



IMS

Institut für Mikroelektronische Systeme  
Leibniz Universität Hannover

# Studienarbeit

Konzeption und Implementierung quantitativer Analysen zur  
Bewertung von Elastographie-Daten

Leibniz Universität Hannover  
Fakultät für Elektrotechnik und Informatik  
Institut für Mikroelektronische Systeme  
Fachgebiet Architekturen und Systeme  
Prof. Dr.-Ing. habil. Holger Blume

cand. el. Stefan Balke  
Matrikelnummer: 2677830  
geb. am 24.04.1988 in Höxter

Betreuer: Dipl.-Ing. (FH) Hans-Peter Brückner  
Dipl.-Ing. Gregor Schewior

Hannover, den 27. Juni 2012



# Inhaltsverzeichnis

<b>Abbildungsverzeichnis</b>	<b>V</b>
<b>Tabellenverzeichnis</b>	<b>VI</b>
<b>1 Einleitung</b>	<b>3</b>
<b>2 Grundlagen</b>	<b>4</b>
2.1 Medizinischer Hintergrund . . . . .	4
2.1.1 Anatomie der weiblichen Brust . . . . .	4
2.1.2 Krankheitsbilder . . . . .	4
2.1.3 BI-RADS . . . . .	7
2.2 Sonographie . . . . .	7
2.2.1 Aufbau . . . . .	7
2.2.2 Wellenausbreitung . . . . .	8
2.2.3 Amplituden-Mode . . . . .	9
2.3 Elastographie . . . . .	10
2.3.1 Theorie . . . . .	10
2.3.2 Entwicklungsstand . . . . .	11
2.4 Bildverarbeitung . . . . .	12
2.4.1 Operationen der Bildverarbeitung . . . . .	12
2.5 Farbtheorie . . . . .	15
2.5.1 Farbwahrnehmung . . . . .	15
2.5.2 Farbmodelle . . . . .	16
2.6 Segmentierung . . . . .	19
2.6.1 K-Means . . . . .	19
2.6.2 Gaussian Mixture Models . . . . .	20
2.6.3 Snakes . . . . .	21
2.6.4 Bewertung einer Segmentierung . . . . .	21
2.7 Support Vector Machine . . . . .	22
<b>3 Konzeption</b>	<b>24</b>
3.1 Datenaufbereitung . . . . .	24
3.2 Segmentierung . . . . .	26
3.3 Featureextraktion . . . . .	29
3.3.1 Konturfeatures . . . . .	29
3.3.2 Speicherung . . . . .	31
3.4 Prädiktion . . . . .	31
3.5 Graphische Benutzeroberfläche . . . . .	31
<b>4 Implementierung</b>	<b>33</b>
4.1 Segmentierung: kmeans . . . . .	34
4.2 Segmentierung: gmm . . . . .	37

4.3	Berechnung: featureCalc . . . . .	39
4.4	Training: trainSVM . . . . .	42
4.5	Prädiktion: testSVM . . . . .	44
4.6	Graphische Benutzeroberfläche . . . . .	45
4.6.1	Model . . . . .	45
4.6.2	View . . . . .	46
4.6.3	Controller . . . . .	46
<b>5</b>	<b>Evaluation</b>	<b>48</b>
5.1	Segmentierungsverfahren . . . . .	48
5.2	Verteilung der Features . . . . .	50
5.3	Prädiktion durch SVM . . . . .	51
5.4	GUI-Workflow . . . . .	51
<b>6</b>	<b>Zusammenfassung</b>	<b>54</b>
<b>7</b>	<b>Ausblick</b>	<b>56</b>
<b>Anhang</b>		<b>57</b>
A.1	Telefonprotokoll . . . . .	57
A.2	E-Mail der DEGUM . . . . .	59
A.3	E-Mail der AGO-Kommission-Mamma . . . . .	60
A.4	Verwendung der Testroutinen . . . . .	61
A.5	Vergleichende Segmentierungs-Messergebnisse . . . . .	64
A.6	SVM Prädiktion . . . . .	68
	<b>Literaturverzeichnis</b>	<b>70</b>

# Abbildungsverzeichnis

1.1	Brustkrebsstatistik für Deutschland . . . . .	3
2.1	Anatomie der weiblichen Brustdüse - [FHN03, Tafel 175] . . . . .	5
2.2	Brust-Sonogramme - [DHJK10] . . . . .	6
2.3	Streuung an rauher Grenzfläche . . . . .	9
2.4	Zeitlicher Verlauf eines Signalpaares . . . . .	11
2.5	CIE Normalbeobachter . . . . .	15
2.6	CIE Normbeleuchtung A . . . . .	16
2.7	CIE 1931 Farbdiagramm, nach einer Grafik in [Hof06] . . . . .	17
2.8	CIE-RGB . . . . .	17
2.9	HSV in Zylinderdarstellung für eine feste Luminanz . . . . .	18
2.10	Beispiel K-Means Clustering mit drei Zentren . . . . .	20
2.11	Stufen der Ground-Truth . . . . .	22
3.1	Grundkonzept . . . . .	24
3.2	Verteilung der Befunde . . . . .	25
3.3	ESAOTE Elaxto Imaging . . . . .	25
3.4	Automatischer Elastogrammzuschnitt . . . . .	26
3.5	Elastogramm, Diagnose: BI-RADS 5 . . . . .	27
3.6	Segmentierungskonzept . . . . .	28
3.7	Mögliche Klassifizierungsfeatures . . . . .	29
4.1	Toolchain . . . . .	33
4.2	Programmablauf kmeans . . . . .	36
4.3	Programmablauf gmm . . . . .	38
4.4	Programmablauf featureCalc . . . . .	39
4.5	Konturmasken . . . . .	41
4.6	Programmablauf trainSVM . . . . .	42
4.7	Programmablauf testSVM . . . . .	44
4.8	Hauptfenster elastoGUI . . . . .	47
5.1	Segmentierung durch K-Means-Clustering . . . . .	49
5.2	K-Means mit Lab-Farbmodell . . . . .	49
5.3	Werteverteilung beispielhafter Features . . . . .	50
5.4	GUI-Workflow . . . . .	53
A.1	Gaussian Mixture Models mit Lab-Farbmodell . . . . .	64
A.2	Gaussian Mixture Models mit HSV-Farbmodell . . . . .	65
A.3	K-Means mit Lab-Farbmodell . . . . .	66
A.4	K-Means mit HSV-Farbmodell . . . . .	67

## Tabellenverzeichnis

2.1	BI-RADS Klassen . . . . .	7
2.2	Schallfeldgrößen für verschiedene biologische Materialien [Dös00, S. 187] . . . . .	8
3.1	Featurevektor . . . . .	31
5.1	Messergebnisse der Segmentierungsverfahren . . . . .	48
5.2	Auswertung der korrekt prädizierenden 31 unterschiedlichen SVMs . . . . .	51
A.1	Ebene 0 . . . . .	68
A.2	Ebene 1 . . . . .	68
A.3	Ebene 2 . . . . .	69

# Aufgabenstellung

## Studienarbeit

für Herrn cand. el. Stefan Balke

## Konzeption und Implementierung quantitativer Analysen zur Bewertung von Elastographie-Daten

Am Fachgebiet „Architekturen und Systeme“ werden im Rahmen mehrerer Forschungsvorhaben im Bereich Medizintechnik dedizierte und programmierbare Architekturen für die Auswertung von Ultraschall- und Elastographie-Daten untersucht. Eine neuartige Anwendung soll die durch Elastographie erfassten Daten quantitativ auswerten und dem Benutzer Maßzahlen für weitere Analysen darstellen.

Am Institut werden zurzeit Verfahren zur quantitativen Bewertung von Elastographie-Daten untersucht. Das Ziel ist die eindeutige Klassifizierung von Elastographie-Aufnahmen in der Mammadiagnostik. Durch die quantitative Bewertung soll dem untersuchenden Arzt ein zusätzliches objektives Entscheidungskriterium zur Verfügung gestellt werden.

Herr Balke erhält die Aufgabe, Algorithmen zur quantitativen Bewertung von Elastographie-Daten zu evaluieren und anschließend zu implementieren. Die Arbeit soll mit einer detaillierten Analyse bestehender Algorithmen zur Analyse von Elastographie-Bildern beginnen. Anschließend sind diese in Matlab zu implementieren und zu verifizieren. Nach erfolgreicher Verifikation erfolgt die Umsetzung in C++, wobei hier ein besonderer Fokus auf Hardwarenähe und benötigten System-Ressourcen liegt. Die C++ Realisierung soll später eine echtzeitfähige Berechnung der Parameter erlauben.

Das Referenzmodul zur Auswertung der Elastographie-Daten ist in Matlab zu erstellen, die spätere Softwarerealisierung soll in der Programmiersprache C++ implementiert werden. Die Qualität der implementierten Analysen ist durch eine statistische Auswertung nachzuweisen. Die echtzeitfähige Funktionalität der Implementierung soll abschließend durch ein Profiling belegt werden.

Auf eine gute Dokumentation des C++ Codes ist zu achten. Die eingereichten Exemplare sowie die Ergebnisse der Arbeit bleiben Eigentum des Instituts.

Betreuer:       Dipl.-Ing. (FH) Hans-Peter Brückner  
                  Dipl.-Ing. Gregor Schewior  
                  Institut für Mikroelektronische Systeme, Universität Hannover  
Erstprüfer:     Prof. Dr.-Ing. Holger Blume  
                  Institut für Mikroelektronische Systeme, Universität Hannover  
Zweitprüfer:   Prof. Dr.-Ing. Bodo Rosenhahn  
                  Institut für Informationsverarbeitung, Universität Hannover

Tag der Ausgabe: 13.12.2011

Tag der Abgabe: 10.07.2012

## Erklärung

Ich versichere hiermit, dass ich die vorstehende Arbeit selbständig angefertigt, keine anderen als die angegebenen Hilfsmittel benutzt und sowohl wörtliche, als auch sinngemäß entlehnte Stellen als solche kenntlich gemacht habe. Die Arbeit hat in gleicher oder ähnlicher Form noch keiner anderen Prüfungsbehörde vorgelegen.

---

Stefan Balke

Hannover, den 27. Juni 2012

# 1 Einleitung

Brustkrebs ist bei west-europäischen Frauen die am häufigsten auftretende Krebsform [Int]. In Deutschland sind 2009 knapp 72000 Frauen an dieser Krebsform erkrankt. Die Entwicklung der Neuerkrankungen in Deutschland seit dem Jahr 2003 ist in Abbildung 1.1(a) dargestellt. Die Faktoren für die steigende Tendenz sind bekannt: Durchschnittlich späteres Gebären von Kindern, verringerte Stillzeiten, früheres Einsetzen der Pubertät, Bewegungsmangel und steigendes Übergewicht [Kre12].

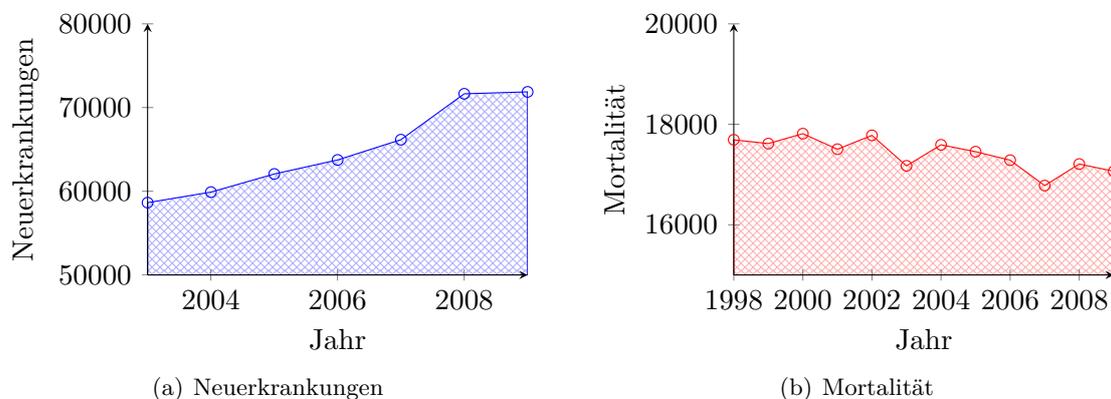


Abbildung 1.1: Brustkrebsstatistik für Deutschland [Ges]

Die frühzeitige Diagnose der Veränderung der Brust spielt für den Verlauf und die Heilungschancen eine wichtige Rolle. Zu diesem Zweck wird seit 2008 ein kostenloses, jährliches Mammographie-Screening für Frauen zwischen 50 und 69 Jahren angeboten.

Bei den jährlichen Vorsorgeuntersuchungen für jüngere Frauen wird, aufgrund der Strahlenbelastung durch die Mammographie und der unterschiedlichen anatomischen Gegebenheiten der Brust vor der Menopause, die Untersuchung durch Ultraschall bevorzugt.

Diese Studienarbeit befasst sich mit einem Verfahren, das mittels Ultraschall Rückschlüsse auf die Elastizität des Brustgewebes gibt. Diese sogenannte Elastographie soll dazu eingesetzt werden, im Ultraschallbild schlecht diagnostizierbare Veränderungen des Brustgewebes aufzudecken. Im Zusammenspiel mit der herkömmlichen Ultraschalldiagnostik kann somit auch jüngeren Frauen eine erweiterte Vorsorgeuntersuchung angeboten werden.

Das Ziel dieser Arbeit ist es, mithilfe von Konzepten und Algorithmen aus dem Bereich der Computer Vision, diese Elastogramme automatisiert zu analysieren und zu klassifizieren. Dazu wird ein Framework bestehend aus mehreren Programmen erstellt, welches diese geforderte Aufgabe umsetzt und dessen korrekte Funktionalität anhand eines anzulegenden Referenzdatensatzes verifiziert.

Der Inhalt dieser Arbeit gliedert sich in ein Grundlagenkapitel, in dem technische und medizinische Hintergründe erläutert werden, ein Konzeptionskapitel, dem darauf aufbauenden Implementierungskapitel und der abschließenden Evaluation des umgesetzten Frameworks.

