsergebnissen und einer Referenzkontur, die manuell segmentiert wurde, berechnet. Zu beachten ist, dass nicht der Abstand der manuellen Segmentierungspunkte  $\mathbf{b}$  und der automatischen Segmentierungspunkte  $\mathbf{v}_i$  verwendet werden kann, da die Punkte verschoben zueinander liegen können (s. Abbildung 5.3). Um den kürzesten Abstand zwischen den Konturen  $\mathbf{v}_i$  und  $\mathbf{b}$  zu ermitteln, wird für jeden Punkte der aktuellen Kontur der Abstand zwischen diesem und der Geraden berechnet, die von den beiden benachbarten Punkten der Kontur  $\mathbf{b}$  aufgespannt wird.

Weiterhin ist zu beachten, dass die manuelle Segmentierung nur pixelgenau, aber der Algorithmus subpixelgenau segmentiert. In Abbildung 5.4 wird dies veranschaulicht, indem die manuell segmentierte Kontur (blaue Rechtecke) nur natürliche Zahlen und die automatische Kontur (grüne Punkte) auch reelle Zahlen annehmen kann. Das bedeutet, dass bei einem Abstand  $< 1$  die Objektkonturen nahe beieinander liegen.

Für die Auswertung der Ergebnisse wird der arithmetische Mittelwert aller



**Abbildung 5.3:** Abstand zwischen Konturpunkten

Abstände berechnet, der wie folgt aussieht:

$$\bar{d} = \frac{1}{n} \sum_{i=1}^n \min(\mathbf{v}_i, \mathbf{b}) \quad (5.1)$$

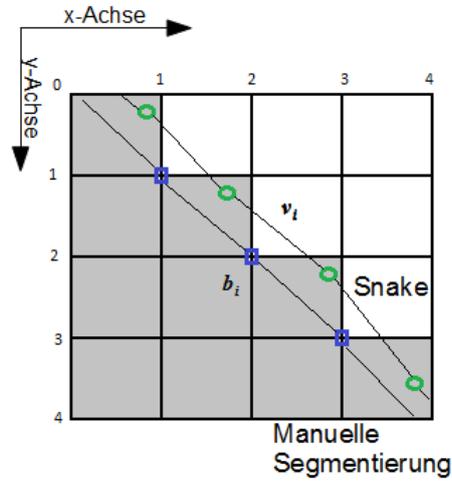
wobei  $\min(\mathbf{v}_i, \mathbf{b})$  die geringste Distanz zwischen dem Punkt  $\mathbf{v}_i$  und der manuell segmentierten Kontur  $\mathbf{b}$  ist und  $n$  die Anzahl der Punkte der automatisch generierten Kontur. Der arithmetische Mittelwert der Abstände allein ist nicht aussagekräftig. So kann das arithmetische Mittel einer Kontur einen höheren Wert haben, falls die segmentierte Kontur durchgängig einen gewissen Abstand zur Referenzkontur hat. Daher werden zur Auswertung noch die Standardabweichung  $\sigma_d$ , der kleinste und der größte Abstand  $d_{min}$  bzw.  $d_{max}$  für die Auswertung hinzugezogen. Die Standardabweichung  $\sigma_d$  wird folgendermaßen berechnet:

$$\sigma_d = \left( \frac{1}{n-1} \sum_{i=1}^n (d_i - \bar{d})^2 \right)^{\frac{1}{2}} \quad (5.2)$$

Als Startkontur wird jeweils ein Kreis gesetzt, der sich möglichst innerhalb bzw. außerhalb des gesuchten Objektes befindet.

## 5.2 Parametereinstellungen

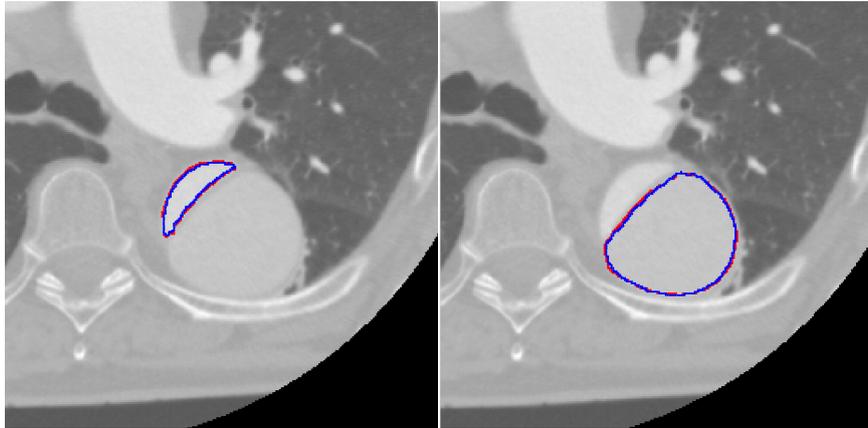
In Tabelle 5.1 werden die für die Evaluation benutzten Parametereinstellungen aufgelistet. Für die Vergleichbarkeit der Ergebnisse erhalten die Parameter möglichst die gleichen Werte. Spezielle Parameter müssen aber angepasst werden. So müssen auf Grund von starken oder schwachen Kontrasten an den Objektkanten die Parameter der Kantenkräfte  $E_{edge}$  und der GVF Iterationen  $G_{iter}$  angepasst werden. Wird der Parameter für die Kantenkräfte für den



**Abbildung 5.4:** Pixelgenaue manuelle und subpixelgenaue automatische Segmentierung

Parameter	Synthetische Bilder	Klinische Bilder
Externe Energien/Kräfte		
$\sigma_1$	1	1
$\sigma_2$	1	1
$\sigma_3$	0,5	0,5
$E_{edge}$	6	15 (Aorta/ Aortenaneurysma) bzw. 200 (Aortendissektion)
$E_{line}$	0	0
$E_{term}$	0	0
$\mu$	0,5	0,5
$G_{iter}$	4	1
Interne Energien/Kräfte <i>Dual-GVF-Snakes</i>		
$\lambda$	0,5	0,5
<i>Erhöhung der Gewichtung der adaptive driving forces</i>	0,5	0,5
Gewichtung der <i>adaptive driving forces</i> zwischen den Objekten	0,9	0,9

**Tabelle 5.1:** Parametereinstellungen



**Abbildung 5.5:** Manuell segmentierte Lumen zu unterschiedlichen Zeitpunkten (rote und blaue Kontur); links Segmentierung des wahren Lumens und rechts des falschen Lumens

	$\bar{d}$	$\sigma_d$	$d_{min}$	$d_{max}$
Wahres Lumen	0,20	0,40	0	1
Falsches Lumen	0,21	0,42	0	2
Mittelwert	0,20	0,41	0	1,5

**Tabelle 5.2:** Mittelwert und Standardabweichung der manuell segmentierten Konturen in Pixel (px)

Bildkontrast zu klein gewählt, findet die Energieminimierung kein Minimum. Wird dieser Parameter zu groß gewählt, werden starke Kräfte auf die Konturpunkte ausgeübt, die bewirken, dass die Konturpunkte springen, aber keine Objektkanten segmentiert werden können. Der Parameter  $G_{iter}$  muss auf den Bildkontrast angepasst werden, da bei einer zu hohen Anzahl von Iterationen Kanten mit einem schlechten Kontrast nicht erkannt werden.

### 5.3 Vergleich von manuellen Segmentierungsergebnissen

Jede manuelle Segmentierung sieht anders aus. Selbst bei der mehrmaligen Segmentierung desselben Objektes vom derselben Person sind Unterschiede zu erkennen. In Abbildung 5.5 sind die Segmentierungsergebnisse einer Aorten dissektion dargestellt. Die rote Kontur ist an einem anderen Tag als die blaue Kontur von derselben Person segmentiert worden. Man erkennt in der Segmentierung des falschen Lumens (rechts), dass bei der ersten Segmentierung Pixel, die innerhalb des Objektes am Rand liegen, markiert hat und eine Woche später Pixel, die außerhalb des Objektes am Rand liegen, als Zielkontur definiert

interne Energien/Kräfte <i>GVF-Snakes</i>	
$\alpha$	0,03
$\beta$	0,03
$\delta$	Kontur liegt innerhalb des gesuchten Objektes $\rightarrow$ -0,1 ansonsten 0,1
$\kappa$	4

**Table 5.3:** Parameter der *GVF-Snakes*

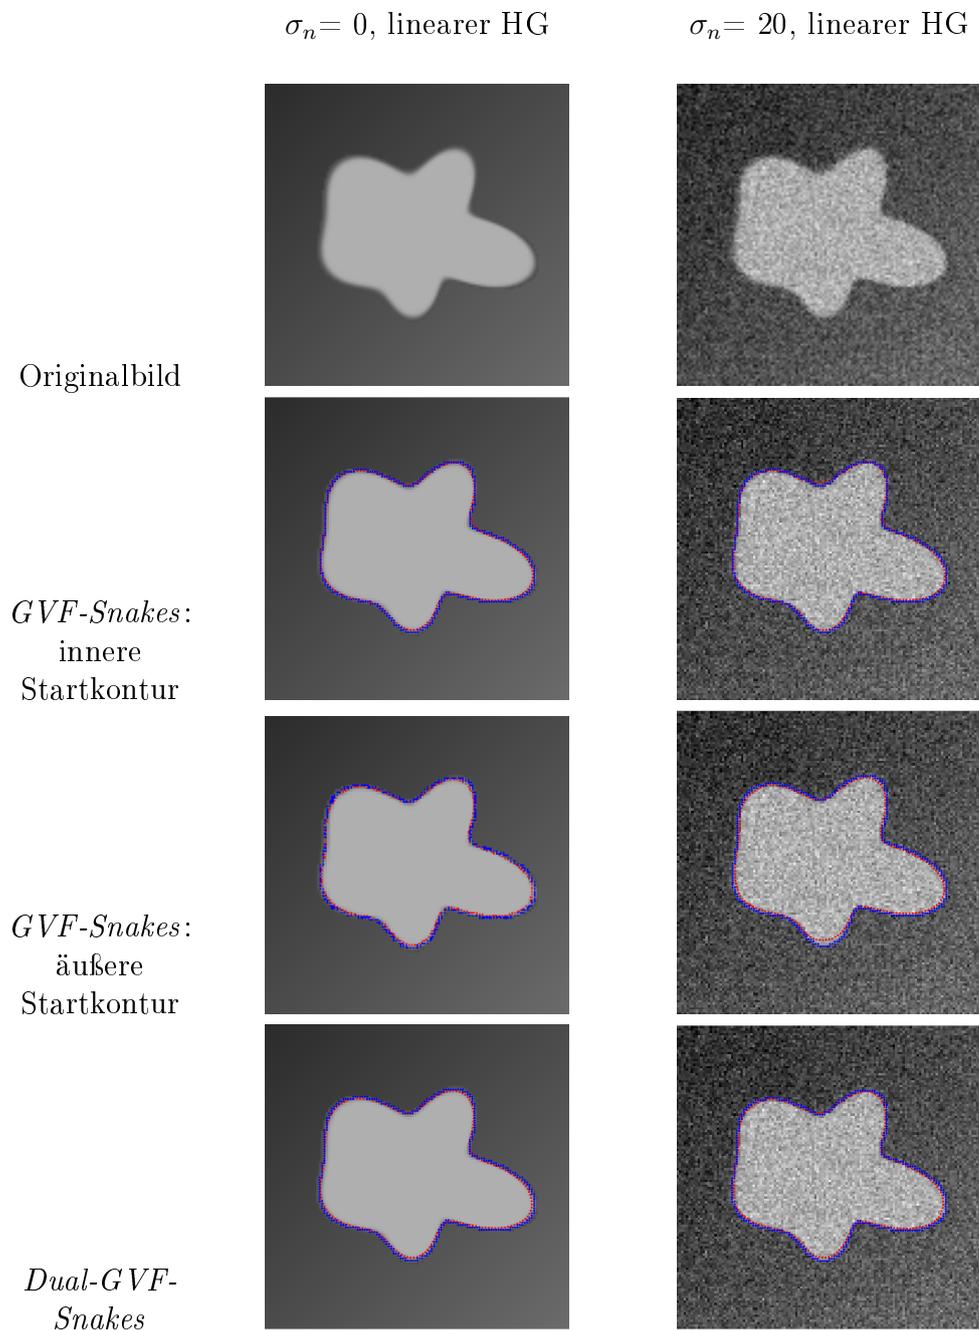
hat. Zur besseren Einschätzung der Ergebnisse der automatischen Segmentierung werden daher der maximale Abstand  $d_{max}$ , der Mittelwert  $\bar{d}$  und die Standardabweichung  $d_\sigma$  der Abstände der manuell segmentierten Konturen, die in Tabelle 5.2 dargestellt sind, hinzugezogen. So beträgt der größte arithmetische Mittelwert in Pixel (px)  $\bar{d} = 0,2 px$  und die größte Standardabweichung  $\sigma_d = 0,41 px$ . Der größte Abstand zwischen den beiden Konturen beträgt  $d_{max} = 2 px$ .