## 2 Grundlagen

Dieses Kapitel beschäftigt sich mit den Grundlagen: Angefangen mit der anatomischen Beschreibung der weiblichen Brust mit dem Fokus auf den sogenannten gut- und bösartigen Tumoren und der Ultraschalldiagnostik derselben, über die Theorie des hier verwendeten bildgebenden Verfahrens der Elastographie, bis hin zur Beschreibung von Segmentierungsverfahren.

### 2.1 Medizinischer Hintergrund

#### 2.1.1 Anatomie der weiblichen Brust

Etwa auf Höhe der 2. bis 7. Rippe (Costa II und Costa VII, s. Abbildung 2.1(b)), zwischen Sternum und Achselhöhle, liegt die Brust der erwachsenen Frau. Sie liegt auf dem großen Brustmuskel (*M. pectoralis major*) und besteht aus der Brustdrüse (*Glandula mammaria*), Fettgewebe, Bindegewebe, Warzenhof, Brustwarze und der umliegenden Haut [Psc04, S. 1108]. Zwischen der Brust und dem Brustmuskel befindet sich ein Spalt, der retromammäre Raum, der eine leichte Verschiebbarkeit der Brust ermöglicht [HA07, S. 444].

Mittig der Areola mammae (Warzenhof) befindet sich die Mamilla (Brustwarze). Durch das feine Nervengeflecht ist die Mamilla sehr empfindlich und stellt sich bei Berührung durch Kontraktion des innen liegenden Muskelfasernetzes auf.

Die Hauptbestandteile der Brust sind Drüsengewebe, Fettgewebe und Bindegewebe. Es gibt 15-20 Drüsensegmente, bestehend aus Alveolen (Milchbläschen) und zugehörigen Milchkanälen, die in die Mamilla münden. Räumlich werden die Segmente durch die sog. Cooper-Ligamente (*Ligamenta suspensoria mammaria*) getrennt.

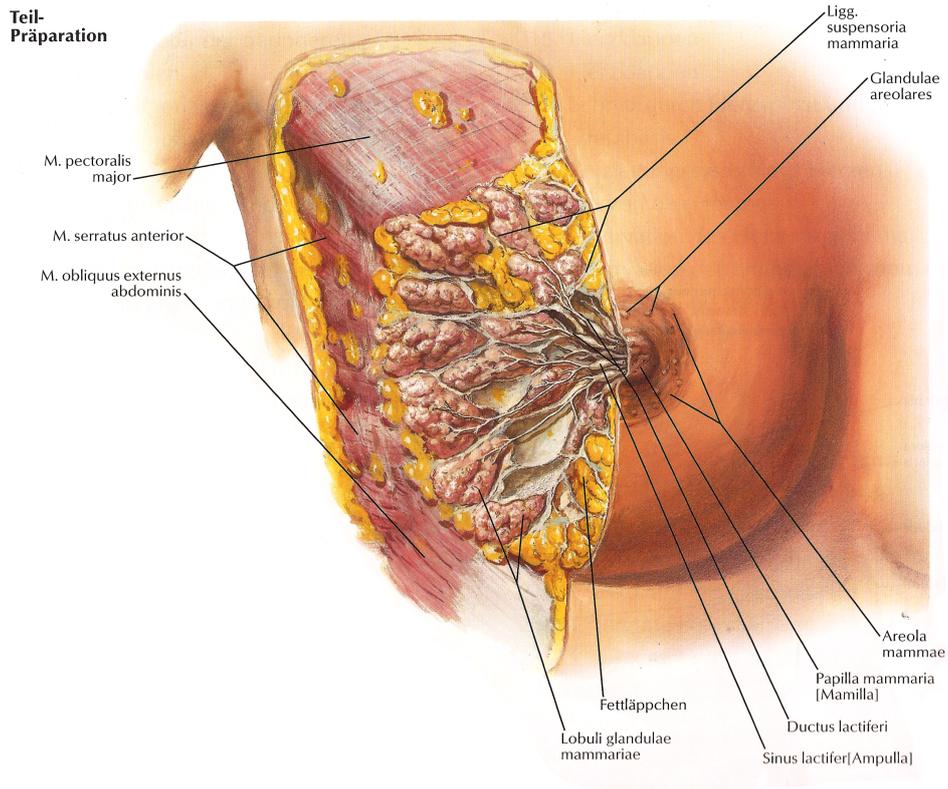
#### 2.1.2 Krankheitsbilder

##### Prämenstruelles Syndrom

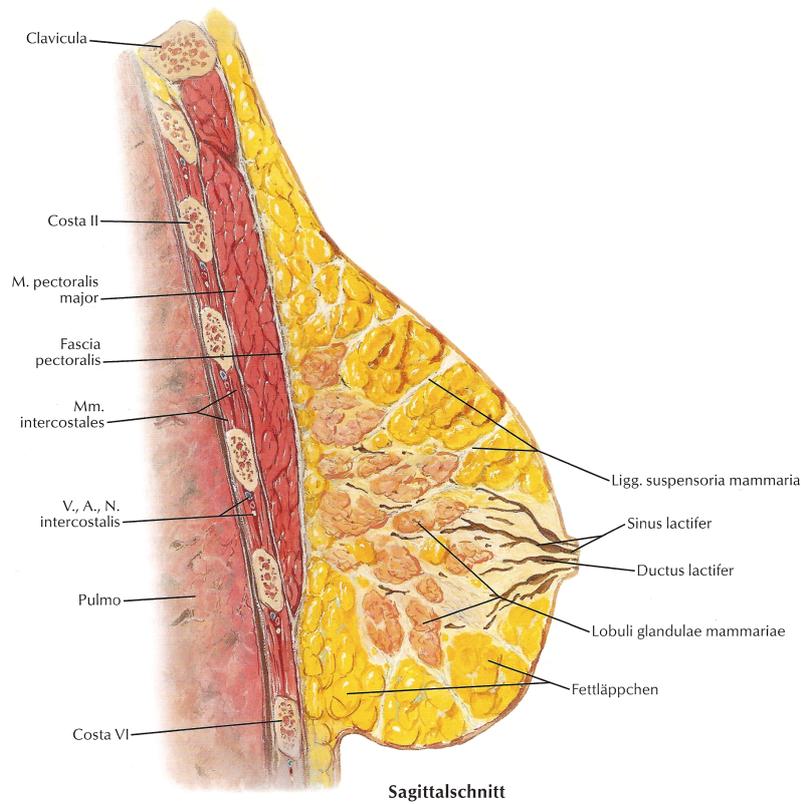
Das Prämenstruelle Syndrom (PMS) ist ein Sammelbegriff für unterschiedliche Symptome vor der Menstruation [SMW04, S. 60]. Neben Darmbeschwerden, Kopfschmerzen u.a. gehört die Mastodynie (Schmerzhaftigkeit der Brust) dazu [SMW04, S. 377]. Die Ursachen für die Schmerzen können verschieden sein, beim PMS entstehen diese durch Spannung bedingt durch Wassereinlagerungen in der Brust.

##### Gutartige Tumore

Gutartige Tumore zeichnen sich durch scharfe Abgrenzbarkeit zum umliegenden Gewebe und eine homogene Struktur aus. Sie entstehen aus dem Drüsen- oder Bindegewebe oder einer Kombination aus beiden (z.B. Fibroadenom, s. Abbildung 2.2(b)). Ihre Bedeutsamkeit



(a) Teilpräparation frontal



(b) Sagittalschnitt

Abbildung 2.1: Anatomie der weiblichen Brustdüse - [FHN03, Tafel 175]

besteht darin, „dass sie stets die diagnostische Abgrenzung vom Karzinom erforderlich machen“ [SMW04, S. 376]. Eine Zyste (Kammer mit Flüssigkeit) würde sich als echolose, abgegrenzte Struktur im Sonogramm zeigen (s. Abbildung 2.2(a)), zudem erkennt man eine Echoverstärkung unter dem Befund.

### Mastopathie (Mastopathia fibrocystica)

Die Mastopathie beschreibt eine Gewebeveränderung in der Brust, die je nach Ausprägung als große oder kleine knotige Verhärtung wahrgenommen wird [Psc04, S. 1122]. Im Gegensatz zu den gutartigen Tumoren ist die Symptomatik nicht auf isolierte Verwachsungen eingeschränkt, sondern kann das komplette Gewebe betreffen [SMW04, S. 376]. Auf dem Sonogramm ähnelt dies dem Bereich um das Fibroadenom von Abbildung 2.2(b) herum.

### Bösartige Tumore

Bei den bösartigen Brusttumoren, insbesondere den Mammakarzinomen, unterscheidet man nach dem Ursprungsort:

**duktal** den Milchgang betreffend

**lobulär** Milchdrüsenläppchen betreffend

und ob das Karzinom *in situ* oder *invasiv* ist:

**in situ** „an seinem natürlichen Ort; auch gleichbedeutend mit nichtinvasiv, im Zusammenhang mit Krebs ein Tumor, der noch nicht in umliegendes Gewebe eingewandert ist“ [DHJK, Buchstabe I]

**invasiv** „Wachstum von Tumorgewebe ohne scharfe Grenze in das umgebende Gewebe.“ [DHJK, Buchstabe I]

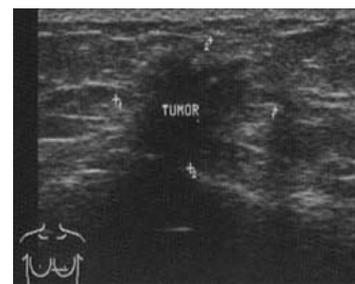
Abbildung 2.2(c) zeigt das Sonogramm eines invasiven Mammakarzinoms. Zu beobachten ist der Schallschatten unter dem Herdbefund.



(a) Sonogramm einer Zyste



(b) Sonogramm eines Fibroadenoms



(c) Sonogramm eines Karzinoms

Abbildung 2.2: Brust-Sonogramme - [DHJK10]

### 2.1.3 BI-RADS

BI-RADS<sup>1</sup> ist eine Klassifikation von Bildgebungsbefunden der Brust. Zuerst galt diese Einstufung nur für Mammographiebefunde, wurde aber im Laufe der Zeit für die Ultraschalldiagnostik vom American College of Radiology erweitert [BIR03]. Sie hält zudem auch Empfehlungen für weitere Untersuchungsmethoden vor.

Die verschiedenen Klassen sind in Tabelle 2.1 erläutert.

Tabelle 2.1: BI-RADS Klassen

Klasse	Bedeutung
0	weitere Bildgebung nötig
1	unauffällig
2	sicher benigner <sup>2</sup> Befund
3	wahrscheinlich benigner Befund
4	suspekte Veränderung, Malignität <sup>3</sup> ist möglich
5	hochgradig malignitätsverdächtiger Befund
6	maligner, durch Biopsie bestätigter Befund

## 2.2 Sonographie

Die Sonographie (ugs. Ultraschall) visualisiert die Ausbreitung von Schallwellen im Körper. Dieses Verfahren bedient sich demnach keiner ionisierenden Strahlung und ist somit nicht gewebeschädigend. Es ist daher prädestiniert für die Anwendung bei regelmäßigen Vorsorgeuntersuchungen. Im Folgenden sollen die grundlegenden physikalischen Zusammenhänge der Sonographie erklärt werden, die ebenso für das Verständnis der Elastographie notwendig sind.

### 2.2.1 Aufbau

Ein Ultraschallgerät besteht aus einem Schallkopf und einer Basiseinheit mit angeschlossener Betrachtungseinheit. Die Basiseinheit übernimmt die analog-digital-Wandlung, die räumliche Zuordnung der empfangenden Scanlinien, sowie ein mögliches Postprocessing der Bilddaten. Visualisiert werden die Daten typischerweise auf einem angeschlossenen Monitor.

Der Schallwandler arbeitet je nach Untersuchung im Hochfrequenzbereich zwischen 1 MHz und 12 MHz [Kra11, S. 361]. Er ist für das Senden der Messimpulse, sowie den Empfang der Echos zuständig (Verhältnis Sende- und Empfangszeit ca. 1:1000). Die grundlegenden ausgenutzten Mechanismen der Wellen sind nachstehend erläutert.

<sup>1</sup>Breast Imaging Reporting and Data System

<sup>2</sup>Synonym für gutartig, von lat.: *benignus* - gutartig, freundlich

<sup>3</sup>Synonym für bösartig, von lat.: *malignitas* - Bösartigkeit

Tabelle 2.2: Schallfeldgrößen für verschiedene biologische Materialien [Dös00, S. 187]

Substanz	$c$ [m/s]	$Z$ [kg cm <sup>-2</sup> s <sup>-1</sup> ]	$\rho$ [g/cm <sup>3</sup> ]
Luft	331	43	0,013
Fett	1470	1,42 10 <sup>5</sup>	0,97
Wasser	1492	1,48 10 <sup>5</sup>	0,9982
Hirn	1530	1,56 10 <sup>5</sup>	1,02
Muskel	1568	1,63 10 <sup>5</sup>	1,04
Knochen	3600	6,12 10 <sup>5</sup>	1,7

### 2.2.2 Wellenausbreitung

In Flüssigkeiten und Gasen beschreibt man die Wellenausbreitung als sich zeitlich verändernde Drücke  $p$  auf Volumenelemente. Verallgemeinert man dies auf drei Dimensionen und sieht die zeitliche Veränderung des lokalen Druckes als Welle an, so gelangt man zur üblichen Darstellung einer Wellenausbreitung als partielle Differentialgleichung [Mös07, S. 43]:

$$\Delta p - \underbrace{\frac{\rho}{K}}_{\frac{1}{c^2}} \frac{\partial^2 p}{\partial t^2} = 0 \quad (2.1)$$

Die Schallgeschwindigkeit  $c$  lässt sich daraus als

$$c = \sqrt{\frac{K}{\rho}} \quad (2.2)$$

ableiten. In Tabelle 2.2 finden sich Ausbreitungsgeschwindigkeiten für verschiedene Materialien. Aufgrund der fehlenden Scherspannungen in Gasen und Flüssigkeiten ist dort nur eine longitudinale (Teilchenauslenkung parallel zur Ausbreitungsrichtung) Wellenausbreitung statt. Aufgrund der nun definierten Wellenausbreitung ist es möglich weitere übliche Faktoren wie Reflexion, Absorption und Streuung von Wellen zu betrachten.