## 5.4 Synthetische Bilder

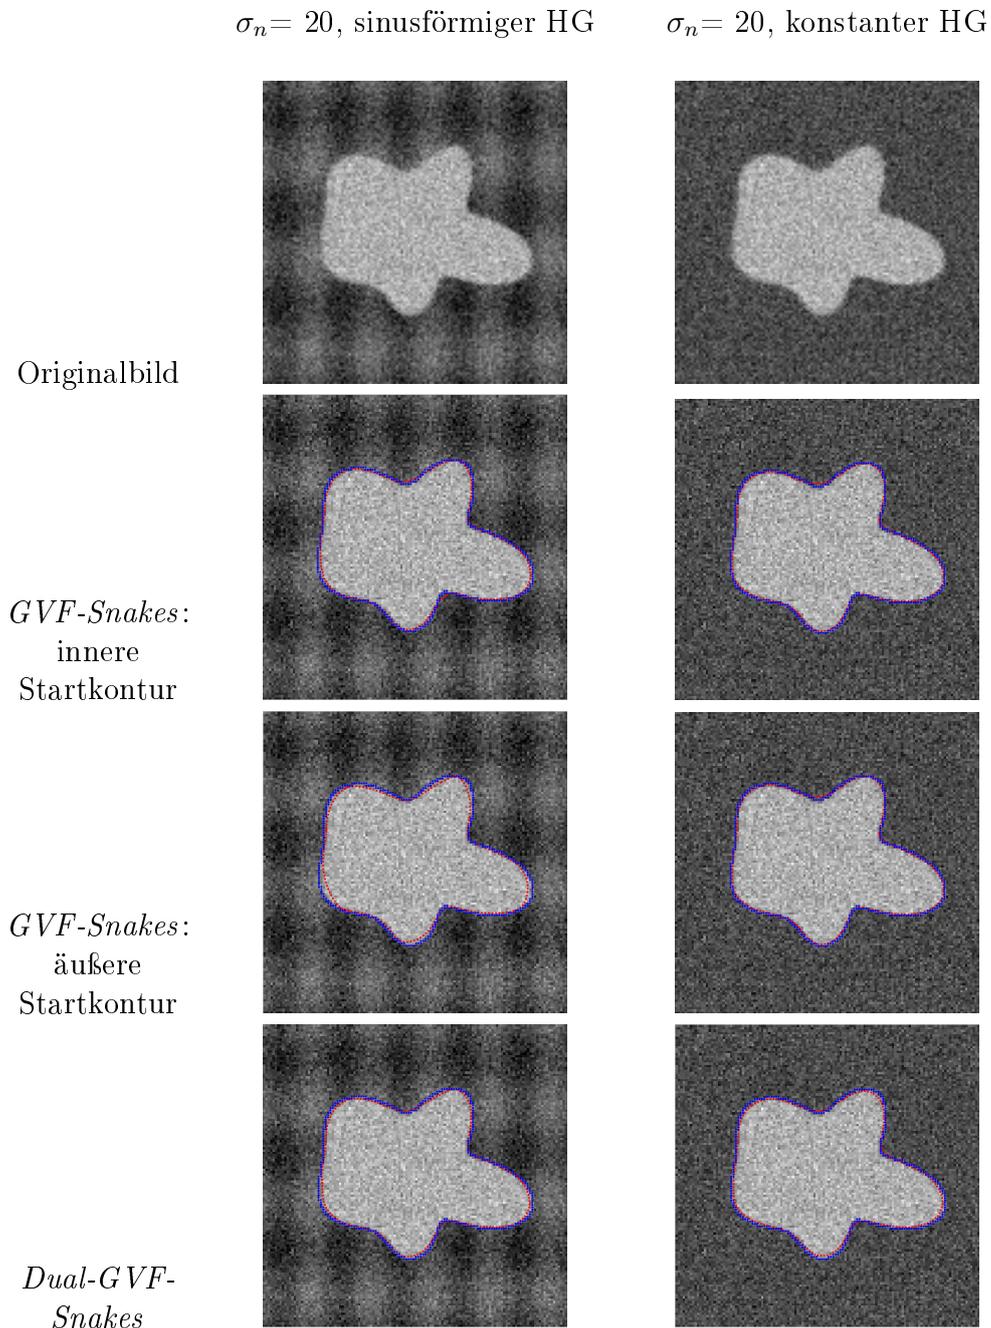
In den Abbildungen 5.6, 5.7 und 5.8 sind die Ergebnisse der Segmentierung der synthetischen Bilder mit Hilfe der *GVF-Snakes* und der *Dual-GVF-Snakes* abgebildet. Die blaue Linie ist die Referenzkontur und die rote Linie die automatisch segmentierte Kontur. Für den Vergleich der Segmentierungsverfahren werden die gleichen Parametereinstellungen wie bei den *Dual-GVF-Snakes* verwendet. Da aber eine andere interne Energie bzw. andere interne Kräfte verwendet werden, müssen Parametereinstellungen aus Tabelle 5.3 für die *GVF-Snakes* gesetzt werden. Dabei ist zu beachten, dass der Parameter  $\delta$ , der die Balloon-Kräfte gewichtet, jedes Mal auf die Lage der Initialisierung angepasst werden muss. Falls die Initialisierung innerhalb des Objektes erfolgt ist, so muss  $\delta$  mit  $(-1)$  multipliziert werden. Dies ist der Grund, warum bei den *GVF-Snakes* unterschieden wird, ob die Startkonturen innerhalb oder außerhalb des gesuchten Objektes gesetzt wurden.

### 5.4.1 Ergebnisse der synthetischen Bilder mit einem Objekt

In den Abbildungen 5.6 und 5.7 und der Tabelle 5.4 werden die Ergebnisse der Segmentierung der Testbilder mit einem Objekt dargestellt. Man erkennt, dass alle Ergebniskonturen sowohl bei den *GVF-Snakes* als auch bei den *Dual-GVF-Snakes* nahe an der Referenzkontur liegen. Auch die Mittelwerte und die



**Abbildung 5.6:** Ergebnisse der Segmentierung von synthetischen Bildern mit einem Objekt; die blaue Kontur ist die Referenzkontur und die rote die automatisch generierte Kontur



**Abbildung 5.7:** Ergebnisse der Segmentierung von synthetischen Bildern mit einem Objekt; die blaue Kontur ist die Referenzkontur und die rote die automatisch generierte Kontur

Bild	$\sigma_n = 0$ , linearer HG	$\sigma_n = 20$ , linearer HG	$\sigma_n = 0$ , sinusförmiger HG	$\sigma_n = 0$ , konst. HG	Mittelwert
<i>GVF-Snakes; Startkontur innen</i>					
$\bar{d}$	0,420	0,331	0,381	0,333	0,366
$d_{min}$	0,005	0,003	0,001	0,002	0,003
$d_{max}$	1,243	1,028	1,553	0,903	1,182
$\sigma_d$	0,306	0,244	0,335	0,243	0,282
<i>GVF-Snakes; Startkontur außen</i>					
$\bar{d}$	0,329	0,527	0,613	0,542	0,503
$d_{min}$	0,001	0,009	0,003	0,009	0,005
$d_{max}$	1,001	1,684	2,710	2,489	1,971
$\sigma_d$	0,265	0,374	0,540	0,394	0,393
<i>Dual-GVF-Snakes</i>					
$\bar{d}$	0,379	0,325	0,466	0,449	0,405
$d_{min}$	0,005	0,000	0,000	0,000	0,001
$d_{max}$	1,057	1,495	1,801	1,332	1,421
$\sigma_d$	0,279	0,325	0,397	0,334	0,334

**Tabelle 5.4:** Werte der Abstandsberechnung zwischen Referenzkontur und *GVF-Snakes* bzw. *Dual-GVF-Snakes* Segmentierung von den synthetisch erstellten Bildern mit einem Objekt in Pixel

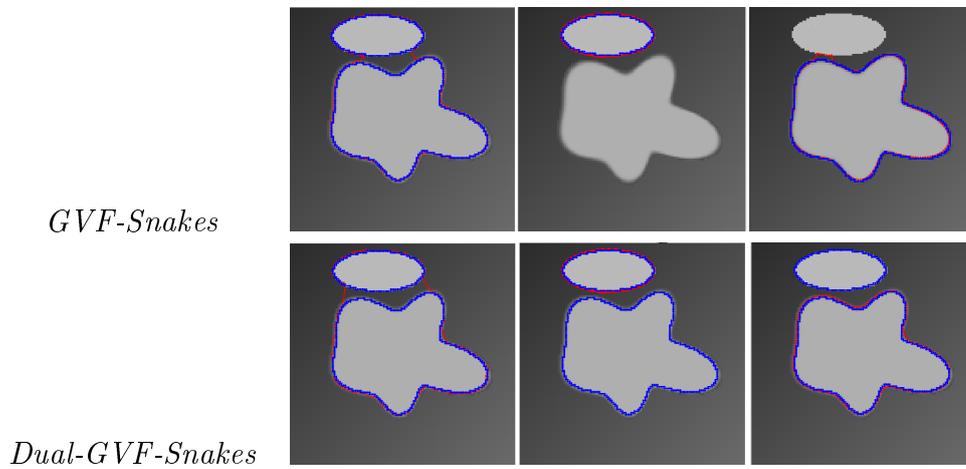
Standardabweichungen der Abstände zur manuellen Segmentierung bestätigen dieses, da die Werte in dem Bereich von 0.2 bis 0.5 px liegen. Diese Werte sind kleiner 1, was bedeutet, dass die Konturen sehr nahe an der Referenzkontur liegt. Auch der größte Abstand zur Referenzkontur beträgt 2.708 px und ist damit nur 0.7 px weiter von der Referenzkontur entfernt, als die beiden manuell segmentierten Konturen voneinander entfernt sind (s. Tabellen 5.2 und 5.4).

Anhand des Mittelwertes, des maximalen Abstandes und der Standardabweichung, die in der Tabelle 5.4 dargestellt sind, erkennt man, dass sowohl die Segmentierungsergebnisse der *Dual-GVF-Snakes* als auch die der *GVF-Snakes* nicht so nahe an der Referenzkontur liegen wie in dem Bild ohne Rauschen. Desweiteren beeinflusst auch der Grauwertverlauf des Bildes die Kanten des Objektes. Bei einem konstanten Grauwert liegen die Segmentierungsergebnisse beider Konturen nahe an der Referenzkontur, während bei dem sinusförmigen HG beide Verfahren durch diesen beeinflusst werden.

Die *GVF-Snakes* mit der Kontur innerhalb des Objektes liegt durchschnittlich am nächsten an der Referenzkontur, während die *GVF-Snakes* mit der Kontur außerhalb bei starkem Rauschen und unterschiedlichen HGs weiter von der Referenzkontur abweichen. Die Segmentierungsergebnisse der *Dual-GVF-Snakes* liegen durchschnittlich nicht so nahe an der Referenzkontur wie die der *GVF-Snakes* mit der Startkontur innerhalb, aber näher an der Referenzkontur als die *GVF-Snakes* mit der Startkontur außerhalb. Da die Region innerhalb des Objektes homogener ist als die Region außerhalb des Objektes, findet die Energieminimierung der inneren Kontur kein lokales Minimum, sondern das globale Minimum. Die schlechten Durchschnittswerte der *Dual-GVF-Snakes* entstehen dadurch, dass die Kontur insgesamt um einen Pixel zur Referenzkontur verschoben ist. Außerdem erkennt man in den visuellen Ergebnissen, dass die Kontur in konvexen Objektabschnitten im Vergleich zu den *GVF-Snakes* (Startkontur innen) keine "Ausreißer"-Konturpunkte hat.