### Wellenwiderstand

Der Wellenwiderstand oder auch in der Akustik Schallkennimpedanz genannt, berechnet sich im Fernfeld (Annahme: Schalldruck  $p$  und Schallschnelle  $v$  sind dort in Phase) zu:

$$Z = \frac{p}{v} = \rho \cdot c \quad (2.3)$$

Dieser wird zur Berechnung des Reflexionsfaktors  $r$  benötigt.

### Reflexion

An der glatten Grenzfläche zweier unterschiedlich schallharten Materialien – demnach unterschiedlichen Wellenwiderständen – wird ein Teil der Welle transmittiert und der Rest reflektiert (Annahme: Keine Absorption). Der Quotient aus reflektierter und einfallender

Welle wird Reflexionsfaktor genannt.

$$r = \frac{\text{Schalldruck reflektierte Welle}}{\text{Schalldruck einfallende Welle}} = \frac{Z_2 - Z_1}{Z_2 + Z_1} \quad (2.4)$$

Bei  $r = 1$  liegt eine Totalreflexion vor; bei  $r = 0$  wäre für die Welle keine Grenzfläche vorhanden. Für die Richtung der reflektierten Welle gilt die einfache Beziehung *Einfallswinkel* = *Ausfallswinkel* bezogen auf das Lot der Grenzfläche.

### Streuung

Glatte Grenzflächen kommen im Körper weitestgehend nicht vor. Hier handelt es sich mehrheitlich um rauhe Grenzflächen. Eine Besonderheit von rauhen Grenzflächen ist es, dass diese nicht nur in eine Richtung reflektieren, sondern die einfallende Welle in mehrere Richtungen streuen (s. Abbildung 2.3). Für die Echomessung bedeutet dies, dass der Schallkopf nicht genau rechtwinklig über der Grenzfläche stehen muss.

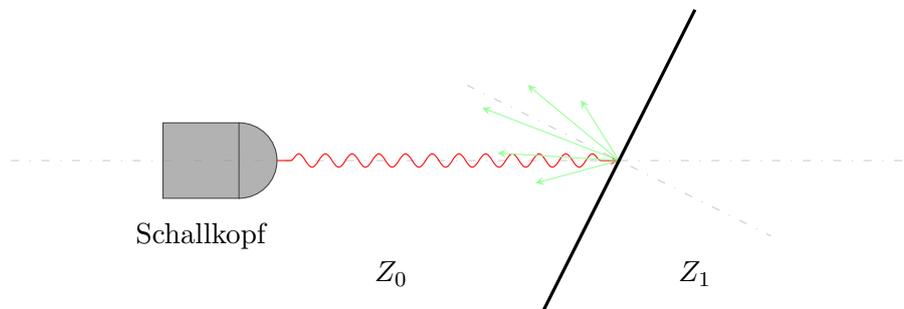


Abbildung 2.3: Streuung an rauher Grenzfläche, Grafik nach [Dös00, S. 199]

### Absorption

Durch Schallabsorption nimmt die Schallintensität  $J$  mit zunehmender Eindringtiefe ab:

$$J(x, \nu) = J_0 e^{-x \mu_n(\nu)} \quad (2.5)$$

Der Absorptionskoeffizient  $\mu_n(\nu)$  ist abhängig von der Art der Materialies, sowie der eingesetzten Frequenz  $\nu$ .

#### 2.2.3 Amplituden-Mode

Der Amplituden-Mode (A-Mode) ist die einfachste Form des Ultraschalls. Wie eingangs erwähnt, sendet der Schallkopf hochfrequente Messimpulse aus. Diese dringen als Schallwellen in den Körper ein. An den einzelnen Grenzflächen zwischen den Organen wird die Welle in Teilen reflektiert und nach einem Zeitversatz  $\Delta t$  am Schallkopf detektiert. Mithilfe einer gemittelten Schallgeschwindigkeit in Gewebe von  $c_m = 1530$  m/s [Kra11, S. 359] lässt sich die Echotiefe somit errechnen zu:

$$z = c_m \frac{\Delta t}{2} \quad (2.6)$$

Ordnet man nun die A-Linien zu einem 2-dimensionalen Raster an und weist den einzelnen Echoamplitude einen Grauwert zu, so kommt man zur allgemein bekannten Darstellungsform – dem sog. Brightness-Mode (B-Mode) – wie sie auch in Abbildung 2.2(a) verwendet wurde.

## 2.3 Elastographie

Die Elastographie geht auf eine Erfindung von Ophir et. al. [OCP91a, OCP<sup>+</sup>91b] zurück. Mit diesem bildgebenden Verfahren ist es möglich den Härtegrad eines Gewebes zu visualisieren. In den weiteren Forschungen [COPM93] wurde die Anwendung primär auf die Ergänzung von sonographischen Untersuchungen gelenkt, mit dem Ziel, schwer zu ertastende oder auf dem Sonogramm schwer zu diagnostizierende Befunde sichtbar zu machen. Der folgende Abschnitt soll das Prinzip des Verfahrens verdeutlichen.

### 2.3.1 Theorie

Die Entstehung eines Elastogrammes lässt sich in der Theorie wie folgt erklären: Der Ultraschallkopf zeichnet jeweils einen Echoverlauf des komprimierten und des nicht komprimierten Gewebes auf. Diese Kompression wird erreicht, indem der Kopf axial um  $z$  verschoben wird. Die Echos werden jeweils bis zu einer Tiefe von ca. 12 cm aufgenommen. Die Aufzeichnung der Signale über der Zeit ist in Abbildung 2.4 gezeigt. Sie entsprechen zwei A-Mode-Linien eines Ultraschallgerätes. Da das komprimierte A-Mode-Linien Signal um die Kompression  $\frac{2dz}{c}$  kürzer ist, wird der Rest mit Nullen aufgefüllt.

Diese empfangenen Signale werden in  $N = 40 - 60$  überlappende Segmente von 4 mm Länge eingeteilt und jeweils paarweise verglichen (ein Paar besteht aus einem komprimierten und einem unkomprimierten Segment). Der Zeitversatz zwischen den Einzelsegmenten wird via Kreuzkorrelation berechnet (s. Abbildung 2.4) und ergibt je Segmentpaar ein  $t_i$ . Die nun entstandenen Zeitdifferenzen  $t_i$  werden nach [OCP<sup>+</sup>91b] in ein Dehnungsprofil umgerechnet:

$$s_i = \frac{t_{i+t} - t_i}{\frac{2z}{c}}, \quad 1 < i \leq N - 1 \quad (2.7)$$

Somit wird die Zeitdifferenz der Segmente - normiert auf die maximale Echozeit - als Verschiebungsindikator benutzt. War die zeitliche Verschiebung der Segmente aus der Kreuzkorrelation gleich, wurde auch nichts gedehnt oder gestaucht - der Bereich ist also hart. Waren sie unterschiedlich, ist der Bereich kompressibel und somit weich. Ungenauigkeiten entstehen durch die Annahme eines homogenen Gewebes entlang des Wellenweges.

Angewendet auf alle A-Mode-Linien ergibt sich somit ein 2-dimensionales Elastogramm, welches nun graphisch als Graustufen- oder Falschfarbenbild dargestellt werden kann.

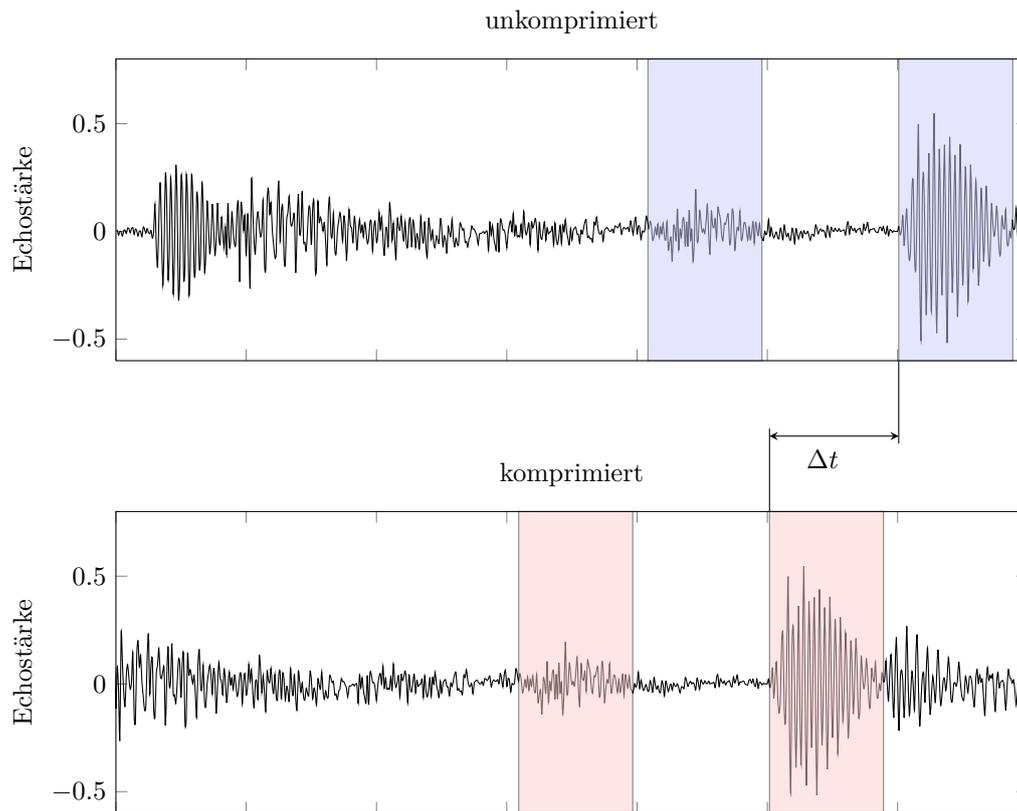


Abbildung 2.4: Zeitlicher Verlauf eines Signalpaares

### 2.3.2 Entwicklungsstand

#### Vibrographie

Ein Schwachpunkt ist, dass die Qualität der Messung stark vom behandelnden Arzt abhängt. Die manuelle Kompression birgt viele Fehlerfaktoren, weswegen versucht wird, diese zu automatisieren. Ein Ansatz besteht darin, den Schallkopf mittels eines Motors auszulenken, um eine niederfrequente Kompression des Gewebes zu erreichen [SSL<sup>+</sup>91].

Ein ähnlicher Ansatz wird mit der AFUSON (assisted-freehand ultrasound) [KN09] verfolgt. Es wurde beobachtet, dass bei ungeübten Untersuchenden die Fehlerrate deutlich anstieg. Zudem eröffnet die im Gegensatz zur manuellen geringe Kompression von 1-2 mm andere Anwendungsgebiete wie die Prostata- oder Gehirntumordiagnostik.

Ein Nachteil ist die Verwendung eines speziellen Schallkopfes und die damit verbundenen Zusatzkosten, was eine breite Verwendung in Vorsorgeuntersuchungen beeinträchtigen könnte.

#### Axial Shear Strain Elastography

Die aktuelle Entwicklung der Elastographie-Gründer Garra und Ophir beschäftigt sich seit einigen Jahren mit der Axial Shear Strain Elastography (kurz: ASSE) [VW02]. Die Auswertung der Scherkräfte, die auf die Läsionen wirken, gibt eine sensiblere Aussage über die Lagerung des Gewebes. Somit soll die Verwachsung zum umliegenden Gewebe einfacher

zu deuten sein [Gar11]. Gestützt durch klinische Studie ([TYM<sup>+</sup>11, TMKC<sup>+</sup>08]) spricht man der ASSE eine hohe Bedeutung in der Zukunft der Elastographie zu.

### Verwendung und Standardisierung

Die Verbreitung der Elastographie verläuft sehr schleppend. Mittlerweile wird die Funktionalität von den führenden Herstellern in ihren Geräten zwar implementiert, findet aber wenig Anklang in der ausführenden Ärzteschaft.

Kern des Problems könnte das Fehlen von aussagekräftigen Ergebnissen sein. Zwar wurde in diversen Studien ([KS10, HKS<sup>+</sup>01, GCO<sup>+</sup>97]) eine Anwendbarkeit der Elastographie gerade im Bereich der Prävention von Falschdiagnosen attestiert, eine Standardisierung durch die DEGUM<sup>4</sup> (s. Anhang A.2) oder eine Richtlinie der AGO<sup>5</sup> (s. Anhang A.3) hat allerdings noch nicht stattgefunden.

### Weitere Verfahren

Zusätzlich zu der hier beschriebenen Elastographie wird an weiteren alternativen Verfahren zur klassischen Mammographie geforscht. Ein nennenswertes ist dabei ein radar-basierter Ansatz [FMS03]. Hierzu werden die durch thermische Änderung variierenden elektrischen Eigenschaften (Leitfähigkeit, Permittivität) des Brustgewebes untersucht. Durch Absorption der Strahlung erwärmt sich das jeweilige Gewebe und ändert damit die o.g. elektrischen Eigenschaften. Klemm et. al. [KCL<sup>+</sup>09] wählten einen hemisphärischen Aufbau eines Antennen-Arrays, um daraus eine 3D-Rekonstruktion der Brust zu erreichen, die weitere Möglichkeiten zur Lokalisierung und Bewertung von Brustläsionen ermöglicht [KCL<sup>+</sup>08]. Ähnlich zur Elastographie schlagen sie das Verfahren als additive Diagnose zur Mammographie vor bzw. als weitere Untersuchungsmöglichkeit für Frauen vor der Menopause. Eine gute Übersicht über die verschiedenen auf dem Markt verfügbaren Technologien und deren Anwendbarkeit liefert [Moo01].

## 2.4 Bildverarbeitung

Die digitale Bildverarbeitung beschäftigt sich, neben der Erfassung, Segmentierung und semantischen Analyse, mit der Filterung und Vorverarbeitung von Bilddaten. Digitale Bilddaten lassen sich in Form einer 2-dimensionalen Matrix darstellen, je nach Kanalanzahl mit mehrschichtigen Matrizen. Zur Manipulation dieser Daten wird im Wesentlichen zwischen drei Operatoren unterschieden: Punktoperator, lokaler und globaler Operator.