#### 5.4.2 Ergebnisse der synthetischen Bilder mit zwei Objekten

In Abbildung 5.8 werden die Segmentierungsergebnisse von einem synthetisch hergestellten Bild mit zwei Objekten dargestellt. Dabei wurde bei den *GVF-Snakes* eine Startkontur außerhalb der beiden Objekte gesetzt, eine innerhalb des ovalen Objektes und eine Kontur innerhalb des Objektes mit konkaven Formen. Das Verfahren der *Dual-GVF-Snakes* hat die gleichen Startkonturen wie die *GVF-Snakes*, werden aber alle gleichzeitig während des Minimierungsprozesses der *Dual-GVF-Snakes* benötigt und erstellt.



**Abbildung 5.8:** Segmentierungsergebnisse der synthetischen Bilder mit *GVF-Snakes* mit zwei Objekten und drei unterschiedlichen Startkonturen, die unterschiedliche Parametereinstellungen haben, und gleichzeitig erstellte Segmentierungsergebnisse der *Dual-GVF-Snakes* mit den gleichen Parametereinstellungen

$\sigma_n = 0$ , linearer HG	Äußere Kontur	Innere Kontur Objekt	Innere Kontur Kreis	Mittelwert
<i>GVF-Snakes</i>				
$\bar{d}$	0,431	0,430	0,331	0,387
$d_{min}$	0,001	0,004	0,001	0,002
$d_{max}$	3,674	3,564	1,971	2,254
$\sigma_d$	0,585	0,533	0,282	0,382
<i>Dual-GVF-Snakes</i>				
$\bar{d}$	0,452	0,406	0,395	0,418
$d_{min}$	0,000	0,006	0,000	0,002
$d_{max}$	4,019	2,035	1,112	2,389
$\sigma_d$	0,539	0,333	0,308	0,393

**Tabelle 5.5:** Werte der Abstandsberechnung zwischen manueller, *GVF-Snakes* und *Dual-GVF-Snakes* Segmentierung von den synthetisch erstellten Bildern mit zwei Objekten in Pixel (px)

#### 5.4.2.1 Ergebnisse *GVF-Snakes*

Das Ergebnis der Segmentierung mittels der *GVF-Snakes* mit einer Kontur, die außerhalb der beiden Objekte liegt, beinhaltet beide Objekte, aber auch den Raum zwischen den beiden Objekten. Die Kontur nähert sich von außen an die Kante und findet ein Minimum an den Objektkanten und zwischen den beiden Kanten der beiden Objekte. Da die Kontur aber keine topologischen Veränderungen durchführen kann, wird die Kontur zwar durch die externen Kräfte in den Zwischenraum der beiden Objekte gezogen, doch die inneren Kräfte verhindern, dass sich die Kontur in zwei Konturen auftrennt. Die *GVF-Snakes* können die Ellipse ohne Probleme segmentieren, da an den Kanten ein starker Gradientenbetrag vorzufinden ist und die Textur der Ellipse homogen ist. Das Objekt mit den konkaven und konvexen Strukturen wird in den synthetischen Bildern ohne Probleme segmentiert. Durch die Ellipse, dessen Kante einen stärkeren Gradientenbetrag hat, wird die Kontur des Objektes von der Kante der Ellipse angezogen und überschreitet die Kontur des gesuchten Objektes (s. Tabelle 5.8). Dass die Zielkontur in einem Bereich von der Referenzkontur entfernt liegt, erkennt man auch an dem maximalen Abstand  $d_{max} = 3.564$  der inneren Kontur des Objektes mit konkaven und konvexen Strukturen und den ansonsten niedrigen Werten der Standardabweichung und des Mittelwertes (s. Tabelle 5.5).

#### 5.4.2.2 Ergebnisse *Dual-GVF-Snakes*

Sowohl die Ellipse als auch das Objekt mit den konkaven und konvexen Abschnitten werden mit den *Dual-GVF-Snakes* ohne Probleme gleichzeitig segmentiert. Für den Minimierungsprozess der drei gesetzten Konturen werden immer die gleichen Parameter verwendet. Betrachtet man die drei Zielkonturen einzeln, so haben die Konturen, die innerhalb des Objektes gesetzt wurden, die beiden Objekte segmentiert. Damit die Kontur, die innerhalb des Objektes mit konkaven und konvexen Abschnitten gesetzt wurde, die Kontur des Objektes nicht überschreitet, wirken während des Minimierungsprozesses die modifizierten *adaptive driving forces* entgegen der Anziehungskraft des starken Gradientenbetrags der anderen Kontur (s. Abschnitt 4.5.4). Das Segmentierungsergebnis der äußeren Kontur beinhaltet die beiden Objekte und auch den Bereich zwischen den beiden Objekten. Daher ist das Ergebnis ähnlich dem Ergebnis der *GVF-Snakes* mit der äußeren Initialisierung. Zwei Faktoren des Minimierungsprozesses beeinflussen die äußere Kontur: die *adaptive driving forces* und die Aufteilung der Konturen in Segmente. Wie in Abschnitt 4.5.3.2 beschrieben wird die Kontur in Segmente aufgeteilt um damit die korrespondierenden Punkte zu berechnen. Durch die *adaptive driving forces* wird die äußere Kontur zu den korrespondierenden Punkten und damit nicht in den Zwischenraum gezogen.

Distance Search	3	Distanz, in der die Kontur sich bewegt
Displacement min	1.00	
Displacement max	2.00	
Threshold dist positive	20	Distanzbereich, indem eine Kontur wachsen oder schrumpfen kann
Threshold dist negative	20	
Inv alpha min	0.60	Minimaler und maximaler Alpha-Wert der Deriche Filterung
Inv alpha max	1.00	
Reg min	5.00	Minimaler und maximaler Regularisierungswert
Reg max	10.00	
Mul factor	0.3000	Multiplikationsfaktor für die Modifikation der oben angegebenen Werte
Gradient threshold:	5	
Number of iterations:	50	
Step result show:	1	

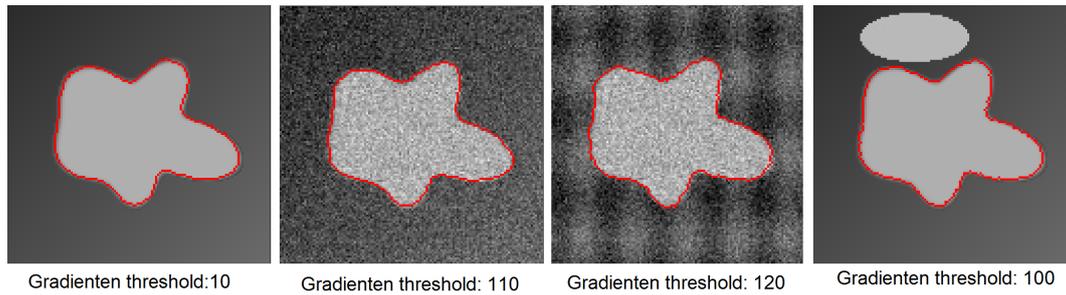
Abbildung 5.9: Parametereinstellungen der *AB-Snakes*

### 5.4.3 Vergleich *GVF-Snakes* und *Dual-GVF-Snakes*

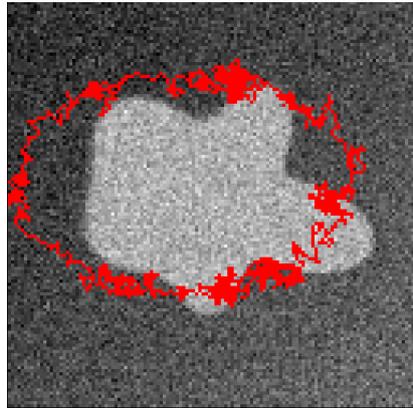
Sowohl die *GVF-Snakes* als auch die *Dual-GVF-Snakes* haben keine Probleme die synthetisch hergestellten Bilder mit einem Objekt zu segmentieren. Dieses ist sowohl in der Visualisierung der Konturen (s. Abbildungen 5.6 und 5.7) als auch in den Abstandswerten zu erkennen (s. Tabelle 5.4). Probleme treten bei den *GVF-Snakes* auf, sobald zwei Objekte unterschiedlich hohe Gradientenbeträge aufweisen und die Objekte nahe aneinander liegen. Dabei wird das Objekt mit einem hohen Gradientenbetrag an der Kante gut segmentiert, aber bei der Objektkante mit einem niedrigeren Gradientenbetrag wird die Kontur zur Kante des anderen Objektes gezogen. Dieses Problem wurde bei den *Dual-GVF-Snakes* durch die Segmentaufteilung und durch die modifizierten *adaptive driving forces* verringert.

### 5.4.4 *AB-Snakes*

Die *AB-Snakes* wurden von Andrey und Boudier [5] entwickelt und in Abschnitt 3.2.5 erläutert. Das hier verwendete Programm wurde von Andrey und Boudier in *ImageJ* implementiert. Für die Implementierung werden die Parameter, die in Abbildung 5.9 dargestellt sind, benötigt. Die *AB-Snakes* segmentieren die Objekte in den synthetisch hergestellten Bildern gut. Die in Abbildung 5.10 segmentierten Objekte wurden mit den Parametereinstellungen aus Abbildung 5.9 segmentiert. Lediglich der *gradient threshold* wurde angepasst (s. Beschriftung der Abbildung 5.10) und die Anzahl der Iterationen



**Abbildung 5.10:** Segmentierungsergebnisse mit *AB-Snakes*



**Abbildung 5.11:** Segmentierungsergebnis der *AB-Snakes* eines verrauschten Bildes mit einem *gradient threshold* 40, 10 Iterationen

auf 10 gesetzt. Problematisch ist aber das Setzen der passenden Parameter besonders bei verrauschten Bildern. In Abbildung 5.11 wird als Beispiel ein Segmentierungsergebnis eines verrauschten Bildes dargestellt, das mit den in Abbildung 5.9 angegebenen Parametern, einem *gradient threshold* von 40 und 10 Iterationsschritten, segmentiert worden ist. Dabei ist zu erkennen, dass auf Grund des falschen *gradient threshold*, der im Bereich von 100 liegen sollte, die Konturpunkte immer wieder ein Minimum finden. Das gesuchte lokale Minimum der Objektkontur wird nicht gefunden. Für den Anwender ist es in dem Fall unintuitiv zu erkennen, welche der Parameter falsch eingestellt sind und wie diese verbessert werden können. Besonders schwierig ist die richtige Parametereinstellung bei den klinischen Bildern zu finden, daher wurden die Segmentierungsergebnisse der klinischen Bilder nicht weiter evaluiert.

## 5.5 Klinische Bilder

Die Segmentierungsergebnisse der klinischen Bilder werden wie die synthetischen Bilder visuell dargestellt und es werden die Abstände zu der Referenz-

Bild	Aorta	Aorten- aneurysma	Mittelwert
<i>GVF-Snakes; Startkontur innen</i>			
$\bar{d}$	0,653	0,331	0,492
$d_{min}$	0,001	0,001	0,001
$d_{max}$	6,167	6,105	6,136
$\sigma_d$	0,776	0,951	0,863
<i>GVF-Snakes; Startkontur außen</i>			
$\bar{d}$	0,674	5,752	3,213
$d_{min}$	0,001	0,016	0,009
$d_{max}$	3,969	41,510	22,739
$\sigma_d$	0,757	6,442	3,600
<i>Dual-GVF-Snakes</i>			
$\bar{d}$	0,430	0,635	0,533
$d_{min}$	0,003	0,003	0,003
$d_{max}$	2,784	5,528	4,156
$\sigma_d$	0,398	0,772	0,585

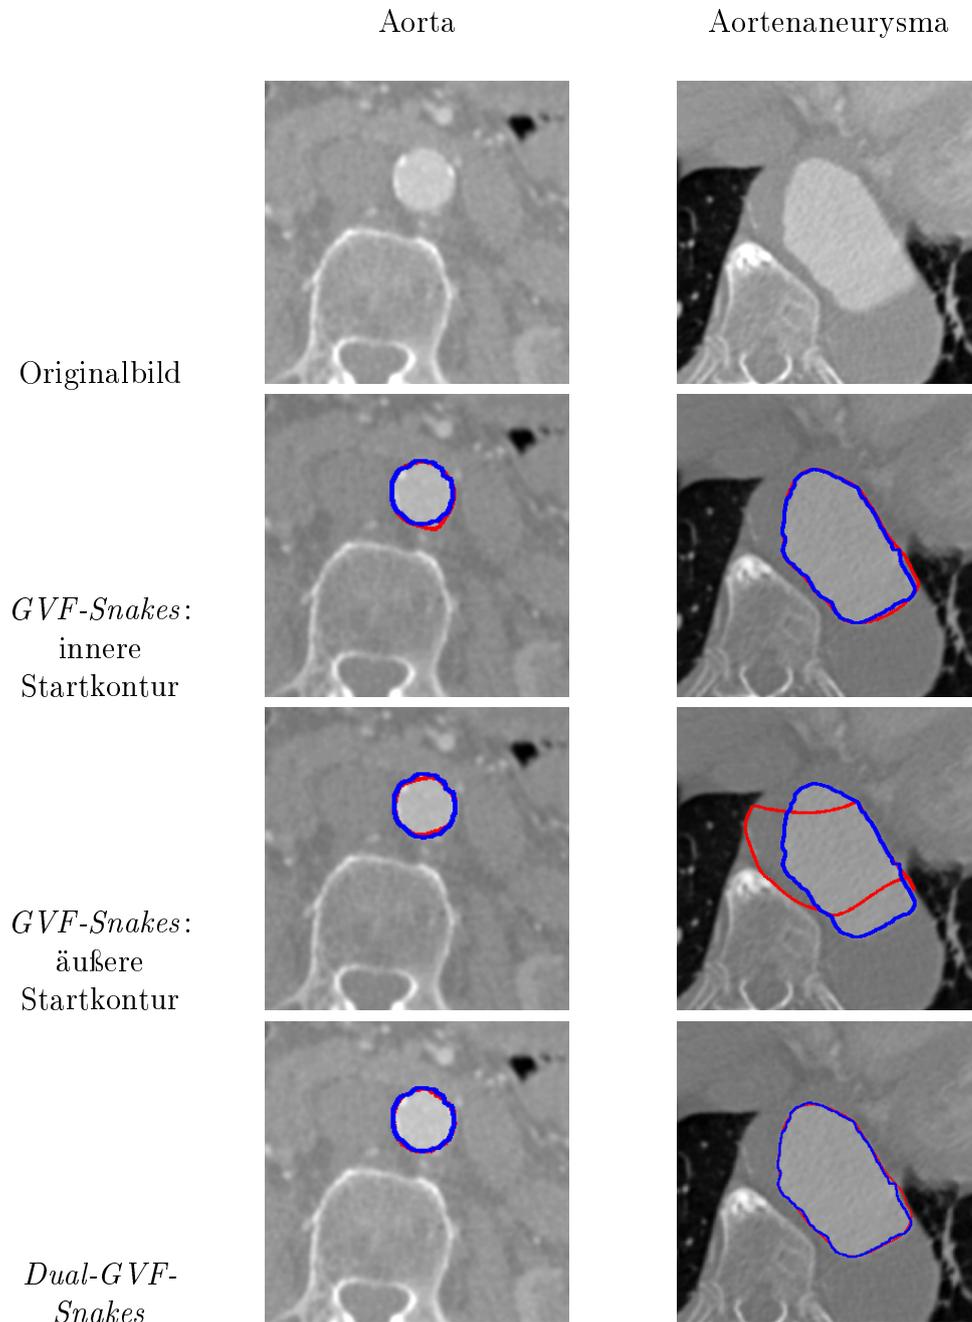
**Tabelle 5.6:** Werte der Abstandsberechnung zwischen manueller, *GVF-Snakes* und *Dual-GVF-Snakes* Segmentierung der klinischen Bilder einer Aorta und eines Aortenaneurysmas in Pixel (px)

kontur angeben.

## 5.5.1 Klinische Bilder mit einem Lumen

### 5.5.1.1 Ergebnisse *GVF-Snakes*

Die *GVF-Snakes* kann Objekte mit Kanten, die einen starken Gradientenbetrag haben, und einer Startkontur innerhalb einer homogenen Region mit kleineren Problemen segmentieren (s. Tabelle 5.12, linke Spalte). Soll aber ein Objekt segmentiert werden, welches an den Kanten einen schwachen Gradientenbetrag hat und außerdem in der Nähe von Strukturen liegt, deren Kanten einen höheren Gradientenbetrag haben, konvergiert das Minimierungsverfahren in einem lokalen Minimum. Dieses Minimum ist in dem Segmentierungsergebnis des Aortenaneurysmas mit einer Startkontur außerhalb des Lumens zu erkennen (s. Abbildung 5.12). Da die Bildkante der Lunge einen hohen Gradientenbetrag hat, wird die Kontur von weitem zu der Kante der Lunge gezogen. Durch die internen Kräfte wird auch der Rest der Kontur beeinflusst und überschreitet Kanten des Lumens. Die Kontur entfernt sich bis zu  $d_{max} = 41 \text{ px}$  von der Referenzkontur und auch die Standardabweichung  $d_\sigma = 6,442 \text{ px}$  und der Mittelwert  $\bar{d} = 5,5752 \text{ px}$  zeigen, dass sich die Kontur weit von der



**Abbildung 5.12:** Ergebnisse der Segmentierung von klinischen Bildern einer Aorta und eines Aortenaneurysmas; die blaue Kontur ist die Referenzkontur und die rote die automatisch generierte Kontur

Referenzkontur entfernt befindet (s. Tabelle 5.6). Auch bei Versuchen mit unterschiedlich vielen Iterationen des *gradient vector field* und der Kantenenergie  $E_{edge}$  konnte dieses Problem nicht gelöst werden.

### 5.5.1.2 Ergebnisse *Dual-GVF-Snakes*

Sowohl das Segmentierungsergebnis der Aorta als auch des Aortenaneurysmas mittels der *Dual-GVF-Snakes* liegt nahe an der Referenzkontur (s. Abbildung 5.12). Schon während des Verformungsprozesses erkennt man, dass die äußere Kontur nicht zu den hohen Gradientenbeträgen der Kanten der Lunge angezogen wird. Durch die *adaptive driving forces* wird die Kontur zur inneren Kontur gezogen. Nur in Fällen, bei denen hohe Gradientenbeträge sich in unmittelbarer Nähe der Startkontur befinden, kann es sein, dass die Kontur von der Kante angezogen wird und damit die Kontur nach außen verformt wird.

### 5.5.1.3 Vergleich *GVF-Snakes* und *Dual-GVF-Snakes*

Sowohl die *GVF-Snakes* als auch die *Dual-GVF-Snakes* haben Probleme Objekt zu segmentieren, deren Kanten einen niedrigeren Gradientenbetrag als Kanten anderer Objekte, die sich in der Nähe des gesuchten Objektes befinden, aufweisen. Die Kontur wird zu der Kante mit dem höheren Gradientenbetrag gezogen. Dieses erkennt man sowohl im Segmentierungsergebnis der *GVF-Snakes* mit einer inneren Startkontur als auch im Ergebnis der *Dual-GVF-Snakes* (s. Abbildung 5.12). Der Vorteil der *Dual-GVF-Snakes* ist aber, dass durch die innere und äußere Kontur und der *adaptive driving forces* der Bereich, in dem sich die gesuchte Kontur befindet, eingeschränkt wird und damit die Kontur nicht zu Kanten mit starkem Gradientenbetrag weit außerhalb des gesuchten Objektes gezogen wird. Desweiteren erkennt man, dass die Kontur der *GVF-Snakes* (Startkontur innen) schwache Kanten leicht überschreitet und damit eine schlechtere Standardabweichung von  $d_\sigma = 0,951$  aufweist. Ansonsten liegt die Zielkontur der *GVF-Snakes* näher an der Referenzkontur, was der mittlere euklidische Abstand von  $\bar{d} = 0.331$  zu dem der *Dual-GVF-Snakes* von  $\bar{d} = 0.635$  belegt. Hier tritt wieder das Problem auf, dass die Zielkontur der *Dual-GVF-Snakes* die Kontur besser segmentiert hat, aber durchgängig um einen Pixel von der Referenzkontur abweicht.

## 5.5.2 Klinische Bilder mit zwei Lumen

Bei den klinischen Bildern mit zwei zu segmentierenden Lumen werden für die Minimierung mittels der *GVF-Snakes* nur Startkonturen verwendet, die innerhalb der Lumen gesetzt werden. Der Grund dafür ist, dass Konturen mit einer Startkontur außerhalb des Lumens ein lokales Minimum finden, da das

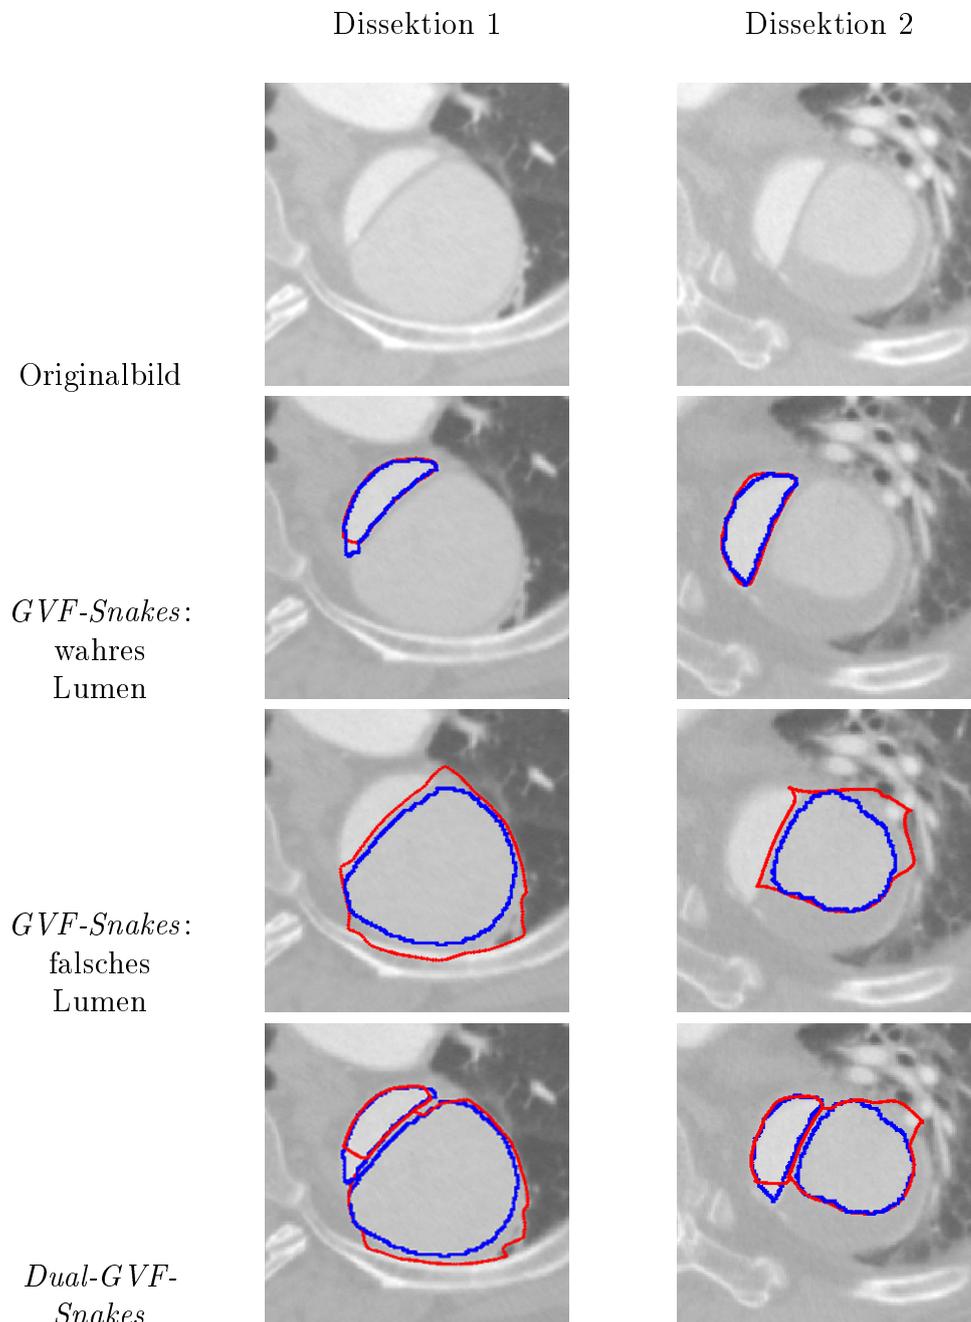
Bild	Bild 1a	Bild 1b	Bild 2	Bild 3	Bild 4	Mittelwert
<i>GVF-Snakes</i> ; wahres Lumen						
$\bar{d}$	0,321	0,532	0,440	0,476	0,550	0,464
$d_{min}$	0,001	0,001	0,001	0,010	0,006	0,004
$d_{max}$	2,647	6,105	1,417	1,465	3,290	2,985
$\sigma_d$	0,339	0,951	0,350	0,335	0,687	0,532
<i>GVF-Snakes</i> ; falsches Lumen						
$\bar{d}$	2,691	2,650	2,257	2,942	1,094	2,326
$d_{min}$	0,015	0,026	0,071	0,006	0,008	0,025
$d_{max}$	9,943	7,939	8,370	7,230	4,862	7,668
$\sigma_d$	2,334	1,989	2,386	2,148	1,314	2,034
<i>Dual-GVF-Snakes</i> ; wahres Lumen						
$\bar{d}$	0,310	0,514	0,445	0,788	0,458	0,503
$d_{min}$	0,001	0,011	0,001	0,005	0,005	0,005
$d_{max}$	1,709	2,538	2,337	4,039	2,973	2,719
$\sigma_d$	0,311	0,456	0,427	0,775	0,559	0,506
<i>Dual-GVF-Snakes</i> ; falsches Lumen						
$\bar{d}$	1,778	2,042	1,541	1,859	1,742	1,792
$d_{min}$	0,002	0,002	0,003	0,002	0,030	0,008
$d_{max}$	6,747	6,791	8,384	6,899	7,360	7,236
$\sigma_d$	1,626	1,676	2,083	1,767	1,674	1,765