### 2.4.1 Operationen der Bildverarbeitung

#### Punktoperator

Ein Punktoperator nimmt einen Punkt  $p_0^*$  (Pixel oder Voxel) des Bildes  $B$  (Höhe  $a$ , Breite  $b$ ),  $B \in [a \times b]$ , und bildet ihn über eine lineare oder nichtlineare Transformation  $T_n(x, y)$

---

<sup>4</sup>Deutsche Gesellschaft für Ultraschall in der Medizin

<sup>5</sup>Arbeitsgemeinschaft für gynäkologische Onkologie e.V.

auf  $p_0^*$  ab. Als Beispiel ist hier ein Schwellwertverfahren angegeben:

$$p_0 = B(x_0, y_0) \quad (2.8)$$

$$p_0^* = T_{\text{Schwellwert}}(p_0) \quad (2.9)$$

$$T_{\text{Schwellwert}}(p) = \begin{cases} 0, & \text{wenn } p < 100, \\ 255, & \text{sonst.} \end{cases} \quad (2.10)$$

### Lokaler Operator

Lokale Operatoren betreffen nicht nur den Zielpunkt, sondern beziehen auch umliegende Gebiete mit ein. Darstellbar ist dies über lineare, verschiebungsinvariante Filter, die mittels 2-dimensionaler Faltung (2.11) auf den Zielpunkt angewendet werden [Jäh05, S. 115]:

$$g(x, y) = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} s(i, j) f(x - i, y - j) \quad (2.11)$$

Im Folgenden sind wichtige Filterkerne aufgelistet:

$$\textbf{Glättung: } M_4 = \frac{1}{4} \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix}, M_9 = \frac{1}{9} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix}, \text{ allg.: } g_{mn} = \frac{1}{mn} \quad (2.12)$$

$$\textbf{Sobel: } G_x = \nabla B(x_0, y_0) = \frac{1}{8} \begin{pmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{pmatrix}, G_y = G_x^T, G = \sqrt{G_x^2 + G_y^2} \quad (2.13)$$

$$\textbf{Laplace: } L = \Delta B(x_0, y_0) = \begin{pmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{pmatrix} \quad (2.14)$$

### Globaler Operator

Globale Operationen beziehen sich auf das gesamte Bild. Sie gehen meist einher mit einem Basiswechsel, so auch die Fourier Transformation, die vom Orts- in den Frequenzraum transformiert. Für die Bildverarbeitung und Codierung ist die diskrete Fourier Transformation (DFT) von hoher Bedeutung [Mus02, S. 128]:

$\vec{x}$ : Eingangswerte,  $T$ :  $(N \times N)$ -Transformationsmatrix,  $\vec{c}_{mn}$ : Transformationskoeffizienten

$$\vec{c} = T\vec{x} \quad (2.15)$$

$$t_{mn} = \frac{1}{\sqrt{N}} e^{-j \frac{2\pi}{N} (n-1)(m-1)} \quad n, m = 1 \dots N \quad (2.16)$$

$$c_{mn} = \sum_{i=1}^N \sum_{j=1}^N x_{ij} t_{nj} t_{mi} \quad (2.17)$$

$$\vec{x} = T^{-1}\vec{c} \quad (2.18)$$

Beschränkt man sich hier auf reelle Basen, gelangt man zur diskreten Cosinus Transformation.

## Momente

Momente werden in der Statistik zur Charakterisierung von Wahrscheinlichkeitsdichten benutzt. Im hier vorliegenden zweidimensionalen Fall sind die Verbund- bzw. Verbundzentralmomente für ein Bild  $f(x_i, y_j)$  wie folgt definiert [Mus05]:

$$E[x^n \cdot y^m] = \sum_{i=-\infty}^{+\infty} \sum_{j=-\infty}^{+\infty} x_i^n y_j^m f(x_i, y_j) \quad (2.19)$$

$$E[(x - m_x)^n \cdot (y - m_y)^m] = \mu_{nm} = \sum_{i=-\infty}^{+\infty} \sum_{j=-\infty}^{+\infty} (x - m_x)^n (y - m_y)^m f(x_i, y_j). \quad (2.20)$$

Eine Besonderheit von Zentralmomenten ist die Verschiebungsinvarianz.

Die Berechnung des Schwerpunkts eines Bildes oder Ausschnittes kann ebenfalls über die Momente ermittelt werden:

$$\{\bar{x}, \bar{y}\} = \left\{ \frac{\mu_{10}}{\mu_{00}}, \frac{\mu_{01}}{\mu_{00}} \right\}. \quad (2.21)$$

Zur unabhängigen Beschreibung von Bildelementen gilt es allerdings folgende Forderungen zu erfüllen:

- Verschiebungsinvarianz
- Skalierungsinvarianz
- Rotationsinvarianz.

Die Skalierungsinvarianz kann durch eine Normierung der Verbundzentralmomente erfolgen:

$$\eta_{ij} = \frac{\mu_{ij}}{\mu_{00}^{1 + \frac{i+j}{2}}}. \quad (2.22)$$

Um eine Rotationsinvarianz zu erhalten werden oftmals die Hu-Momente verwendet [Hu62], die einen Satz orthogonaler Momente darstellen:

$$I_1 = \eta_{20} + \eta_{02} \quad (2.23)$$

$$I_2 = (\eta_{20} - \eta_{02})^2 + (2\eta_{11})^2 \quad (2.24)$$

$$I_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \quad (2.25)$$

$$I_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \quad (2.26)$$

$$I_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + \quad (2.27)$$

$$(3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \quad (2.28)$$

$$I_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \quad (2.29)$$

$$I_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] - \quad (2.30)$$

$$(\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]. \quad (2.31)$$

Aus Momenten lassen sich sehr vielen Informationen über das Bild ableiten. Neben der Größe von Flächen oder den Schwerpunkten lässt sich beispielsweise die Ausrichtung eines

Bildes ableiten. Für weitere Einsatzbereiche von Momenten sei auf [FSZE09] verwiesen.

## 2.5 Farbtheorie

Wir Menschen nehmen Farben wahr und benutzen Sie zur Trennung und Klassifikation von Objekten. Um diese Information mathematisch und damit computerseitig erfassbar zu machen, sind physikalische Modelle nötig.

### 2.5.1 Farbwahrnehmung

Die Farbwahrnehmung des Menschen wurde 1931 und 1964 von der **Commission Internationale de l'Éclairage** experimentell untersucht. Resultat sind zwei gemittelte Beobachter, die die Empfindlichkeit der Rezeptoren im Auge als Grundlage haben (s. Abbildung 2.5)<sup>6</sup>.

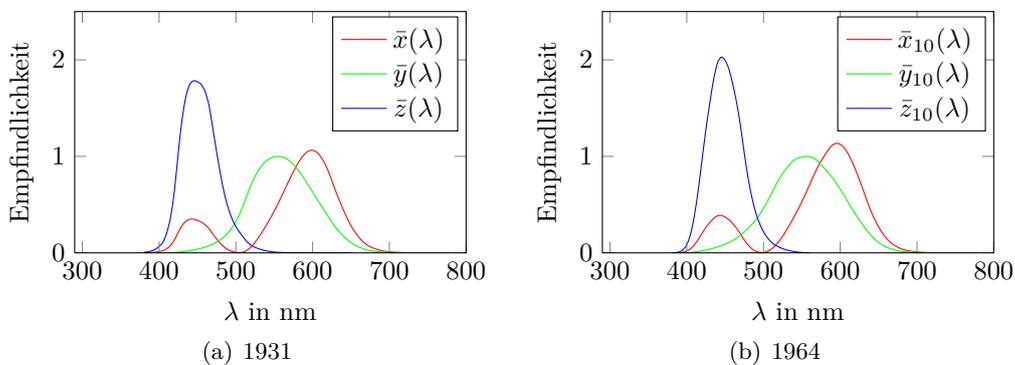


Abbildung 2.5: CIE Normalbeobachter

Um nun jede möglich erfassbare Farbe darzustellen, werden wie in [FVDF<sup>+</sup>94] beschrieben, die drei Hauptkomponenten  $X$ ,  $Y$  und  $Z$  eingeführt.  $X$ ,  $Y$  und  $Z$  treten an die Stelle der Grundfarben (rot, grün, blau), wobei  $Y$  die Lichtempfindlichkeit des menschlichen Auges beschreibt. Mit der additiven Überlagerung dieser drei Größen kann nun jede Farbe  $C$  dargestellt werden als:

$$C = x_c X + y_c Y + z_c Z \quad (2.32)$$

Wobei sich  $x$ ,  $y$  und  $z$  aus den CIE Normalbeobachtern errechnet:

$$x_c = k \int_0^\infty I(\lambda) \bar{x}(\lambda) d\lambda \quad (2.33)$$

$$y_c = k \int_0^\infty I(\lambda) \bar{y}(\lambda) d\lambda \quad (2.34)$$

$$z_c = k \int_0^\infty I(\lambda) \bar{z}(\lambda) d\lambda \quad (2.35)$$

<sup>6</sup>Wenn nicht anders vermerkt wird der Beobachter von 1931 verwendet.

$k$  wird hier je nach Quelle zur Normierung benutzt<sup>7</sup>.  $I(\lambda)$  beschreibt die spektrale Leistungsdichte. Da diese vom emittierenden Strahler abhängt, hat die CIE diese zur weiteren Vergleichbarkeit für verschiedene Farbtemperaturen standardisiert. Im Folgenden wird die CIE Normbeleuchtung A verwendet (s. Abbildung 2.6).

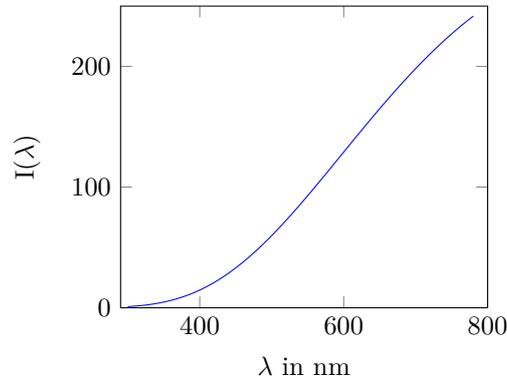


Abbildung 2.6: CIE Normbeleuchtung A

Durch Normierung auf die gesamte Lichtenergie  $X + Y + Z$  entstehen

$$x = \frac{X}{X + Y + Z}, \quad y = \frac{Y}{X + Y + Z}, \quad z = \frac{Z}{X + Y + Z}. \quad (2.36)$$

Damit gilt nun  $x + y + z = 1$ . Bezogen auf  $X$ ,  $Y$  und  $Z$  befinden sich  $x$ ,  $y$  und  $z$  nun auf der Ebene  $X + Y + Z = 1$ . Mithilfe einer orthogonalen Projektion auf die  $xy$ -Ebene erhält man das bekannte CIE 1931 Farbdigramm (s. Abbildung 2.7). Auf diesem Farbdigramm wird nun der gesamte menschliche Gamut<sup>8</sup> für eine feste Luminanz dargestellt.

## 2.5.2 Farbmodelle

Das erste Graßmannsche Gesetz [Doh09] beschreibt die Separabilität von Farben in unabhängige Grundgrößen. Die verschiedenen Arten der Trennung werden in Farbmodellen beschrieben. Die Wahl des geeigneten Farbmodells ist wichtig im Hinblick auf die Segmentierung, weshalb einige Vertreter hier kurz vorgestellt werden.

### RGB

Das RGB-Modell wird vorzugsweise in Farbmonitoren und Rastergrafiken benutzt. **R**ot, **g**rün und **b**lau sind hier die Primärvalenzen, aus denen sich additiv die Farben ergeben. Aufgrund der drei Primärvalenzen bietet sich eine kubische Darstellungsart an:

$$\vec{c} = \begin{pmatrix} r \\ g \\ b \end{pmatrix}, \quad 0 < \{r, g, b\} \leq 1 \quad (2.37)$$

So befinden sich auf den Achsen die Anteile der Primärvalenzen und auf der Hauptdiagonalen vom Ursprung  $(0, 0, 0)$  bis hin zum Weißpunkt  $(1, 1, 1)$  die Graustufen. Exemplarisch ist

<sup>7</sup>Typischerweise so, dass strahlendes weiß eine Luminanz (Helligkeit)  $Y$  von 100 aufweist.

<sup>8</sup>Gamut: Spektrum

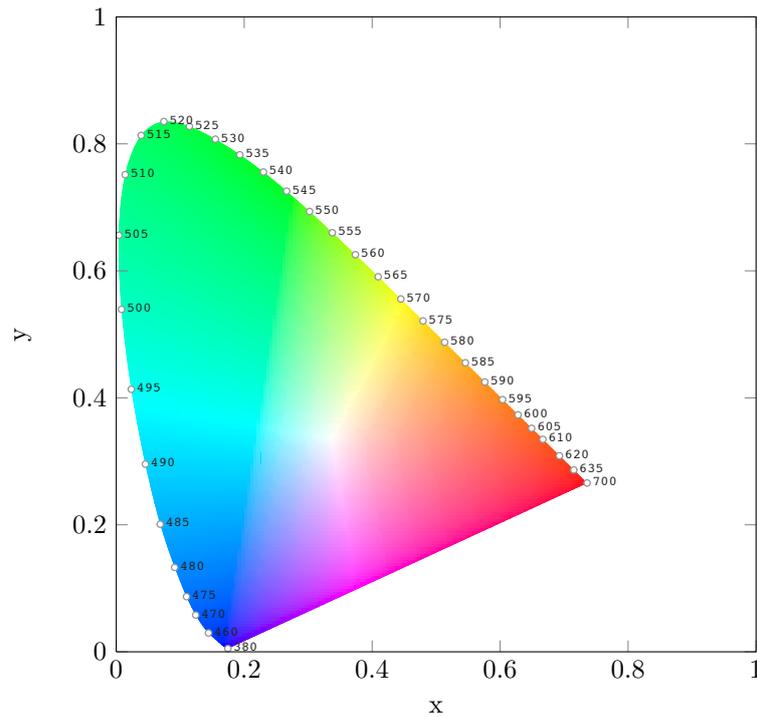


Abbildung 2.7: CIE 1931 Farbdiagramm, nach einer Grafik in [Hof06]

hier das CIE RGB Modell ausgewählt worden. Es arbeitet mit den Primärvalenzen bei  $r = 700 \text{ nm}$ ,  $g = 546.1 \text{ nm}$  und  $b = 435.8 \text{ nm}$ . Im Vergleich zum CIE-XYZ (s. Abbildung 2.8) können nicht alle wahrnehmbaren Farben im RGB-Farbraum dargestellt werden.