**Tabelle 5.7:** Werte der Abstandsberechnung zwischen manueller, *GVF-Snakes* und *Dual-GVF-Snakes* Segmentierungsergebnissen der Aortendisektion in Pixel (px)

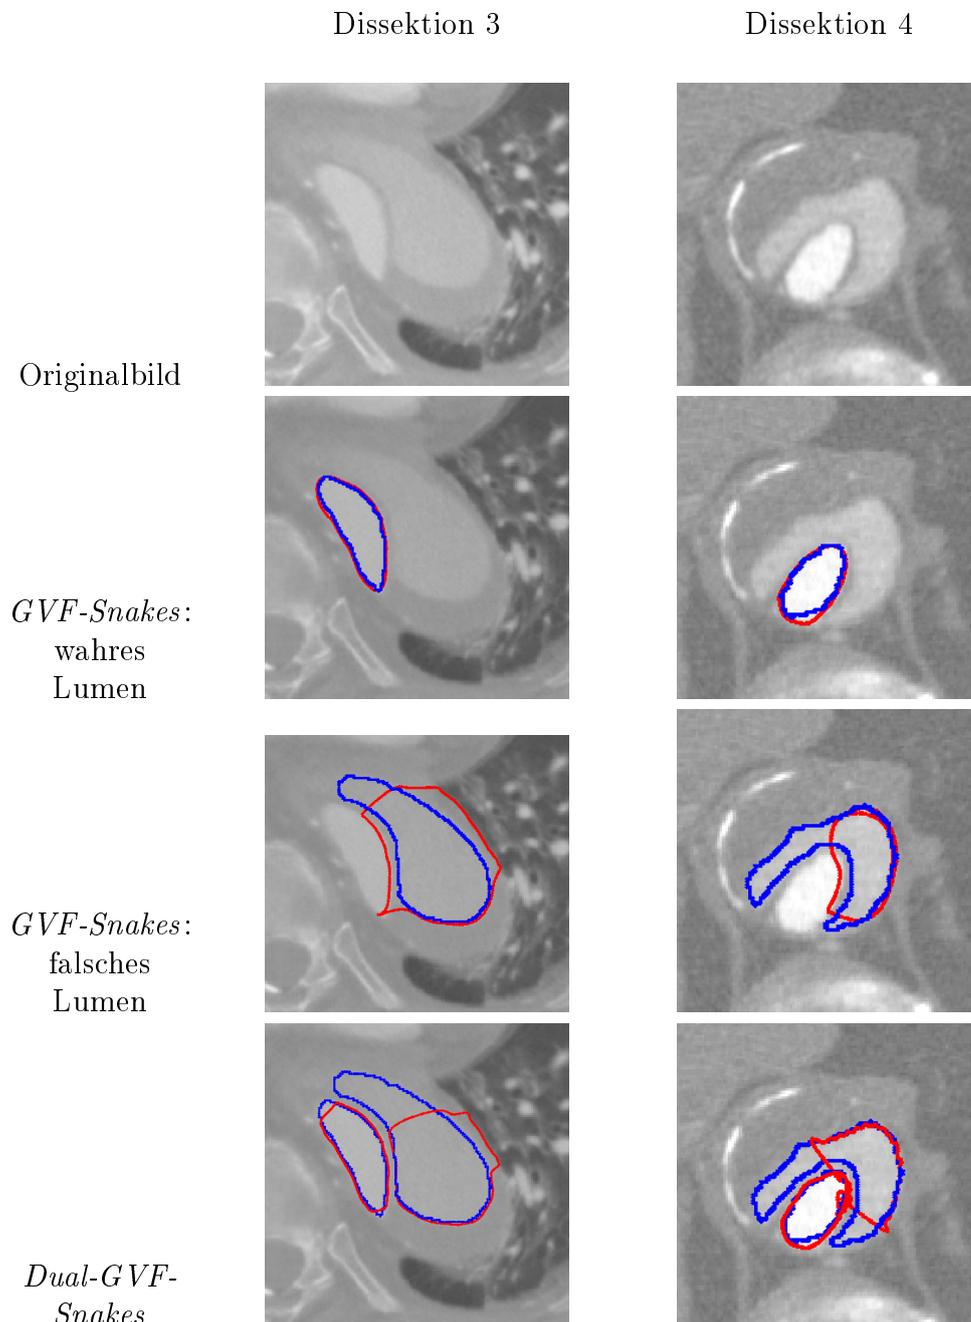
Lumen von verschiedenen Strukturen umgeben ist, welche hohe Gradientenbeträge aufweisen. Im Gegensatz dazu ist die Region innerhalb des Lumens homogen. Desweiteren muss die Gewichtung der Kantenenergie auf den Wert  $E_{edge} = 100$  erhöht werden, damit Kanten in den Bildern erkannt werden.

### 5.5.2.1 Ergebnisse *GVF-Snakes*

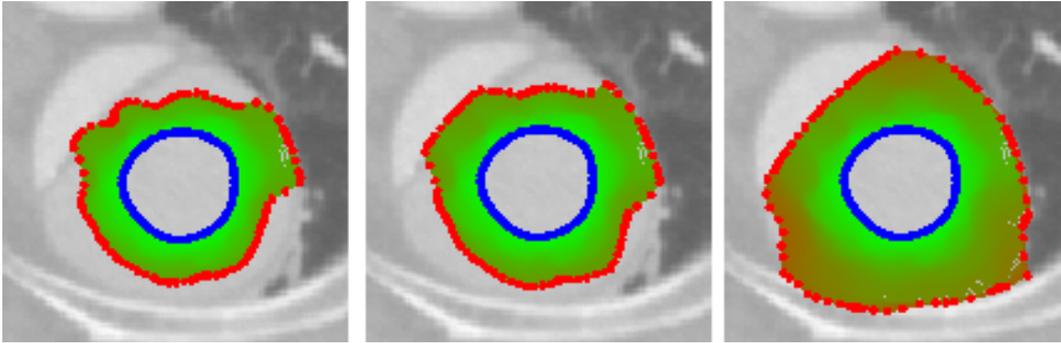
Wie schon in Abschnitt 5.5.1.1 erwähnt, hat das Minimierungsverfahren der *GVF-Snakes* keine Probleme Objekte in verrauschten klinischen Bildern zu segmentieren, falls die Startkontur innerhalb einer homogenen Region gesetzt wird und die Kanten des Objektes einen starken Gradientenbetrag aufweisen. So erkennt man in den Abbildungen 5.13 und 5.14 und auch in der Tabelle 5.7, dass sich die Segmentierungsergebnisse aller wahren Lumina nahe an den Referenzkonturen befinden. Dies liegt daran, dass die Region innerhalb des Lumens homogen ist und dass das wahre Lumen einen helleren Grauwertes hat, was



**Abbildung 5.13:** Ergebnisse der Segmentierung von klinischen Bildern von Aortendissektionen; die blaue Kontur ist die Referenzkontur und die rote die automatisch generierte Kontur



**Abbildung 5.14:** Ergebnisse der Segmentierung von klinischen Bildern von Aortendissektionen; die blaue Kontur ist die Referenzkontur und die rote die automatisch generierte Kontur



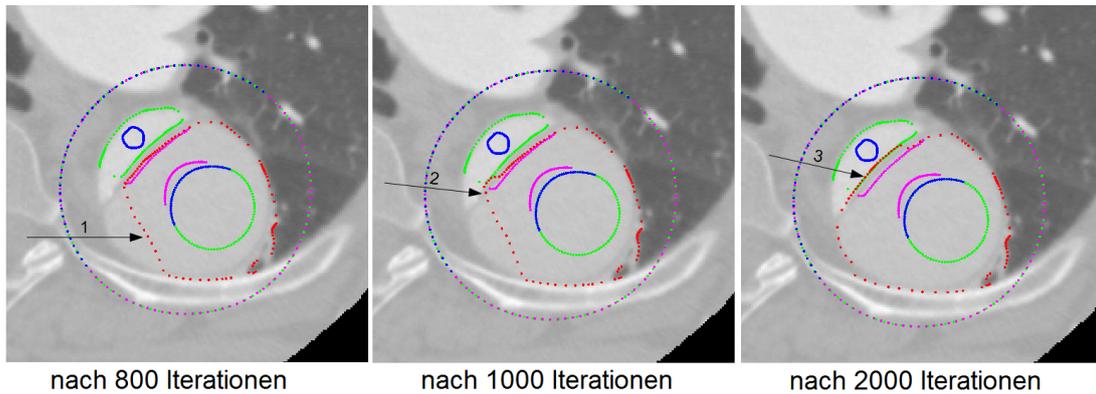
**Abbildung 5.15:** *GVF-Snakes*: Verformungsprozess der inneren Kontur im Bild Dissektion 1; blaue Kontur: Startkontur; rote Kontur: aktuelle Kontur; grüner Bereich: Bewegung der Kontur von der Startkontur bis zur aktuellen Kontur und der Bereich wird nach jedem Iterationsschritt dunkler

einen größeren Gradientenbetrag als das falsche Lumen zur Folge hat. Probleme treten bei der Segmentierung des falschen Lumens auf. In Abbildung 5.15 wird der Verformungsprozess der Kontur, die innerhalb des falschen Lumens gesetzt wurde, in zeitlicher Abfolge für drei unterschiedliche Iterationsschritte dargestellt. Die Kante des falschen Lumens, die sich an der Membran zwischen dem falschen und wahren Lumen befindet, wird nur von einigen wenigen Punkten der Kontur erkannt. Die meisten Konturpunkte werden aber durch den starken Gradientenbetrag der Kante des wahren Lumens zu dieser Kante gezogen. Anschließend werden durch die interne Energie Konturpunkte in der unmittelbaren Umgebung auch an diese Kante gezogen. Damit ist ein Berechnen des Energieminimums an dieser Kante nicht möglich. Auf Grund dieser Kante liegt sowohl die Standardabweichung  $d_\sigma$  als auch der Mittelwert  $\bar{d}$  der Segmentierungsergebnisse der *GVF-Snakes* des falschen Lumens im Bereich von 2 bis 3 px (s. Tabelle 5.7). Desweiteren kann der Algorithmus mit den aktuellen Parametereinstellungen keine konkaven Objekte segmentieren (s. Abbildung 5.14 *GVF-Snakes* falsches Lumen).

### 5.5.2.2 Ergebnisse *Dual-GVF-Snakes*

Die Gradientenbeträge der Membran zwischen den beiden Lumen bewirkt, dass die Kontur zu der Kante mit dem größeren Gradientenbetrag gezogen wird. Da die Membran aber eine gewisse Breite besitzt, werden bei den *Dual-GVF-Snakes*, wie in Abschnitt 4.5.4 beschrieben, die korrespondierenden Punkte versetzt und die *adaptive driving forces* neu gewichtet. Diese Kräfte sorgen dafür, dass die Kontur die Membran nicht überschreitet.