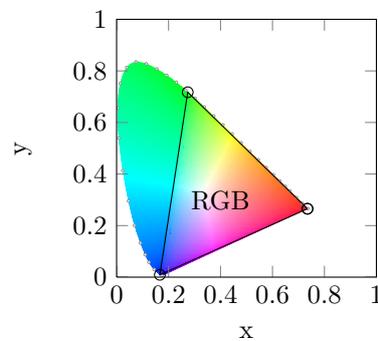


Abbildung 2.8: CIE-RGB

### CIE-Lab

Das CIE-Lab-Modell entsteht direkt aus dem ursprünglichen XYZ-Modell, nur das hier der Ansatz verfolgt wurde, die Abstände zwischen den Farben gleich zu halten. Dies erreicht

man durch folgende Abbildungsvorschrift [Lin]:

$$W_r = \{X_r, Y_r, Z_r\} \text{ (weiß-Referenz)} \quad (2.38)$$

$$L = 116f_y - 16 \quad (2.39)$$

$$a = 500(f_x - f_y) \quad (2.40)$$

$$b = 200(f_y - f_z) \quad (2.41)$$

$$f_{\{x_r, y_r, z_r\}} = \begin{cases} \sqrt[3]{\{x_r, y_r, z_r\}} & \text{wenn } \{x_r, y_r, z_r\}_r > \epsilon, \\ \frac{\kappa\{x_r, y_r, z_r\} + 16}{116} & \text{wenn } \{x_r, y_r, z_r\}_r \leq \epsilon \end{cases} \quad (2.42)$$

$$\{x_r, y_r, z_r\} = \frac{\{X, Y, Z\}}{\{X_r, Y_r, Z_r\}} \quad (2.43)$$

$$(2.44)$$

$L$  steht für die Luminanz,  $a$  für eine grün-rot Mischung und  $b$  für eine blau-gelb-Mischung. Um eine Stetigkeit der Teilfunktionen von  $f_{\{x_r, y_r, z_r\}}$  zu erreichen, werden rechnerisch die Werte  $\epsilon$  und  $\kappa$  zu

$$\epsilon = \frac{216}{24389} \quad (2.45)$$

$$\kappa = \frac{24389}{27}. \quad (2.46)$$

bestimmt.

## HSV

Der HSV-Farbraum basiert auf den Farben des RGB-Raumes. Die Parameter **H**ue, **S**aturation und **V**alue (Farbton, Sättigung und Helligkeit) beschreiben die Basen eines Zylinderkoordinatensystemes. Wie in Abbildung 2.9 ersichtlich, wird durch den Winkel  $\theta$  der Farbton, durch  $\rho$  die Sättigung und die Luminanz durch  $z$  bestimmt.

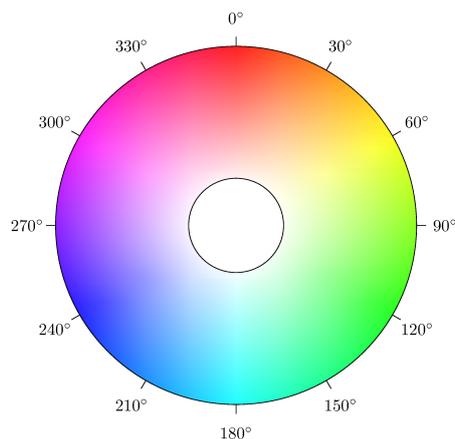


Abbildung 2.9: HSV in Zylinderdarstellung für eine feste Luminanz

## 2.6 Segmentierung

Segmentierung beschreibt Verfahren zur Trennung von Objekten. Klassischerweise trennt es den Vordergrund vom Hintergrund. Man spricht von einer vollständigen Segmentierung, wenn jedes Pixel eine Objektzugehörigkeit aufweist.

Segmentierungsverfahren sind unterscheidbar in [Jäh05, S. XII]:

- pixelorientierte Segmentierung
- kantenbasierte Segmentierung
- regionenorientierte Verfahren
- modellbasierte Verfahren.

Im Folgenden werden drei Vertreter dieser Verfahren vorgestellt, die im Rahmen dieser Arbeit weiter untersucht werden.

### 2.6.1 K-Means

K-Means ist ein Verfahren zur Gruppierung (Clustering) von Datensätzen. Es ist identisch mit dem Lloyd-Algorithmus, der in der Vektorquantisierung benutzt wird [Mus02, S. 91]. Die Konvergenz des Algorithmus kann durch das Finden einer Lyapunov-Funktion gezeigt werden [Mac03, S. 291]. Falls ein System eine Lyapunov-Funktion aufweist, ist die Konvergenz garantiert.

Der Algorithmus lässt sich wie folgt beschreiben:

---

**Algorithmus 1** K-Means Clustering [HW79]

---

**Initialisierung:** Setze  $k$   $\{\vec{m}^{(k)}\}$  zufällige Repräsentativwerte

**Zuordnung:** Jeder Datenpunkt  $\vec{x}^{(n)}$  wird anhand des nächsten Repräsentativwertes dem Cluster  $k^{(n)}$  zugeordnet:

$$k^{(n)} = \underset{k}{\operatorname{argmin}} d\left(\vec{m}^{(k)}, \vec{x}^{(n)}\right).$$

**Aktualisierung:** Berechne neue Repräsentativwerte:

$$\vec{m}^{(k)} = \text{Schwerpunkt}\left(k^{(n)}\right)$$

**repeat**

**Zuordnung** und **Aktualisierung**

**until** keine Änderung der **Zuordnung**

---

Der beispielhafte Ablauf eines Clusterings durch den K-Means-Algorithmus ist in Abbildung 2.10 gezeigt. Auf der Abszisse ist der a-Kanal und auf der Ordinate der b-Kanal eines Bildes aufgetragen. Die Pixel des Bildes werden nun ihrem Farbwert nach auf der ab-Ebene aufgetragen und dem Algorithmus zugeführt. Nachdem die Cluster gebildet sind, kann einer Farbe im Bild eine eindeutige Cluster-Nummer zugewiesen werden. Es entsteht eine überdeckungsfreie, nicht zusammenhängende Segmentierung.

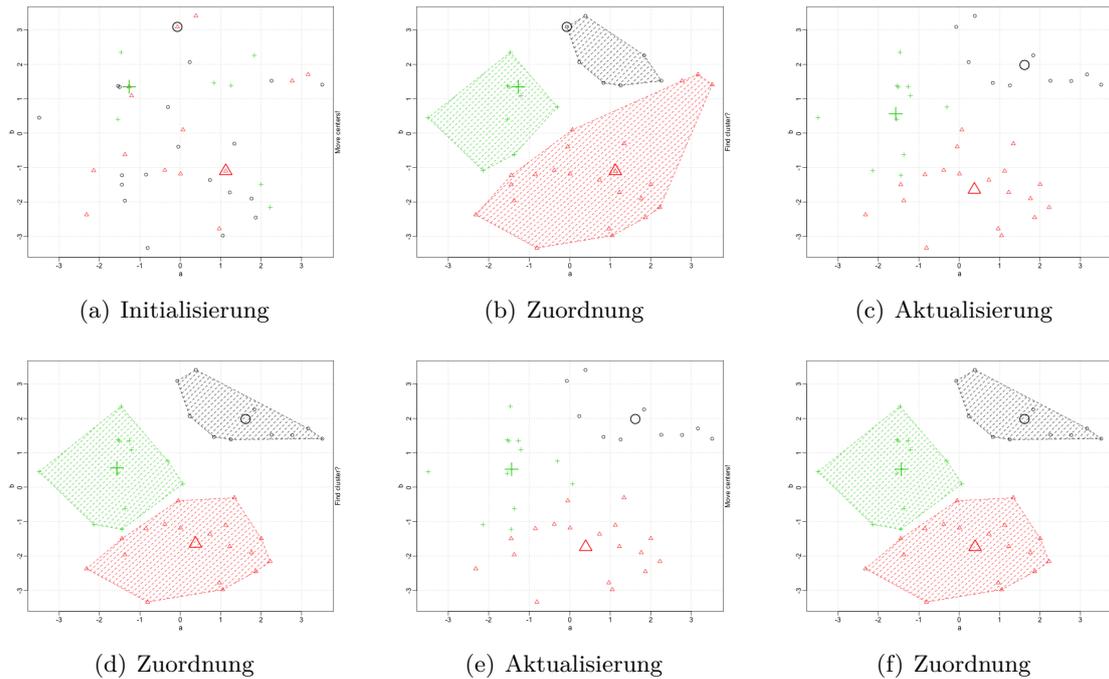


Abbildung 2.10: Beispiel K-Means Clustering mit drei Zentren

## 2.6.2 Gaussian Mixture Models

Die Grundidee der Gaussian Mixture Models (kurz:GMM) besteht darin eine unbekannte Wahrscheinlichkeitsdichtefunktion  $p(x)$  eines Datensatzes  $X = \{x_1, \dots, x_N\}$  als Summation von gewichteten Normalverteilungen  $\mathcal{N}$  zu modellieren:

$$p(x) = \sum_{i=1}^N w_i \cdot \mathcal{N}(x|m_i, \sigma_i) \text{ mit } \sum_{i=1}^N w_i = 1. \quad (2.47)$$

$w_i$  beschreibt dabei die Gewichtung oder auch a priori Wahrscheinlichkeit der Gaußkerne. Die Wahl der Zentren der Gaußkerne wird durch die Maximierung der zugehörigen Likelihood-Funktion ermittelt:

$$\Theta^* = \operatorname{argmax}_{\Theta} p(X|\Theta) = \operatorname{argmax}_{\Theta} \prod_{i=1}^N p(x_i|\Theta). \quad (2.48)$$

Zur Lösung dieser Gleichung kann der Expectation-Maximization-Algorithmus (EM-Algorithmus) benutzt werden. Der Algorithmus selbst sowie die Konvergenzeigenschaften wurden 1977 von Dempster et. al. beschrieben [DLR77].

Angewandt auf die GMM lassen sich mit dem EM-Algorithmus die Mittelwerte  $m_i$ , die Varianzen  $\mu_i$  und die Gewichte  $w_i$  bestimmen, womit die Likelihood-Funktion komplett beschrieben ist.

Zum Clustern genügt es nun von jedem Datenpunkt die Wahrscheinlichkeit zu bestimmen, mit der er von einem Gaußkern generiert wurde. Die Cluster-Zuordnung erfolgt über die Auswahl des wahrscheinlichsten Gaußkerns.

### 2.6.3 Snakes

Snakes sind Splines, die sich flexibel an die Kanten eines Bildes anpassen, wobei das Hauptkriterium die Energieminimierung ist. Die dazugehörigen mathematischen Modelle der Energien lieferten Kass, Witkin und Terzopoulos [KWT88].

Diese schlagen folgendes Energiefunktional vor, wobei  $c(s)$  eine parametrische Kontur mit dem Wertebereich  $[0, 1]$  und  $I(x, y)$  die Intensität des Quellbildes beschreiben:

$$E_{Snake} = \int_0^1 E_{intern}(c(s)) ds + \int_0^1 E_{extern}(c(s)) ds \quad (2.49)$$

$$= - \int_0^1 |\nabla I(c(s))|^2 ds + \int_0^1 \alpha \left| \frac{\partial c(s)}{\partial s} \right|^2 + \beta \left| \frac{d^2 c(s)}{ds^2} \right|^2 ds. \quad (2.50)$$

Die interne Energie ergibt sich aus Vorabinformationen aus dem Modell (z.B. Modellierung einer Kontur durch Splines) und hängen nicht von den Eingangsdaten ab. Die externe Energie wird aus dem Bild selbst berechnet. Minimieren lässt sich das Funktional mithilfe der Euler-Lagrange-Gleichung:

$$\frac{\partial E_{Snake}}{\partial c(s)} - \frac{\partial}{\partial s} \frac{\partial E_{Snake}}{\partial c'(s)} + \frac{\partial^2}{\partial s^2} \frac{\partial E_{Snake}}{\partial c''(s)} = 0 \quad (2.51)$$

$$\nabla |\nabla I(c(s))|^2 - \alpha \frac{\partial^2 c(s)}{\partial s^2} + \beta \frac{\partial^4 c(s)}{\partial s^4} = 0. \quad (2.52)$$

Zur konkreten Berechnung wird das Bild als diskretes Gitter angenommen und die Initialisierungs-Snake mithilfe diskreter Stützpunkten vorgegeben.

### 2.6.4 Bewertung einer Segmentierung

Zur Bewertung einer Segmentierung sind Referenzdaten vonnöten, die sogenannten Ground-Truth-Daten. Die eigentliche Bewertung wird hier über den unten aufgeführten F1-Score vorgenommen.

#### Ground-Truth

Zur Erzeugung einer Referenz ist eine Handsegmentierung unumgänglich. In Abbildung 2.11(a) ist ein Elastogramm zu sehen mit seiner zugehörigen Ground-Truth in Abbildung 2.11(b). Für die Ground-Truth wird definiert, dass ein nicht zum Objekt zugehöriger Punkt den Wert 255 und ein Objektpixel einen Wert ungleich 255 besitzt. So entsteht ein Binärbild wie in Abbildung 2.11(c) dargestellt.