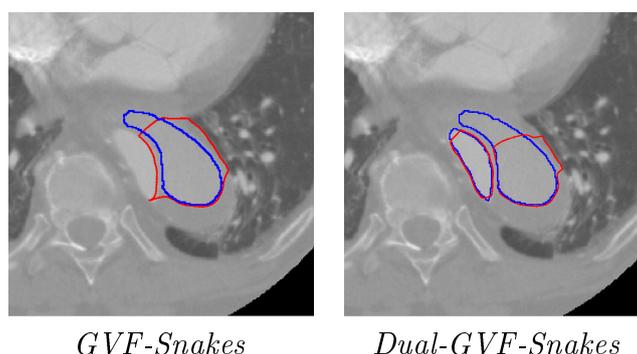
Trotzdem kann der Fall eintreten, dass die Kontur zur falschen Objektkante gezogen wird: In Abbildung 5.16 wird der Verformungsprozess der *Dual-GVF-Snakes* für drei unterschiedliche Iterationsschritte am Beispiel der Dissektion 1



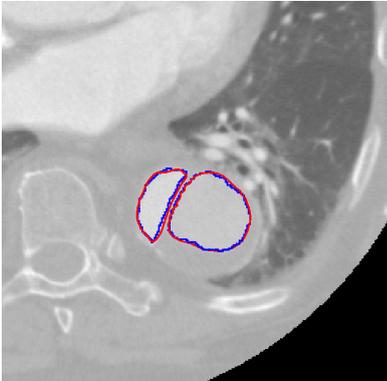
**Abbildung 5.16:** *Dual-GVF-Snakes*: Verformungsprozess der inneren Kontur des falschen Lumens im Bild Dissektion 1

veranschaulicht. Die roten Punkte zeigen, an welcher Stelle sich die Kontur befindet. Die blauen und grünen Punkte zeigen die Startkonturen an und die rosa Punkte die korrespondierenden Punkte. Nach den ersten 800 Iterationsschritten erkennt man, dass sich die Kontur nahe der Objektkontur befindet. In der Region, in die der Pfeil 1 hineinzeigt (s. Abbildung 5.16), hat die Kontur noch kein Energieminimum gefunden. Nach 1000 Iterationsschritten erkennt man, dass die Kontur nicht mehr von den *adaptive driving forces* von der falschen Objektkontur des anderen Lumens ferngehalten wird, da sich die korrespondierenden Punkte nicht mehr auf der richtigen Objektkanten. Die externen Kräfte ziehen die Kontur zu der Objektkontur mit dem stärkeren Gradientenbetrag. Anschließend werden die Konturpunkte durch die internen und externen Kräfte zur Kontur mit dem stärkeren Gradientenbetrag gezogen. Die Kräfte der *adaptive driving forces* sind nicht stark genug um die Konturpunkte im aktuellen Minimum zu halten (s. Pfeil 3 Abbildung 5.16). Die Kontur wird aber auch auf Grund von einem sehr schwachen Gradientenbetrag von der Kante des falschen Lumens an die Kante des wahren Lumens gezogen. Um dieses zu vermeiden könnten die *adaptive driving forces* stärker gewichtet werden. Dieses hätte aber zur Folge, dass auf die andere Kontur so starke Anziehungskräfte in Richtung der korrespondierenden Punkte wirken, dass die Kontur alle weiteren Kanten überschreitet.

In Abbildung 5.14 des Segmentierungsergebnisses der *Dual-GVF-Snakes* der Aortendissektion 3 erkennt man, dass die Zielkontur des falschen Lumens nicht von der Kante des wahren Lumens angezogen wurde. Dieses liegt daran, dass die Kräfte der versetzten korrespondierenden Punkte gegen die externen Kräfte der Kontur, die die Kontur zu den der Kante des wahren Lumens ziehen, durchgängig wirken.



**Abbildung 5.17:** Ergebnisse der Segmentierung des falschen Lumens im Bild Dissektion 3 mittels der *GVF-Snakes* und der *Dual-GVF-Snakes*

	<i>Dual-GVF-Snakes</i> ; wahres Lumen	
	$\bar{d}$	0,372
	$d_{min}$	0,001
	$d_{max}$	1,555
	$\sigma_d$	0,3223
<i>Dual-GVF-Snakes</i> ; falsches Lumen		
$\bar{d}$	0,463	
$d_{min}$	0,004	
$d_{max}$	2,224	
$\sigma_d$	0,420	

**Abbildung 5.18:** Ergebnis der Segmentierung des Bildes Dissektion 2 mittels der *Dual-GVF-Snakes* mit *spring forces* und *volcano forces*

### 5.5.2.3 Ergebnisse der *Dual-GVF-Snakes* mit zusätzlichen Kräften

Durch die *spring forces* und der *volcano forces* können Benutzerinteraktionen hinzugefügt werden. Die in Abbildung 5.18 dargestellte Aortendissektion weist besonders an den Kanten des falschen Lumens einen schwachen Gradientenbetrag auf. Dadurch wird die Kontur häufig von naheliegenden Strukturen mit einem höheren Gradientenbetrag angezogen. Um dieses zu verhindern werden die zusätzlichen Kräfte der *spring forces* und der *volcano forces*, wie in Abbildung 5.19 dargestellt, hinzugefügt. Durch diese Kräfte liegt das Ergebnis nahe an der Referenzkontur und auch die Abstandswerte der *Dual-GVF-Snakes* zu der Referenzkontur sind gering. Dieses zeigt auch der Vergleich der beiden manuell segmentierten Konturen (s. Abschnitt 5.3) mit den Abstandswerten des Ergebnisses der *Dual-GVF-Snakes* mit den zusätzlichen Kräften. So ist der arithmetische Mittelwert der *Dual-GVF-Snakes* Segmentierung des wahren Lumens nur um 0,17 px und des falschen Lumens 0,21 px größer als im Vergleich der beiden manuellen Segmentierungen. Die Standardabweichung ist sogar geringer.



**Abbildung 5.19:** Ergebnis der *Dual-GVF-Snakes* mit den Positionen der *spring forces* und der *volcano forces*

#### 5.5.2.4 Vergleich *GVF-Snakes* und *Dual-GVF-Snakes*

Sowohl die *GVF-Snakes* als auch die *Dual-GVF-Snakes* haben das Problem Kanten mit einem kleinen Gradientenbetrag zu erkennen bzw. durch Kanten mit einem großen Gradientenbetrag angezogen zu werden (s. Tabelle 5.13 und 5.14). Auch haben die *GVF-Snakes* und die *Dual-GVF-Snakes* mit den hier verwendeten Parametereinstellungen Probleme konkave Objekte zu segmentieren.

Die Membran zwischen dem wahren und falschen Lumen der Aortendissektion mit unterschiedlichen Intensitätswerten der beiden Lumen kann von den *GVF-Snakes* nicht segmentiert werden. Die inneren Konturen werden zum Lumen mit dem stärkeren Gradientenbetrag gezogen und berücksichtigen dabei die andere Kante der Membran nicht. Die *Dual-GVF-Snakes* segmentieren die Kante zwischen dem wahren und falschen Lumen meist richtig (s. Tabelle 5.13 und 5.14). Sie haben aber das Problem, dass Konturpunkte bei nicht vorhandenen Kanten zur Kante des anderen Objektes gezogen werden und durch die interne und externe Energie weitere Konturpunkte zur falschen Kante gezogen werden. In Abbildung 5.17 werden die Ergebnisse der beiden Verfahren anhand der Aortendissektion 3 dargestellt, wobei man an diesem Beispiel erkennt, dass die Kontur des falschen Lumens nicht von der Kante des wahren Lumens angezogen wird.

Die Minimierung der *Dual-GVF-Snakes* benötigt ein Vielfaches an Rechenzeit der *GVF-Snakes*. Dies liegt daran, dass die *Dual-GVF-Snakes* zwei bzw.

drei Konturen gleichzeitig minimieren, während die *GVF-Snakes* nur eine bzw. zwei Konturen minimieren. Auf der anderen Seite kann aber der Fall eintreten, dass die Parametereinstellungen der *GVF-Snakes* nicht optimal gewählt wurden und daher mehrfach korrigiert werden müssen. Dieses hat zur Folge, dass mehrere Minimierungsdurchläufe durchgeführt werden müssen.



# Kapitel 6

## Diskussion und Ausblick

*Snakes* stellen ein mächtiges Werkzeug in der Bildverarbeitung dar. In dieser Arbeit wurde eine Erweiterung der *Snakes*, die *Dual-GVF-Snakes*, verwendet um das Lumen der Aorta und verschiedener Aortenpathologien in CTA-Aufnahmen zu segmentieren. Die entwickelte Methode ist eine Kombination aus *Dual Snakes* und *GVF-Snakes* und wird *Dual-GVF-Snakes* genannt. Zur Segmentierung eines Objektes werden dafür zwei Initialisierungen benötigt, eine innerhalb und eine außerhalb des gesuchten Objektes. Da sowohl von außen als auch von innen ein Minimum gesucht wird und immer die Kontur mit der größeren Energie weiterverformt wird, ziehen sich die Konturen gegenseitig aus einem lokalen Minimum.

Da mit diesem Verfahren auch zwei Objekte gleichzeitig segmentiert werden sollen, wurde in dieser Arbeit das Verfahren der *Dual-GVF-Snakes* so weiterentwickelt. Dabei werden zwei Initialisierungskonturen innerhalb der beiden Objekte und eine Initialisierungskontur außerhalb der beiden Objekte gesetzt. Zum Finden der korrespondierenden Punkte werden die drei Konturen in Segmente aufgeteilt.

Eine besondere Herausforderung stellen die Datensätze der Aortendissektion dar, da es vorkommt, dass die Intensitäten innerhalb des Lumens variieren und damit Kanten mit unterschiedlich starkem Gradientenbetrag vorhanden sind. Dieses Problem kann mit einer Segmentaufteilung der drei Startkonturen und dem anschließenden Zuordnen von unterschiedlichen Eigenschaften minimiert werden. So kann ein gewisser Abstand zwischen den beiden Lumen erreicht werden, indem die korrespondierenden Punkte neu gesetzt werden und die *adaptive driving forces* die Konturpunkte zu den neu gesetzten Punkten ziehen.

Das Verfahren der *Dual-GVF-Snakes* wurde zur Segmentierung von Objekten in synthetischen und klinischen Bildern angewendet. Die synthetischen Bilder beinhalten entweder ein oder zwei Objekte und sind unterschiedlich stark verrauscht. Die klinischen Bilder sind CTA-Aufnahmen einer gesunden

Aorta, eines Aortenaneurysmas und unterschiedlichen Aortendissektion. Für die Bewertung, wie gut das Verfahren die gesuchten Objektkanten segmentiert hat, wird der Abstand zwischen der Referenzkontur und der automatisch generierten Kontur berechnet. Verglichen wurde das Verfahren mit den *GVF-Snakes* und den *AB-Snakes*. Dabei stellte sich heraus, dass ein Objekt in dem synthetisch hergestellten Bild mit Rauschen von allen drei Verfahren gut segmentiert wurde. Probleme traten bei der Segmentierung von einem Objekt in einem Bild mit zwei Objekten mit unterschiedlichen Gradientenbeträgen bei den *GVF-Snakes* auf. Auf Grund der unterschiedlich starken Gradientenbeträge wird die Kontur durch die externen Kräfte von der Kante mit einem niedrigeren Gradientenbetrag zur Kante mit dem höheren Gradientenbetrag gezogen. Die Ergebnisse der *AB-Snakes* liegen nahe der Referenzkontur. Das Problem bei diesem Verfahren ist, dass es um so schwieriger wird die richtigen Parameter einzustellen, je verrauschter das Bild ist. Die Objekte der klinischen Bilder werden daher nur mit den *Dual-GVF-Snakes* und den *GVF-Snakes* segmentiert. Dabei wurde festgestellt, dass beide Verfahren Probleme mit Kanten haben, die einen schwachen Gradientenbetrag aufweisen. Bei der Segmentierung der beiden Lumen tritt bei den *GVF-Snakes* das Problem auf, dass die Kontur das Energieminimum bei den Kanten mit einem starken Gradientenbetrag findet. Die Kontur der *Dual-GVF-Snakes* findet während des Verformungsprozesses das Minimum durch die *adaptive driving forces* bei den Kanten mit dem schwachen Gradientenbetrag. Außerdem können das wahre und das falsche Lumen gleichzeitig segmentiert werden und die *Dual-GVF-Snakes* benötigen gegenüber den *GVF-Snakes* weniger Parametereinstellungen. Durch die beiden Startkonturen ist das Verfahren der *Dual-GVF-Snakes* weniger sensitiv gegenüber Rauschen und umliegenden Strukturen. Bei den *GVF-Snakes* muss darauf geachtet werden, dass die Startkontur möglichst in der homogeneren Region liegt, welche entweder außerhalb oder innerhalb des Objektes vorzufinden ist.

Durch das Hinzufügen von Benutzerinteraktionen kann bei der Energieminimierung das globale Minimum an der Objektkontur gefunden werden und damit die Kräfte an Strukturen, die einen höheren Gradientenbetrag an ihren Kanten haben, minimiert werden.

## 6.1 Ausblick

Eine Weiterentwicklung des hier entwickelten Verfahrens ist unter verschiedenen Aspekten möglich. So kann das Setzen der Initialisierungen mit Hilfe von morphologischen Operatoren und/oder weiteren bildverarbeitenden Methoden automatisiert werden. Desweiteren ist es möglich das Verfahren so zu erweitern, dass auch mehr als zwei Objekte gleichzeitig segmentiert werden können.

Wie in dieser Arbeit erläutert, gibt es noch einige Erweiterungen der *Sna-*

kes, die das hier implementierte und analysierte Verfahren verbessern könnten.

- Die *GVF-Snakes* haben Probleme bei der Segmentierung von Objektkanten mit einem schwachen Gradientenbetrag in CTA-Aufnahmen. Amarpur und Kulkarni [2] stellen in ihrer Arbeit 19 Erweiterungen der externen Energie vor und präsentieren die Ergebnisse der Erweiterung von unterschiedlichen Bildaufnahmen. Danach sind *deformable super ellipses Snakes* [95] für die Segmentierung von CT-Aufnahmen geeignet. Sie sind im Vergleich zu anderen Verfahren weniger sensitiv für die Initialisierung und robuster gegenüber Lücken in Objektkanten.
- Interessant ist es auch das Kantenfeld mit dem *fluid vector field* [92] zu ersetzen, um dadurch konkave Objekte segmentieren zu können, ohne dass die Parameter speziell für dieses Problem angepasst werden müssen. Dieses Kantenfeld minimiert das Problem des begrenzten Einzugsbereiches der *GVF-Snakes* und kann komplexe Objekte mit stark ausgeprägten Konkavitäten gut segmentieren. Die Frage ist dabei, ob das Kantenfeld auf Grund des größeren Einzugsbereiches auch die Objektkanten mit einem schwachen Gradientenbetrag erkennt.
- Die *parallel double Snakes* [26] werden zur Segmentierung von zwei nahe gelegenen parallel verlaufenden Linien verwendet. Durch das Ersetzen des hier verwendeten Verfahrens der umfunktionierten *adaptiven driving forces* mit den *parallel double Snakes* könnte die Anzahl der Parameter reduziert werden und es wird erwartet, dass das Setzen der Parameter für die *GVF-Snakes* besser angepasst werden kann, da nicht mehr die schwächere Kante des wahren oder falschen Lumens berücksichtigt werden muss. Desweiteren wird erwartet, dass die *Snakes* die beiden Seiten der Membran besser segmentiert, da die Konturabschnitte zwei parallel verlaufende Linien suchen. Da die Mittellinie aber vom Benutzer gesetzt wird, muss man sich überlegen, wie die Initialisierung angepasst werden muss.
- Das Verfahren wurde bis jetzt nur in 2D implementiert. Da sowohl die *GVF-Snakes* als auch die *Dual Snakes* auf 3D erweiterbar sind, kann man das hier verwendete Verfahren auch auf 3D erweitern.



# Literaturverzeichnis

- [1] B. Al-Diri, A. Hunter, and D. Steel. An active contour model for segmenting and measuring retinal vessels. *IEEE Trans. Medical Imaging*, 28(9):1488–1497, 2009.
- [2] B. Amarapur and PK Kulkarni. External force for deformable models in medical image segmentation: A survey. *Signal & Image Processing*, 2(2):82–101, 2011.
- [3] W. F. Ames. *Numerical Methods for Partial Differential Equations*. Computer Science & Scientific Computing. Acad. Press, 1992.
- [4] A. A. Amini, S. Tehrani, and T. E. Weymouth. Using dynamic programming for minimizing the energy of active contours in the presence of hard constraints. In *Proceedings International Conference on Computer Vision*, pages 95–99. IEEE, 1988.
- [5] P. Andrey and T. Boudier. Adaptive active contours (snakes) for the segmentation of complex structures in biological images. *ImageJ Conference*, pages 18–29, 2006.
- [6] M. Auer and T. C. Gasser. Reconstruction and finite element mesh generation of abdominal aortic aneurysms from computerized tomography angiography data with minimal user interactions. *IEEE Trans. Med. Imaging*, 29(4):1022–1028, 2010.
- [7] A. Ayyalasomayajula, A. Polk, A. Basudhar, S. Missoum, L. Nissim, and J.V. Geest. Three dimensional active contours for the reconstruction of abdominal aortic aneurysms. *Annals of Biomedical Engineering*, 38(1):164–176, 2010.
- [8] H. G. Barrow, J. M. Tenenbaum, R. C. Bolles, and H. C. Wolf. Parametric correspondence and chamfer matching: Two new techniques for image matching. *Proceedings 5th Int. Joint Conf. Artificial Intelligence*, 29:659 – 663, 1977.
- [9] A. Borkowski. *Modellierung von Oberflächen mit Diskontinuitäten*. PhD thesis, Technische Universität Dresden, 2004.

- [10] A. J. Bulpitt, E. Berry, R. D. Boyle, D. J. Scott, and D. Kessel. A deformable model, incorporating expected structure information, for automatic 3d segmentation of complex anatomical structures. *Proceedings Computer Assisted Radiology and Surgery (CARS'00)*, pages 572–577, 2000.
- [11] V. Caselles, R. Kimmel, and G. Sapiro. Geodesic active contours. *International Journal of Computer Vision*, 22(1):61–79, 1997.
- [12] C. Chen, T.L. Poepping, J.J. Beech-Brandt, S.J. Hammer, R. Baldock, B. Hill, P. Allan, W.J. Easson, and P.R. Hoskins. Segmentation of arterial geometry from ultrasound images using balloon models. In *IEEE International Symposium on Biomedical Imaging: Nano to Macro*, pages 1319–1322. IEEE, 2004.
- [13] C. M. Chen, H. H. Lu, and A. T. Hsiao. A dual-snake model of high penetrability for ultrasound image boundary extraction. *Ultrasound Med Biol*, 27(12):1651–65, 2001.
- [14] J. Cheng and S.W. Foo. Dynamic directional gradient vector flow for snakes. *IEEE Trans. on Image Processing*, 15(6):1563–1571, 2006.
- [15] T. Cissarek, K. Kröger, F. Santosa, and T. Zeller. *Gefäßmedizin - Therapie und Praxis*. ABW Wissenschaftsverlag GmbH, 2008.
- [16] L. D. Cohen. On active contour models and balloons. *CVGIP: Image Underst.*, 53(2):211–218, 1991.
- [17] L. D. Cohen and I. Cohen. Finite element methods for active contour models and balloons for 2d and 3d images. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 15:1131–1147, 1991.
- [18] T. F. Cootes, G. J. Edwards, and C. J. Taylor. Active appearance models. In *IEEE Trans. on Pattern Analysis and Machine Intelligence*, pages 484–498. Springer, 1998.
- [19] T.F. Cootes and C.J.Taylor. Active shape models - smart snakes. In *British Machine Vision Conference*, pages 266–275. Springer-Verlag, 1992.
- [20] M. de Bruijne, B. van Ginneken, M.A. Viergever, and W.J. Niessen. Interactive segmentation of abdominal aortic aneurysms in CTA images. *Medical Image Analysis*, 8:127–138, 2004.
- [21] H. Delingette and J. Montagnat. Shape and topology constraints on parametric active contours. *Computer Vision and Image Understanding*, 83(2):140–171, 2001.

- [22] S. Demirci, G. Lejeune, and N. Navab. Hybrid deformable model for aneurysm segmentation. In *Proceedings of the Sixth IEEE international Symposium on Biomedical Imaging: From Nano to Macro*, pages 33–36, Piscataway, NJ, USA, 2009. IEEE Press.
- [23] M. Descoteaux, M. Audette, K. Chinzei, and K. Siddiqi. Bone enhancement filtering: application to sinus bone segmentation and simulation of pituitary surgery. In *Proceedings of the 8th International Conference on Medical Image Computing and Computer-Assisted Intervention - Volume Part I, MICCAI'05*, pages 9–16, Berlin, Heidelberg, 2005. Springer-Verlag.
- [24] M. Elin. *Topographie und Dynamik von Perilipin und Adipophilin in Lipidtröpfchen*. PhD thesis, Westfälische Wilhelms-Universität Münster, 2005.
- [25] Y. Gao and W. Chen. Improved compound vector field based active contours model. In *Bioinformatics and Biomedical Engineering, 2009. In Proceedings of the ICBBE 2009. 3rd International Conference on*, pages 1–5. IEEE, 2009.
- [26] I. Ghorbel, F. Rossant, I. Bloch, and M. Paques. Modeling a parallelism constraint in active contours. application to the segmentation of eye vessels and retinal layers. In Benoit Macq and Peter Schelkens, editors, *In Proceedings of the ICIP*, pages 445–448. IEEE, 2011.
- [27] A. Giachetti and G. Zanetti. Aquatics reconstruction software: the design of a diagnostic tool based on computer vision algorithms. *Computer Vision and Mathematical Methods in Medical and Biomedical Image Analysis*, pages 48–63, 2004.
- [28] G. A. Giraldi, L. Goncalves, and A. Oliveira. Dual topologically adaptable snakes. In *Proceedings of the Third International Conference on Computer Vision, Pattern Recognition, and Image Processing*, volume 1, pages 103–106, 2000.
- [29] K. Greiner, J. Egger, S. Großkopf, J. Kaftan, R. Dörner, and B. Freisleben. Segmentierung von Aortenaneurysmen in CTA-Bildern mit dem statistischen Verfahren der Active Appearance Models. *Bildverarbeitung für die Medizin 2008*, pages 51–55, 2008.
- [30] A. Gruen and H. Li. Semi-automatic linear feature extraction by dynamic programming and LSB-snakes. *Photogrammetric Engineering & Remote Sensing*, 63(8):985–995, 1997.

- [31] S. F. Gunn and M. S. Nixon. A robust snake implementation; a dual active contour. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 19:63–68, 1997.
- [32] J. Hahne. *Endovaskuläre interventionell radiologische Therapie des infrarenalen Aortenaneurysmas: Langzeitergebnisse unter Berücksichtigung von Aneurysmavolumen, Endoleakprävalenz und Stentgraft*. PhD thesis, Universitätsklinikum Hamburg-Eppendorf, 2010.
- [33] F. Hasibether. *Automatische Detektion und Verfolgung von Zungenkonturen*. 2002. Hauptseminar im Sommersemester 2002; Volume 1, Band 6 Oktober 2002.
- [34] T. Heimann and H. P. Meinzer. Statistical shape models for 3d medical image segmentation: A review. *Medical Image Analysis*, 13(4):543–563, 2009.
- [35] W. Höwing, D. Wermser, and L.S. Dooley. Fuzzy snakes. *International Conference on Image Processing and its Applications IPA97*, pages 627–630, 1997.
- [36] R. Huch and K.D. Jürgens. *Mensch Körper Krankheit*. Urban & Fischer bei Elsev, 2007.
- [37] Kai Hüner. *Aufbereitung: Aktive Konturen*. *Mathworks*, 2003. <http://www.bild-medizin.de/>.
- [38] D. Kainmüller. *Level-Set-Segmentierung des Herzens aus vierdimensionalen Phasenkontrast-MRT-Daten*. Master’s thesis, Universität Karlsruhe (TH), 2006.
- [39] D.-G. Kang, D.C. Suh, and J.B. Ra. Three-Dimensional Blood Vessel Quantification via Centerline Deformation. *IEEE Trans. on Medical Imaging*, 28(3):405–414, 2009.
- [40] M. Kass, A. Witkin, and D. Terzopoulos. Snakes: Active contour models. *International Journal of Computer Vision*, 1(4):321–331, 1988.
- [41] M. Kerschner. Homologous twin snakes integrated in a bundle block adjustment. In *International Archives of Photogrammetry and Remote Sensing, Vol. XXXII, Part 3/1*, pages 244–249, 1998.
- [42] M. Kerschner. *Snakes für Aufgaben der digitalen Photogrammetrie und Topographie*. PhD thesis, Technische Hochschule Wien, 2003.
- [43] E. Kienel and G. Brunnett. *GPU Accelerated Contour Extraction on Large Images Using Snakes*. Fak. für Informatik, TU Chemnitz, 2009.