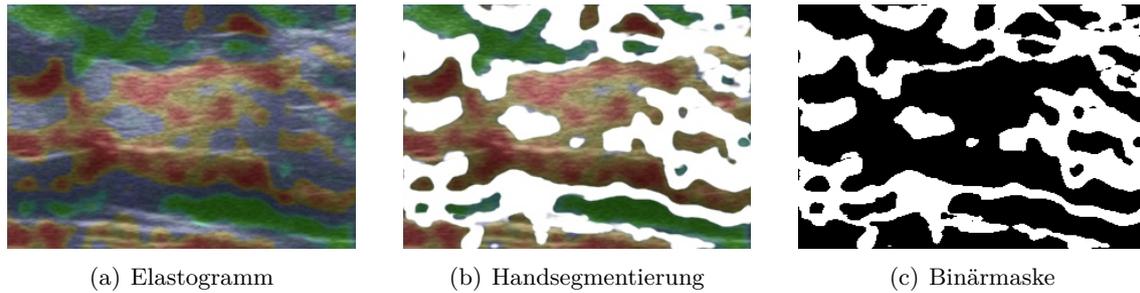


Abbildung 2.11: Stufen der Ground-Truth

### F-Score

Der F-Score nach [Chi92] ist ein üblicher Klassifikator zur Ratifizierung einer Segmentierung anhand von Ground-Truth-Daten. Er lässt sich wie folgt definieren [OD08, S. 138]:

$$F_{\beta} = \frac{(\beta^2 + 1) \text{ Precision} \cdot \text{ Recall}}{\beta^2 \text{ Precision} + \text{ Recall}} \quad (2.53)$$

$$\text{für } \beta = 1: F_1 = \frac{2 \text{ Precision} \cdot \text{ Recall}}{\text{ Precision} + \text{ Recall}} \quad (2.54)$$

Precision beschreibt dabei den Anteil von korrekt positiv deklarierten Ergebnisse zur Gesamtheit der als positiv deklarierten Ergebnisse.

Recall dementsprechend den Anteil der korrekt negativ erkannten Ergebnisse zur Gesamtheit der als negativ deklarierten Ergebnisse.

$$\text{Precision} = \frac{\text{true positive}}{\text{true positive} + \text{false positive}} \quad (2.55)$$

$$\text{Recall} = \frac{\text{true positive}}{\text{true positive} + \text{false negative}}. \quad (2.56)$$

Der  $F_1$ -Score bildet das harmonische Mittel zwischen Precision und Recall [Chi92]:

$$H = \frac{n}{\sum_{i=1}^n \frac{1}{x_i}} = \frac{2}{\text{Precision}^{-1} + \text{Recall}^{-1}} = F_1. \quad (2.57)$$

## 2.7 Support Vector Machine

Die Support Vector Machine (kurz: SVM) wird benutzt um eine Menge von Trainingsvektoren durch eine Hyperebene zu trennen. Eine Hyperebene ist ein  $n-1$ -dimensionaler Unterraum eines  $n$ -dimensionalen Vektorraums. Somit sind im zwei-dimensionalen die Geraden oder im drei-dimensionalen Ebenen Hyperebenen.

Der Abstand der Trainingsvektoren die der Hyperebene am nächsten liegen wird bei maximiert. Diese Vektoren werden als Stützvektoren bezeichnet. Hyperebenen können nur linear unabhängige Vektoren voneinander trennen. Da dies in der Praxis nicht der Fall ist, überführt die SVM den Vektorraum und die darin befindlichen Trainingsvektoren in einen

Raum von theoretisch unendlicher Dimension.

In diesem höher dimensionalen Raum steigt laut Covers Theorem [Cov65] die Wahrscheinlichkeit der linearen Separierbarkeit. Nach der Rückführung auf die Ausgangsdimension liegt eine unter Umständen nicht-lineare, nicht-zusammenhängende Hyperebene, die aber die Gebiete optimal teilt. Um die Komplexität der Ebenen zu reduzieren werden verschiedene Kernelfunktionen eingesetzt, die durch die Dimensionsänderungen weniger komplex werden [CY11].

## 3 Konzeption

In diesem Kapitel wird aufbauend auf den Grundlagen ein Konzept zur automatischen Klassifikation von Elastogrammen erarbeitet. Auf Basis des hier vorgestellten Konzeptes, erfolgt im nächsten Kapitel die Implementierung.

In Abbildung 3.1 ist das Grundkonzept der Arbeit dargestellt. Beginnend mit der Extraktion der Elastogramme aus den Bildexporten, über die Segmentierung, bis hin zur Featureextraktion und -analyse, wird eine Abfolge möglicher Verfahrensschritte dargelegt und erläutert. Das Ziel der Untersuchungen stellt eine mögliche automatische Einordnung der aufgenommenen Elastographie-Daten in das in Abschnitt 2.1.3 erläuterte BI-RAD-System dar.

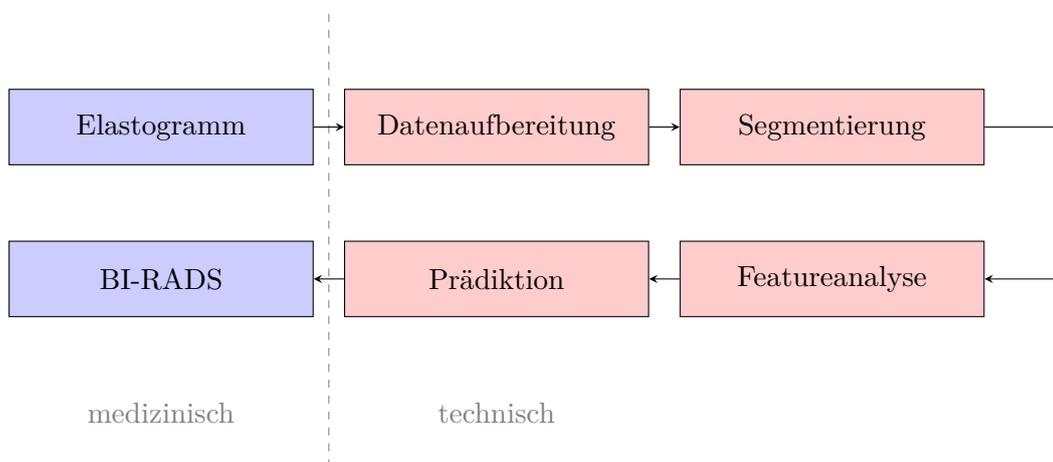


Abbildung 3.1: Grundkonzept

### 3.1 Datenaufbereitung

Dieser Arbeit liegt ein Testdatensatz bestehend aus 71 Bildexporten vor. Die Exporte wurden mit einem MYLAB<sup>TM</sup> TWICE der Firma ESAOTE BIOMEDICA Deutschland GmbH angefertigt. Sie besitzen eine Größe von 800 x 500 Pixel, eine Auflösung von 72 dpi und wurden JPEG-komprimiert gespeichert. Die Verlustbehaftung der JPEG-Codierung und die daraus resultierenden Ungenauigkeiten in der Berechnung sind mangels Rohdaten nicht zu verifizieren. Bei den pixelbasierten Operationen wie dem Schwellwertverfahren sollte dies durch Bereichsangaben berücksichtigt werden.

Zudem wurden die Elastogramme von einem erfahrenen Facharzt für Gynäkologie bewertet. Als Bewertungskriterium wurde das BI-RAD-System angewandt. Die Verteilung der Befunde wird in Abbildung 3.2 dargestellt.

Abbildung 3.3 zeigt den Aufbau der Exporte: Das Elastogramm (1) wird dem Ultraschallbild (2) überlagert. Durch die Farbdarstellung wird die Elastizität dargestellt. Die Zuordnung

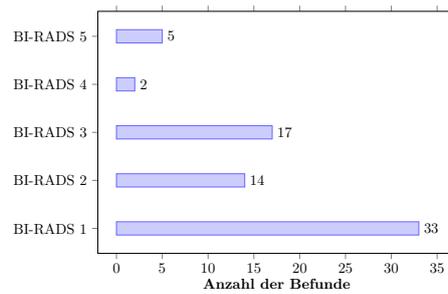


Abbildung 3.2: Verteilung der Befunde

erfolgt über die Skala (3). Die angegedeutete Feder (4) zeigt die Qualität des Elastogramms an. Sie dient dem Untersuchenden als Qualitätsfeedback und färbt sich grün bei richtiger Schallkopfführung. Dieses Kriterium wird im Rahmen dieser Arbeit nicht weiter beachtet, da eine korrekte Aufnahme des Elastogramms vorausgesetzt wird.

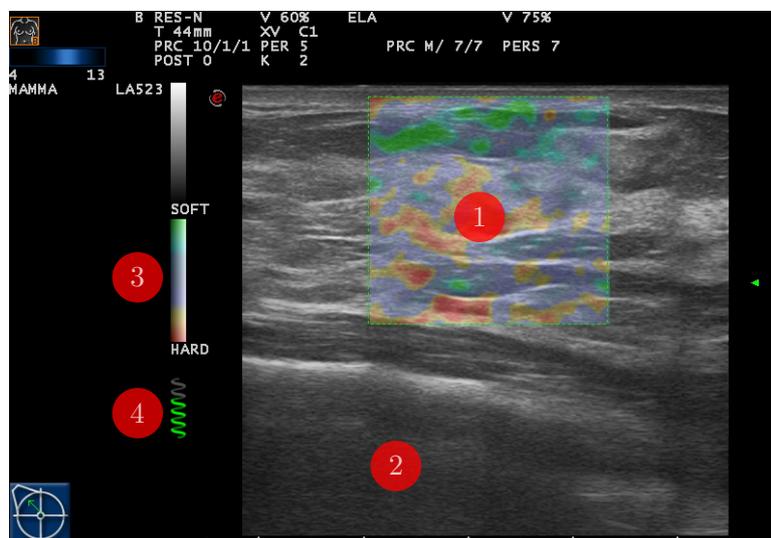


Abbildung 3.3: ESAOTE Elaxto Imaging (1) Elastogramm, (2) Ultraschall B-Mode (3) Elastizitätsskala (4) Qualität des Elastogramms

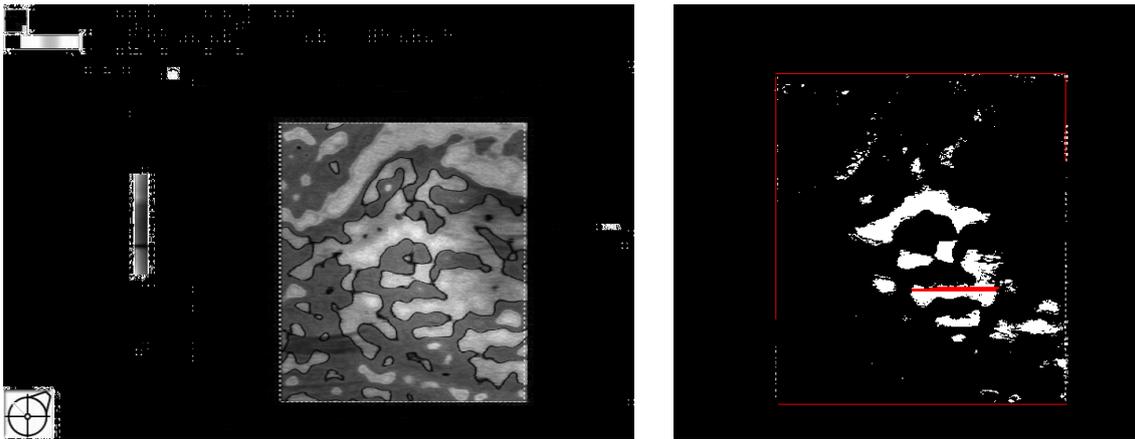
Im ersten Schritt muss das Elastogramm aus dem Gesamtbild extrahiert und für eine spätere Bewertung der Segmentierungsverfahren händisch segmentiert werden. Resultat ist die in Abbildung 2.11 gezeigte Ground-Truth.

Die Extraktion der Elastogramme soll für eine spätere graphische Benutzeroberfläche automatisiert werden. Folgende Schritte sind dabei zu berücksichtigen:

1. **Ausschnittswahl:** Das Ultraschallbild wird im Elastogramm immer gleich positioniert, d.h. der Ausschnitt kann auf das Rechteck mit den Punkten  $P_{oben\ links} = (241, 77)$  und  $P_{unten\ rechts} = (503, 470)$  reduziert werden.
2. **Farbraumtransformation:** Um das farbige Elastogramm möglichst gut vom umliegenden Graubild zu trennen, wird eine Transformation in den HSV-Raum gewählt. Farblose Bezirke sind im Sättigungskanal null (s. Abbildung 3.4(a)).

3. **Binarisierung:** Eine weitere Trennung kann über eine Binarisierung des Bildes vorgenommen werden. Dazu wird eine Schwellwertbildung mit einem Wert von 170 auf den Sättigungskanal angewandt.
4. **Liniendetektion:** Die nun ersichtliche gestrichelte Linie wird über die Progressive Probabilistic Hough-Transform [MGK00]. Basierend auf der Hough-Transformation bietet sie zusätzlich die Möglichkeiten Schwellwerte für die Länge der Liniensegmente und die maximalen Abstände zwischen ihnen festzulegen.

Das Ergebnis dieser Vorgehensweise ist in Abbildung 3.4(b) gezeigt. Über eine iterative Untersuchung der Geradenkoordinaten kann durch Wahl der Eckgeraden das Elastogramm extrahiert werden.



(a) Sättigungskanal nach Transformation in den HSV-Farbraum

(b) Binarisierter S-Kanal mit Hough-Linien

Abbildung 3.4: Automatischer Elastogrammschnitt

## 3.2 Segmentierung

Zur Extraktion der einzelnen Druckgebiete muss das Elastogramm segmentiert werden. Dazu werden für eine erste Analyse die Standard-Operatoren aus Kapitel 2.4.1 auf das Elastogramm in Abbildung 3.5(a) angewandt. Es zeigt sich, dass die Teilung in die RGB-Kanäle keine brauchbare Basis für eine Trennung der Druckgebiete liefert (s. Abbildung 3.5(d)-3.5(f)).

Eine Trennung in die HSV-Kanäle lässt in Abbildung 3.5(g) eine gute Trennung des roten Anteils vermuten. In Abbildung 3.5(b) ist der Sobel-Filter exemplarisch auf den H-Kanal angewendet. Zudem wurde eine Schwellwerttrennung bei 135 festgelegt. Es erfolgt eine gute Trennung der roten Bereiche. Der Übergang von blau zu grün wird allerdings nicht zufriedenstellend erkannt. Die Anwendung auf den a- bzw. b-Kanal liefert vergleichbare Ergebnisse. Auch die Anwendung eines Laplace-Filters bringt nicht die erforderliche Trennung (s. Abbildung 3.5(c)).

Zur genaueren Segmentierung sollen die Segmentierungsalgorithmen aus Kapitel 2.6 Anwendung finden. Da die Snakes aus Kapitel 2.6.3 eine Vorinformation in Form von Stützstellen

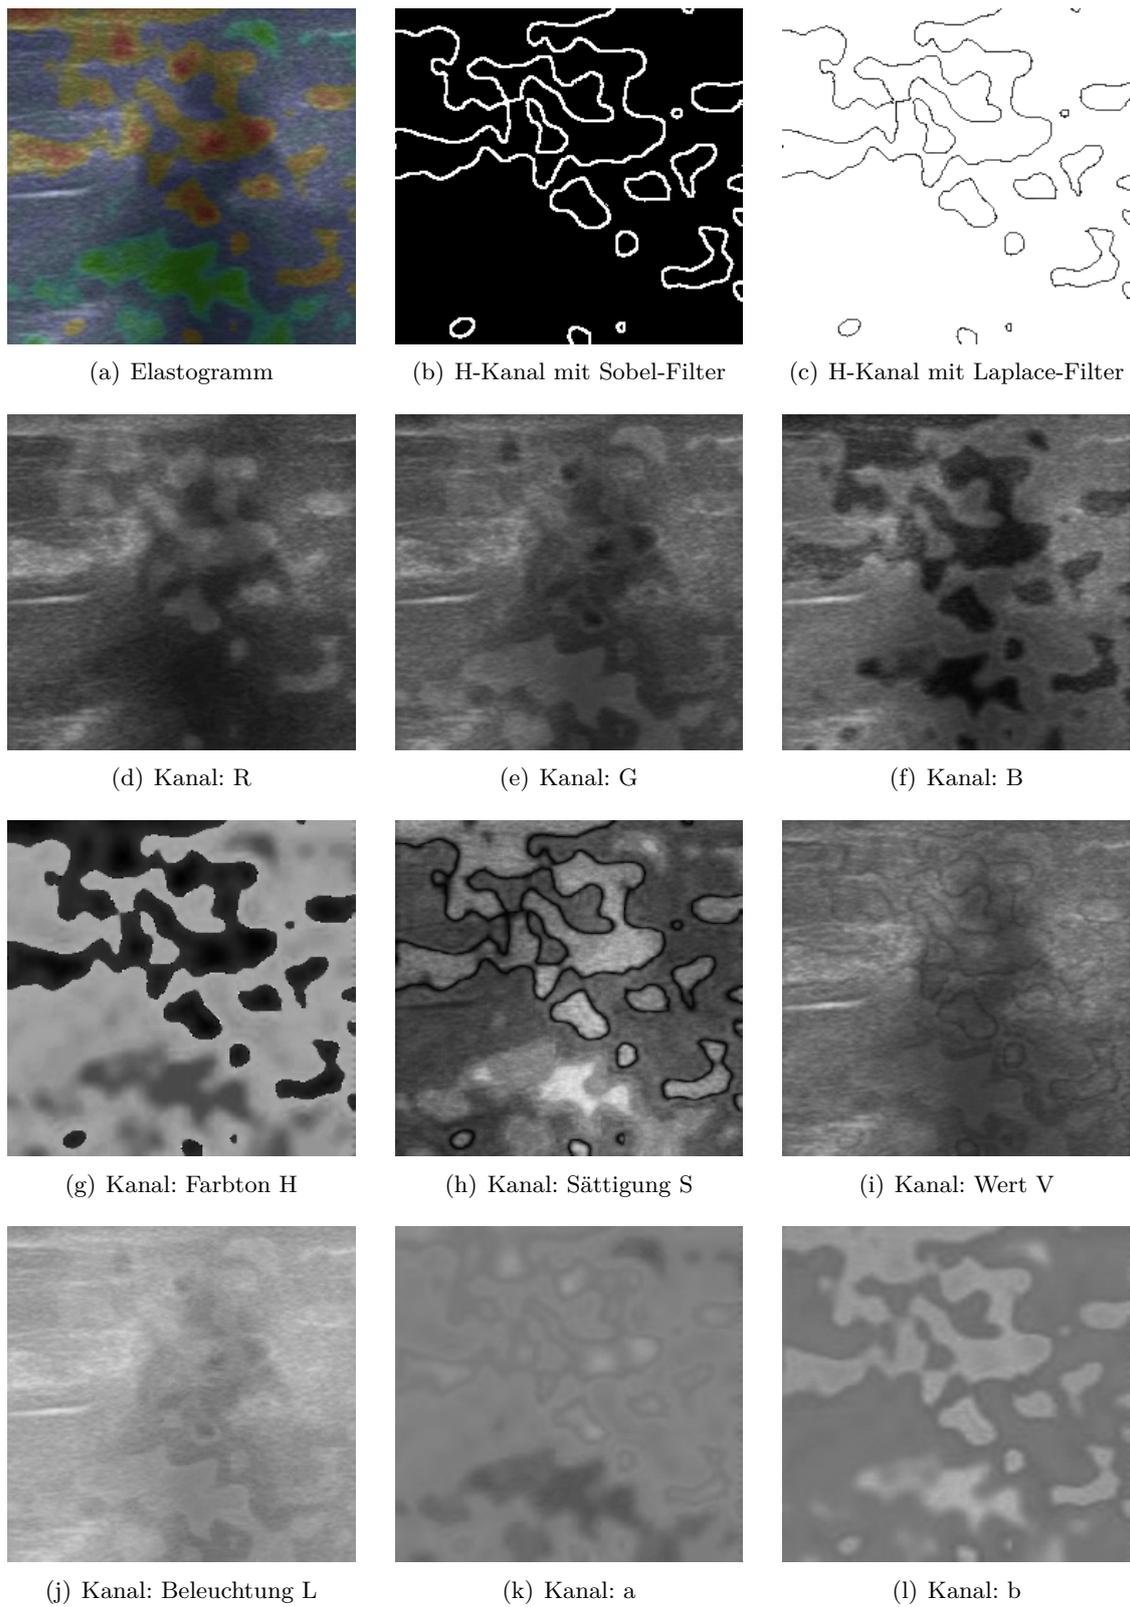


Abbildung 3.5: Elastogramm, Diagnose: BI-RADS 5

benötigen, sowie die Topologie<sup>1</sup> der Segmentierung größer ist als eins, scheidet dieses als Verfahren aus.

Die beiden Clusterverfahren K-Means sowie die Gaussian Mixture Models können beide  $n$ -dimensionale Cluster bilden. Zur Segmentierung von Elastographiedaten sollen im Rahmen dieser Studienarbeit drei Cluster gebildet werden: Rot, Grün und Blau.

Eine Vorauswahl für ein geeignetes Farbmodell lässt sich erzielen, indem die Farbe als Hauptmerkmal zur Trennung der relevanten Bereiche betrachtet wird.

Dieser Betrachtung kommen der Lab- und HSV-Raum entgegen. Beide besitzen zwei Farbkanäle, sowie einen Beleuchtungskanal (L bzw. V). Wird die Beleuchtung ignoriert, so wird jedes Pixel durch zwei Kanäle repräsentiert: S und V, sowie a und b. Dadurch reduziert sich die Berechnung der Cluster um jeweils eine Dimension.

Beide Algorithmen sollen mit den Farbmodellen Lab und HSV geprüft werden. Die Qualitätsprüfung folgt über den in Kapitel 2.6.4 eingeführten F-Score. Zudem wird die Latenz der Berechnung ermittelt.

Um möglichst realistische Latenzanalysen der Berechnungen durchzuführen, werden neben einem anfänglichen Test in Matlab die Algorithmen in C++ umgesetzt. Da es sich hier um Standardverfahren aus dem Bereich Computer Vision handelt, wird hier auf die freie Bibliothek OpenCV [Bra00] zurückgegriffen. Die o.g. Algorithmen, sowie ein Matlab<sup>®</sup>-ähnliches Handling von Bilddaten sind dort vorimplementiert und werden im Folgenden benutzt.

Das Ergebnis der Algorithmen stellen drei Cluster dar. In diesem Fall repräsentieren sie drei Elastizitätsgruppen: Rot-, Grün- und Blautöne. Diese werden in drei separaten Bilddateien gespeichert. Abbildung 3.6 visualisiert das Vorgehen der Segmentierung und Speicherung: Das Elastogramm wird in den gewünschten Farbraum transformiert und dort die gewünschten Kanäle für das anschließende Clustering gewählt. Die drei Ergebniscluster werden im Anschluss gespeichert.

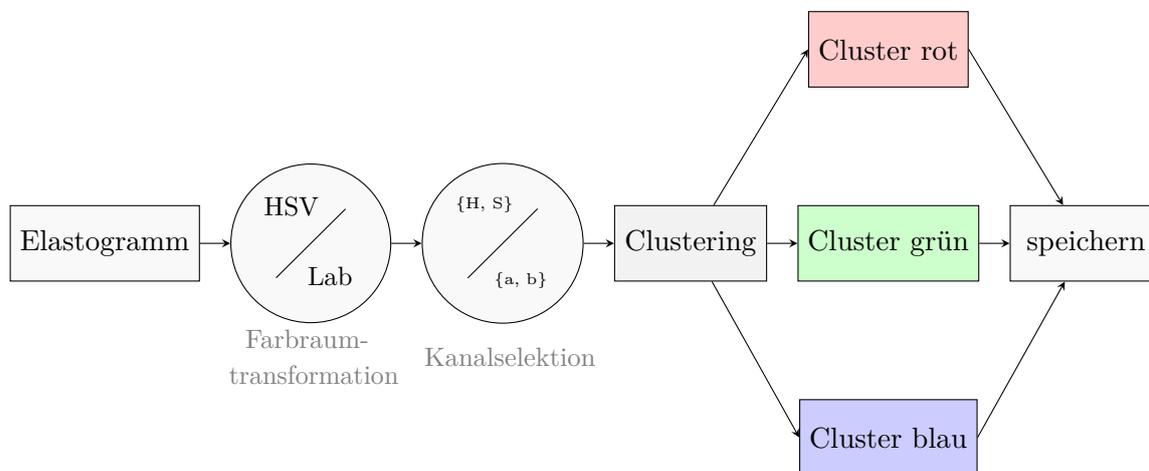


Abbildung 3.6: Segmentierungskonzept

<sup>1</sup>Topologie = *hier*: Anzahl der zu segmentierenden Gebiete

### 3.3 Featureextraktion

Im Hinblick auf eine medizinische Studie ist es wichtig, eine möglichst breite Auswahl an Bildfeatures anzubieten. So erscheint es sinnvoll, zuerst den gängigen Ablauf einer Vorsorgeuntersuchung mittels Ultraschall zu analysieren:

Eine Möglichkeit ist es, den Schallkopf über die Brust zu fahren und beim Entdecken einer Verhärtung mit dem Finger am Schallkopf entlang zu streichen, um den Übergang zwischen Läsion und umliegendem Gewebe zu erfassen (s. Anhang A.1).

Ähnlich gehen Itoh. et. al. [IUT<sup>+</sup>06] vor. Sie schlagen einen Elastizitäts-Score vor, der sich anhand der Druckverhältnisse in und um die Läsion herum ableitet, aber kompatibel mit dem BI-RAD-System ist. Kumm et. al. [KS10] bestätigen diesen Score mittels einer Studie. Neben dem Übergang zum umliegenden Gewebe spielt auch die Größe der Läsion eine Rolle.

Im Bereich der Computer Vision existieren Standard-Features, deren Berechnungen in OpenCV verfügbar sind. Dazu gehören die statistischen Momente, Hu-Momente, Umfang, Zirkularität und Konvexität.

Daraus ergeben sich die in Abbildung 3.7 dargestellten Features.

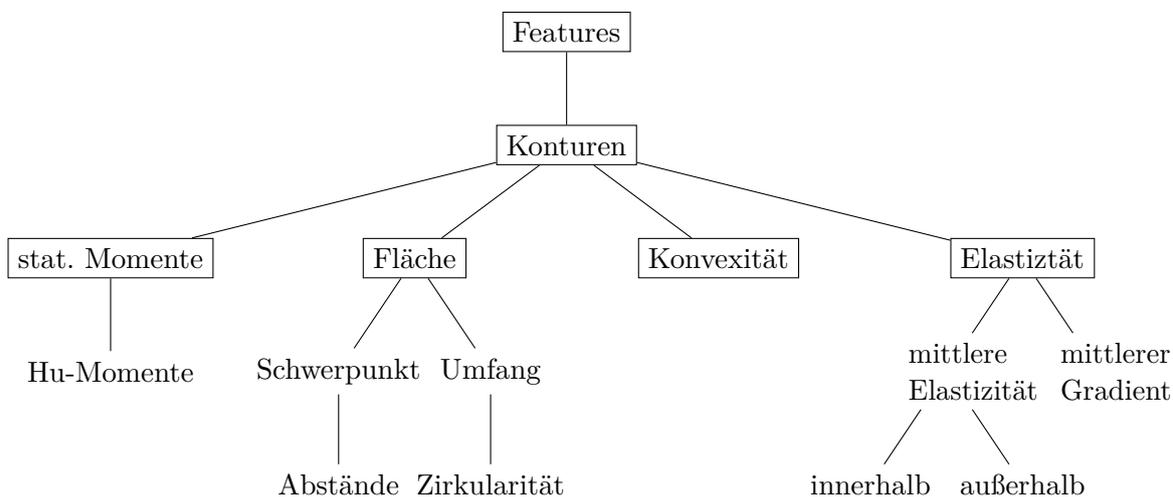


Abbildung 3.7: Mögliche Klassifizierungsfeatures

#### 3.3.1 Konturfeatures

Eine Möglichkeit zur Beschreibung von Regionen erfolgt über deren Konturen. Die zugehörigen Pixel jeder Region werden separat gespeichert und anschließend weiterverarbeitet. So lässt sich direkt aus der Anzahl der Pixel der Umfang der Region ablesen. Zudem ist es möglich, über den Satz von Green von der Kontur auf die umschlossene Fläche zu schließen.

#### Statistische Momente

Die statistischen Momente werden wie in Abschnitt 2.4.1 beschrieben gebildet. Zusätzlich sind die skalierungs-, rotations- und reflektions-invarianten Hu-Momente verfügbar [Hu62].

Sie werden häufig fürs Matching benutzt.

### Fläche

Die Fläche der Region lässt sich, wie oben erwähnt, mittels einer geschlossenen Kontur berechnen. Zu beachten ist, dass im Fall eines Ultraschallschnittbildes nicht die Oberfläche des Objektes berechnet wird, sondern je nach Stellung des Schallkopfes die Dicke des Objektes.