- [44] H. C. Kim, Y. H. Seol, S. Y. Choi, J. S. Oh, M. G. Kim, and K. Sun. A study of aaa image segmentation technique using geometric active contour model with morphological gradient edge function. *Conf Proc IEEE Eng Med Biol Soc*, 2007:4437–40, 2007.
- [45] C. Kiser, C. Musial, and P. Sen. Accelerating active contour algorithms with the gradient diffusion field. In *Pattern Recognition, 2008. ICPR 2008. 19th International Conference on*, pages 1–4. IEEE, 2008.
- [46] M. Kohnen. *Segmentierung und Analyse anatomischer Strukturen mit wissensbasierten Modellen*. PhD thesis, Technische Hochschule Aachen, 2004.
- [47] T. Kovács, P. Cattin, H. Alkadhi, S. Wildermuth, and G. Székely. Automatic segmentation of the aortic dissection membrane from 3d cta images. *Medical Imaging and Augmented Reality*, pages 317–324, 2006.
- [48] T. Kovács, P. Cattin, H. Alkadhi, S. Wildermuth, and G. Székely. Automatic segmentation of the vessel lumen from 3d cta images of aortic dissection. *Bildverarbeitung für die Medizin 2006*, pages 161–165, 2006.
- [49] D. Kroon. Snake: Active contour. *Mathworks*, 2010. <http://www.mathworks.com/matlabcentral/fileexchange/28149-snake-active-contour>.
- [50] M. Kux. Ein Ansatz für die interaktive semiautomatische Erzeugung von Aktiven Konturen innerhalb triangulierter Oberflächen von 3D-Objekten. Master’s thesis, Technische Universität Chemnitz, 2005.
- [51] K.M. Lam and H Yan. Fast greedy algorithm for active contours. *IEEE Trans. Pattern Electronic Letters*, 30:21–23, January 1994.
- [52] I. Laptev, H. Mayer, T. Lindeberg, W. Eckstein, C. Steger, and A. Baumgartner. Automatic extraction of roads from aerial images based on scale space and snakes. *Mach. Vision Appl.*, 12(1):23–31, July 2000.
- [53] F. Leymarie. *Tracking and Describing Deformable Objects Using Active Contour Models*. PhD thesis, McGill University, 1990.
- [54] B. Li and S.T. Acton. Active contour external force using vector field convolution for image segmentation. *IEEE Trans. on Image Processing*, 16(8):2096–2106, 2007.
- [55] C. Li, J. Liu, and M.D. Fox. Segmentation of edge preserving gradient vector flow: an approach toward automatically initializing and splitting of snakes. In *CVPR 2005. IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, volume 1, pages 162–167. IEEE, 2005.

- [56] C. Li, C. Xu, C. Gui, and M. D. Fox. Level set evolution without re-initialization: A new variational formulation. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2005)*, volume 1, pages 430–436. IEEE, 2005.
- [57] H. Li. *Semi-automatic Road Extraction from Satellite and Aerial Images*. Mitteilungen Institut für Geodäsie und Photogrammetrie an der Eidgenössischen Technischen Hochschule Zürich. Institut für Geodäsie und Photogrammetrie, 1997.
- [58] Y. Liu and S. Peng. A new motion detection algorithm based on snake and mean shift. In *Image and Signal Processing, 2008. CISP'08. Congress on*, volume 4, pages 140–144. IEEE, 2008.
- [59] S. Loncaric, M. Subasic, and E. Sorantin. 3D deformable model for aortic aneurysm segmentation from CT images. In *Engineering in Medicine and Biology Society, 2000. Proceedings of the 22nd Annual International Conference of the IEEE*, volume 1, pages 398–401. IEEE, 2000.
- [60] J. Lu, Jan Egger, S. Großkopf, and B. Freisleben. Segmentierung und Visualisierung von Lumen und Thrombus bei thorakalen Aortenaneurysmen. 2007.
- [61] D. Magee, A. Bulpitt, and E. Berry. Combining 3D deformable models and level set methods for the segmentation of abdominal aortic aneurysms. In T. Cootes and C. Taylor, editors, *Proc. 12th British Machine Vision Conference*, pages 119–126, Manchester, UK, Sept. 2001. The British Machine Vision Association.
- [62] T. McInerney and D. Terzopoulos. A dynamic finite element surface model for segmentation and tracking in multidimensional medical images with application to cardiac 4D image analysis. *Computerized Medical Imaging and Graphics*, 19:69–83, 1995.
- [63] T. McInerney and D. Terzopoulos. Topologically adaptable snakes. In *Computer Vision, 1995. Proceedings., Fifth International Conference on*, pages 840–845. IEEE, 1995.
- [64] T. Mcinerney and D. Terzopoulos. Topology adaptive deformable surfaces for medical image volume segmentation. *IEEE Trans. on Medical Imaging*, 18:840–850, 1999.
- [65] T. McInerney and D. Terzopoulos. T-snakes: Topology adaptive snakes. *Medical Image Analysis*, 4(2):73–91, 2000.

- [66] S. Menet, P. Saint-Marc, and G-Medioni. B-snakes: Implementation and application to stereo. *Image Understanding Workshop*, pages 720–726, 1990.
- [67] M. Misfeld. Aortendissektion Was sind Warnhinweise? Wie sieht die Therapie praehospital und insbesondere intrahospital aus? [http://www.uni-leipzig.de/kard/kard/veran/notfall/download/nft\\_15\\_Prof\\_Dr\\_Misfeld\\_Aortendissektion.pdf](http://www.uni-leipzig.de/kard/kard/veran/notfall/download/nft_15_Prof_Dr_Misfeld_Aortendissektion.pdf).
- [68] D. Molloy. Active meshes for motion tracking. Master’s thesis, Dublin City University, 2000.
- [69] Deutsches Herzzentrum München. Aortendissektion, 2001. [http://www.dhm.mhn.de/ww/de/b2b/sonderbereiche/herzchirurgie/fachwissen/fachwissen\\_fuer\\_aerzte/aortendissektion.htm](http://www.dhm.mhn.de/ww/de/b2b/sonderbereiche/herzchirurgie/fachwissen/fachwissen_fuer_aerzte/aortendissektion.htm).
- [70] A. F. Laine N. Lee, H. Tek. True-false lumen segmentation of aortic dissection using multi-scale wavelet analysis and generative-discriminative model matching. 2008.
- [71] B. B. Nakhjavanlo, T. J. Ellis, P. H. Soan, and J. Dehmeshki. 3D medical image segmentation using level set models and anisotropic diffusion. In *Proceedings of the 2011 Seventh International Conference on Signal Image Technology & Internet-Based Systems, SITIS '11*, pages 403–408, Washington, DC, USA, 2011. IEEE Computer Society.
- [72] W. M. Neuenschwander, P. Fua, L. Iverson, G. Székely, and O. Kübler. Ziplock snakes. *Int. J. Comput. Vision*, 25(3):191–201, December 1997.
- [73] S.D. Olabarriaga, M. Breeuwer, and W.J. Niessen. Minimum cost path algorithm for coronary artery central axis tracking in CT images. pages 687–694.
- [74] S. Osher and J. A. Sethian. Fronts propagating with curvature dependent speed: Algorithms based on hamilton-jacobi formulations. *Journal of Computational Physics*, 79(1):12–49, 1988.
- [75] N. K. Paragios and R. Deriche. *A PDE-Based Level-Set Approach for Detection and Tracking of Moving Objects*. In *Proceedings of the ICCV '98*. IEEE Computer Society, Washington, DC, USA, 1998.
- [76] H. K. Park and M. J. Chung. External force of snake: virtual electric field. *Electronics Letters*, 38(24):1500–1502, 2002.
- [77] H.W. Park, T. Schoepflin, and Y. Kim. Active contour model with gradient directional information: directional snake. *Circuits and Systems for Video Technology, IEEE Trans. on*, 11(2):252–256, 2001.

- [78] N. Ray, S. T. Acton, T. Altes, E. E. De Lange, J. R. Brookeman, and S. T. Acton. Merging parametric active contours within homogeneous image regions for mri-based lung segmentation. *IEEE Trans. on Medical Imaging*, 22:189–199, 2003.
- [79] M. Saadatmand-Tarzjan and H. Ghassemian. Self-affine snake: a new parametric active contour. In *IEEE International Conference on Signal Processing and Communications (ICSPC 2007)*, pages 492–495. IEEE, 2007.
- [80] J. A. Sethian. *Level Set Methods: Evolving Interfaces in Geometry, Fluid Mechanics, Computer Vision, and Material Science*. Cambridge Monographs on Applied and Computational Mathematics. Cambridge University Press, 1996.
- [81] J. A. Sethian. *Level set methods and fast marching methods: evolving interfaces in computational geometry, fluid mechanics, computer vision, and materials science*. Cambridge University Press, 1999.
- [82] S. Schneider. *Typ A Aortendisektion Ergebnisse chirurgischer Therapie*. PhD thesis, Westfälische Wilhelms-Universität Münster, 2011.
- [83] L.H. Staib and J.S. Duncan. Deformable fourier models for surface finding in 3-d images. In *Proceedings SPIE the International Society for Optical Engineering*, pages 90–90, 1992.
- [84] Ströble. *Aktive Konturen - Segmentierung mit kapillaren Kräften*, pages 155–171. Institut für Medizinische Informatik der RWTH Aachen, 2008.
- [85] M. Subašić, S. Lončarić, and E. Sorantin. Model-based quantitative AAA image analysis using a priori knowledge. *Comput. Methods Prog. Biomed.*, 80(2):103–114, November 2005.
- [86] K. W. Sum and Paul Y. S. Cheung. Boundary vector field for parametric active contours. *Pattern Recogn.*, 40(6):1635–1645, June 2007.
- [87] J. Tang and S. T. Acton. A DCT based gradient vector flow snake for object boundary detection. In *Image Analysis and Interpretation, 2004. 6th IEEE Southwest Symposium on*, pages 157–161. IEEE, 2004.
- [88] L. Tcherniavski. Segmentierung der 3D Bilddaten. Master’s thesis, Fachhochschule Hamburg, 2003.
- [89] J. Trinder, U. Maulik, and S. Bandyopadhyay. Semi-automated feature extraction using simulated annealing. *International Archives of Photogrammetry and Remote Sensing*, 33(B3/2; PART 3):905–911, 2000.

- [90] C. Tung. Computer image analysis system for 3D coronary artery from multi-detector row computed tomography. Master's thesis, National Cheng Kung University – Taiwan, 2004.
- [91] S. Wang, C. Tung, M. Wu, and Y. Sun. Dual snake-based vessel wall detektion for MSCT coronary artery analysis. *Journal of Medical and Biological Engineering*, 27(4):165–171, 2007.
- [92] T. Wang, I. Cheng, and A. Basu. Fluid vector flow and applications in brain tumor segmentation. *IEEE Trans. on Biomedical Engineering*, 56(3):781–789, 2009.
- [93] D. J. Williams and M. Shah. A fast algorithm for active contours and curvature estimation. *CVGIP: Image Underst.*, 55(1):14–26, January 1992.
- [94] S. Wörz, H. von Tengg-Kobligk, V. Henninger, F. Rengier, H. Schumacher, D. Bockler, H.U. Kauczor, and K. Rohr. 3D quantification of the aortic arch morphology in 3-D CTA data for endovascular aortic repair. *IEEE Transactions on Biomedical Engineering*, 57(10):2359–2368, 2010.
- [95] M. Xiaoping, W. Boliang, H. Shaohui, and D. Peishan. Parametric shape modeling using deformable superellipses for segmentation of medical image. In *The 2nd International Conference on Bioinformatics and Biomedical Engineering (ICBBE 2008)*, pages 2673–2676. IEEE, 2008.
- [96] C. Xu and J. L. Prince. Generalized gradient vector flow external forces for active contours. *Signal Processing*, 71:131–139, 1998.
- [97] C. Xu and J. L. Prince. Snakes, shapes, and gradient vector flow. *IEEE Trans. on Image Processing*, 7:359–369, 1998.
- [98] D. Yuan and S. Lu. Simulated static electric field (SSEF) snake for deformable models. In *Proceedings. 16th International Conference on Pattern Recognition*, volume 1, pages 83–86. IEEE, 2002.
- [99] F. Zhuge, G.D. Rubin, S. Sun, and S. Napel. An abdominal aortic aneurysm segmentation method: Level set with region and statistical information. *Medical Physics*, 33(5):1440–1453, 2006.
- [100] L. Zusne. *Visual perception of form*. Academic Press, 1970.