### Abstandsmatrix

Die Segmentierung produziert eine sehr feine Auflösung. Unter Umständen werden sehr kleine Strukturen als einzelner Befund erkannt. Es erscheint demnach sinnvoll, nah beieinander liegende Regionen zusammenzufassen. Dazu wird zusätzlich zu den Features eine symmetrische Abstandsmatrix generiert:

$$D = \begin{pmatrix} 0 & d_{12} & \cdots & d_{1N} \\ d_{21} & \ddots & & \vdots \\ \vdots & & \ddots & \vdots \\ d_{N1} & \cdots & \cdots & 0 \end{pmatrix} \quad (3.1)$$

Als Distanzmaß wird der euklidische Abstand gewählt, da er dem durch den Betrachter wahrgenommenen Regionsabstand entspricht:

$$d_{\vec{c}_x \vec{c}_y} = \|\vec{c}_x - \vec{c}_y\|. \quad (3.2)$$

$\vec{c}_x$  und  $\vec{c}_y$  beschreiben die Ortsvektoren der Schwerpunkte zweier Regionen.

### Mittlere Elastizität

Die mittlere Elastizität einer Region lässt sich über den Mittelwert der Farbkanäle berechnen. Im Anschluss erfolgt ein Vergleich mit der Farbskala des Elastogramms aus Abbildung 3.3. Diese wird für den sich innerhalb der Kontur befindlichen Teil, sowie für das umliegende Gewebe berechnet.

### Verhältnis innerer zu äußerer Druck

Um dem wichtigen Kriterium der Verwachsung eines Tumors mit dem umliegenden Gewebe gerecht zu werden, wird das Verhältnis von der mittleren innenliegenden zur mittleren äußeren Elastizität gebildet. Je größer der Unterschied ist, desto isolierter ist die Region.

Der gesamte Featurevektor pro Region hat nun folgende Form:

Tabelle 3.1: Featurevektor

Eintrag	Inhalt
1-10	Verbundzentralmomente
11-17	Hu-Momente
18	Fläche
19	Umfang
20	Schwerpunktskoordinate x
21	Schwerpunktskoordinate y
22	Zirkularität = $\frac{\text{Umfang}^2}{\text{Fläche}}$
23	Konvexität
24	innere Elastizität
25	äußere Elastizität
26	$\frac{\text{innere Elastizität}}{\text{äußere Elastizität}}$

### 3.3.2 Speicherung

Zu jedem Bild existiert am Ende ein Satz von Features, der das Elastogramm charakterisiert. Das Clustering liefert je ein rotes, ein grünes und ein blaues Cluster. Diese Cluster bestehen jeweils aus  $n_{\{r,g,b\}}$  separierbaren Druckgebieten - den sog. *connected components*. Über OpenCV ist es möglich, die Konturen dieser automatisch zu erfassen und damit eine eindeutige Zuweisung zu bekommen (*connected component labelling*, s. Abbildung 4.5(a)). Für jedes dieser Druckgebiete werden nun die Features berechnet. Am Ende ergeben sich schließlich drei Matrizen mit den Größen  $n_{\text{Features}} \times n_{\{r,g,b\}}$ , die zur Prädiktion weitergereicht werden.

## 3.4 Prädiktion

Gesucht ist eine Abbildung aus den oben erwähnten Feature-Matrizen auf das dem Arzt bekannte BI-RAD-System. Dieses wird mittels der in Abschnitt 2.7 beschriebenen SVMs versucht nachzubilden. Es soll ferner getestet werden, wie verlässlich die Prädiktionsergebnisse sind. Weitere Zusammenhänge zwischen den einzelnen Features sollten im Fortgang der medizinischen Studie durchgeführt werden. Für die prinzipielle Machbarkeit wird die Ground-Truth-Datenbank benutzt, um die SVM zu trainieren. Wobei vorher von jeder BI-RADS-Klasse jeweils ein Vertreter herausgenommen wird, um später für das Testen der SVM möglichst reale Bedingungen zu schaffen.

## 3.5 Graphische Benutzeroberfläche

Die graphische Benutzeroberfläche soll dem behandelnden Arzt die Möglichkeit geben, ein Elastogramm zu importieren, es zu segmentieren und anschließend bewerten zu lassen. Zudem soll eine Exportmöglichkeit für die Feature-Daten vorhanden sein, um die Rohdaten ggf. einer statistischen Untersuchung o.ä. zugänglich zu machen.

Die Implementierung soll plattformübergreifend erfolgen. Die verwendete Bibliothek openCV sowie der C++ Kompiler sind für alle gängigen Betriebssysteme verfügbar. Als graphisches Frontend kommt das Framework Qt zum Einsatz, welches ebenso plattformübergreifend verfügbar ist. Für das Verständnis des Signal-Slot-Konzeptes sei auf [BS06] verwiesen. Eine andere wichtige Anforderung an das Programm ist eine saubere Trennung der graphischen Ein- und Ausgabe zu den logischen Operationen.

Ein weit verbreitetes Konzept zur Einhaltung dieser Forderung ist die Trennung des Programms in die Teile **Model**, **View** und **Controller**. Die Aufgabenverteilung der drei Elemente im Zusammenspiel mit Qt und OpenCV ist hier beschrieben [Lag11, S. 82], wird aber im Abschnitt 4.6 noch einmal aufgegriffen.

## 4 Implementierung

Zur Verifikation der Konzeption und Generierung von Testdaten wurden im Zuge dieser Studienarbeit fünf Programme entwickelt: kmeans, gmm, featureCalc, trainSVM und testSVM. Zudem wurde eine graphische Benutzeroberfläche erstellt.

Die Programme setzen die Konzeption aus Kapitel 3 um. Sie wurden zudem so modular aufgebaut, dass jedes Programm für sich anpassbar bzw. austauschbar ist.

Mittels einer geeigneten Skriptsprache ist es möglich mit den Programmen Stapelverarbeitung durchzuführen, um somit komfortabel aus einer Vielzahl von Elastogrammen Testdaten zu erzeugen. Hierdurch sind weitere sechs Shell-Skripte entstanden, deren Verwendung und Bedienung im Anhang A.4 ausführlich erläutert wird.

Die gesamte Toolchain ist in Abbildung 4.1 aufgeführt.

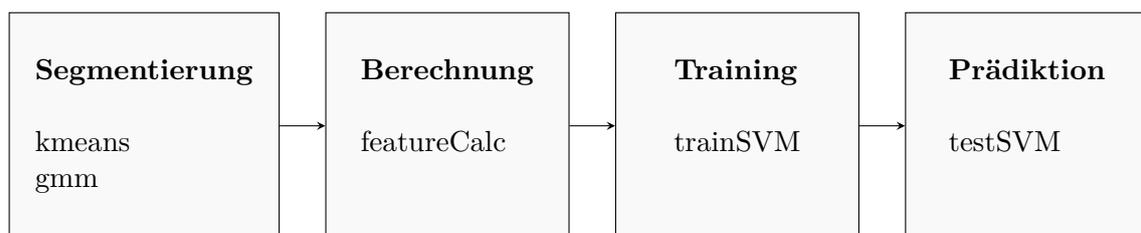


Abbildung 4.1: Toolchain

Im Folgenden sollen die Anforderungen und konkreten Implementierungen der einzelnen Komponenten näher erläutert werden, wobei eine Auflistung des Quelltextes nur an parameterbehafteten Stellen vorgenommen wird.

Zum Zeitpunkt der Implementierung wurde mit folgenden Bibliotheken gearbeitet:

- Boost, Ver. 1.48.0
- OpenCV, Ver. 2.3.1a
- Qt, Ver. 4.8.0.

Gemäß der Toolchain aus Abbildung 4.1 wird mit den Segmentierungsprogrammen gestartet.

## 4.1 Segmentierung: kmeans

### Benötigte Bibliotheken:

- Boost
- openCV

### Programmparameter:

- `--help`: Parameterliste anzeigen
- `--model`: Farbraumauswahl: Lab = 1 (default), HSV = 2
- `--visual`: Ergebnisse auf Bildschirm darstellen
- `--debug`: Debug-Ausgabe aktivieren
- `--src`: Pfad zur zu segmentierenden Datei
- `--mask`: Pfad zur passenden Ground-Truth
- `--writePath`: Pfad zum Speicherort

Dieses Programm dient der Segmentierung der Daten mittels K-Kmeans Clusterings aus Abschnitt 2.6.1. Der Flussplan des Programms ist in Abbildung 4.2 dargestellt. Im Folgenden werden die einzeln nummerierten Funktionsblöcke separat vorgestellt und ihre Funktionsweise erläutert.

Nach dem Programmstart **(1)** werden die Programmparameter von der Kommandozeile ausgewertet **(2)**. Dies geschieht mittels der Boost-Bibliothek *program\_options*.

Anschließend wird das Quellbild (Programmparameter `--src` eingelesen **(3)**) und in Form eines Matrix-Objektes abgespeichert. Diese Objektart stellt die Mat-Klasse aus OpenCV zur Verfügung. Sie ist Ausgangspunkt für alle weiteren Optionen. Die Bildpunkte werden als Matrix gespeichert, wobei jeder Matrixeintrag aufgrund der mehrkanaligen Bilder (z.B. RGB) auch mehrdimensional sein kann. Zu beachten ist, dass OpenCV die Kanäle dreht und Bilddaten als BGR abspeichert.

Die vorliegenden Bilddaten werden je nach Programmparameter `--model` entweder in das HSV- oder Lab-Farbmodell transformiert **(4)**. Gemäß den Ausführungen in Abschnitt 3.2 wird der Beleuchtungskanal ignoriert werden, damit sich das anschließende Clustering auf zwei Dimensionen reduziert. Dies wird unter Punkt Kanalselektion **(5)** vorgenommen.

Die anschließende Datenaufbereitung **(6)** dient der Anpassung der Daten an die Anforderungen der K-Means-Routine von OpenCV. Diese fordert eine eindimensionale Liste der Eingangsdaten, die mittels einer Matrixumformung durchgeführt wird.

---

```

1 /*
2  * Segmentation part
3  */
4 Mat clusters, centers;
5 // start performance test
6 // count cpu ticks and divide it through CLOCKS_PER_SEC
7 start = clock();
8 // Do the kmeans clustering
9 kmeans(image_ab_rs, n_cluster, clusters, cvTermCriteria(
    CV_TERMCRIT_EPS+CV_TERMCRIT_ITER, 100, 0.01), 3,
    KMEANS_RANDOM_CENTERS, centers);
10 // end performance test
11 end = clock();

```

---

Der Quelltext-Abschnitt zeigt die folgenden drei Punkte: In *Zeile 9* wird der Timer gestartet **(7)**, in *Zeile 12* das K-Means-Clustering vollzogen **(8)** und abschließend der Timer in *Zeile 15* wieder gestoppt **(9)**. Ausgehend von diesen Messwerten wird im Anschluss die Latenzanalyse generiert.

Das K-Means-Clustering wird dabei angewiesen  $n\_cluster$  zu erstellen und die abschließende Zugehörigkeit jedes Pixels in  $clusters$  zu speichern. Zudem wird eine Abbruchbedingung eingeführt, die den Algorithmus anweist entweder nach 100 Iterationen oder bei einer Änderung der Clusterzentren um weniger als 0,01 zu stoppen. Das Programm ist dabei so aufgebaut, dass maximal drei Cluster-Versuche mit jeweils unterschiedlichen, zufällig verteilten Initial-Zentren durchgeführt werden. Die Koordinaten der Zentren werden in  $centers$  gespeichert.

Zur Featureberechnung wird folgendes Bild erstellt: Jeder Bildpunkt besitzt nun durch das Clustering eine Clusterzugehörigkeit. Da noch nicht bekannt ist, welches Cluster welchem Farbbereich im Elastogramm entspricht, wird eine Farbwertsmittelung **(10)** der jeweiligen Cluster vorgenommen und dieser Farbwert im HSV-Farbraum betrachtet. Dazu wird folgende Abbildung vorgenommen:

$$\begin{aligned} 90^\circ < H < 150^\circ &\mapsto \{\text{blaues Cluster, ID}^1 = 0\} \\ 30^\circ < H < 90^\circ &\mapsto \{\text{grünes Cluster, ID} = 1\} \\ 0^\circ < H < 30^\circ \text{ und } 150^\circ < H < 180^\circ &\mapsto \{\text{rotes Cluster, ID} = 2\} \end{aligned}$$

Je nach Kriterium der Abbildung werden so die Cluster detektiert **(11)** und eindeutig zugewiesen. Nun besitzt jedes Pixel eine Clusterzuweisung und es ist bekannt welche Cluster-ID welchem Farbbereich entspricht. Dieses Bild wird als PPM<sup>2</sup> abgespeichert und später in Abschnitt 4.3 weiter verarbeitet.

Zur Bewertung der Segmentierung wird das ID-Bild mittels Schwellwert in ein Binärbild gewandelt **(12)**. In der Ground-Truth aus Abschnitt 2.6.4 wurde definiert, dass ein nicht zum Objekt zugehöriger Punkt den Wert 255 und ein Objektpixel einen Wert ungleich 255 besitzt. Hier wird angenommen, dass das blaue Cluster den Hintergrund darstellt und rot und grün Vordergrundinformationen sind. Somit wird das blaue Cluster auf den Grauwert 255 abgebildet und die Vereinigungsmenge von rot und grün auf null.

Mit dieser Umwandlung ist es möglich, die Ground-Truth-Maske mit dem segmentierten Bild zu vergleichen **(13)** und daraus den in Abschnitt 2.6.4 erläuterten F1-Score zu berechnen **(14)**.

Zusammen mit dem Dateinamen, der Berechnungszeit, Precision, Recall und dem F1-Score werden die Werte komma-separiert auf der Kommandozeile ausgegeben **(15)** und können somit als CSV<sup>3</sup> ausgewertet werden.

Schließlich wird das Programm beendet und somit alle laufenden Objektinstanzen aus dem Speicher entfernt **(16)**.

---

<sup>1</sup>ID = Identifikator

<sup>2</sup>Portable Pixmap

<sup>3</sup>CSV = comma-separated values

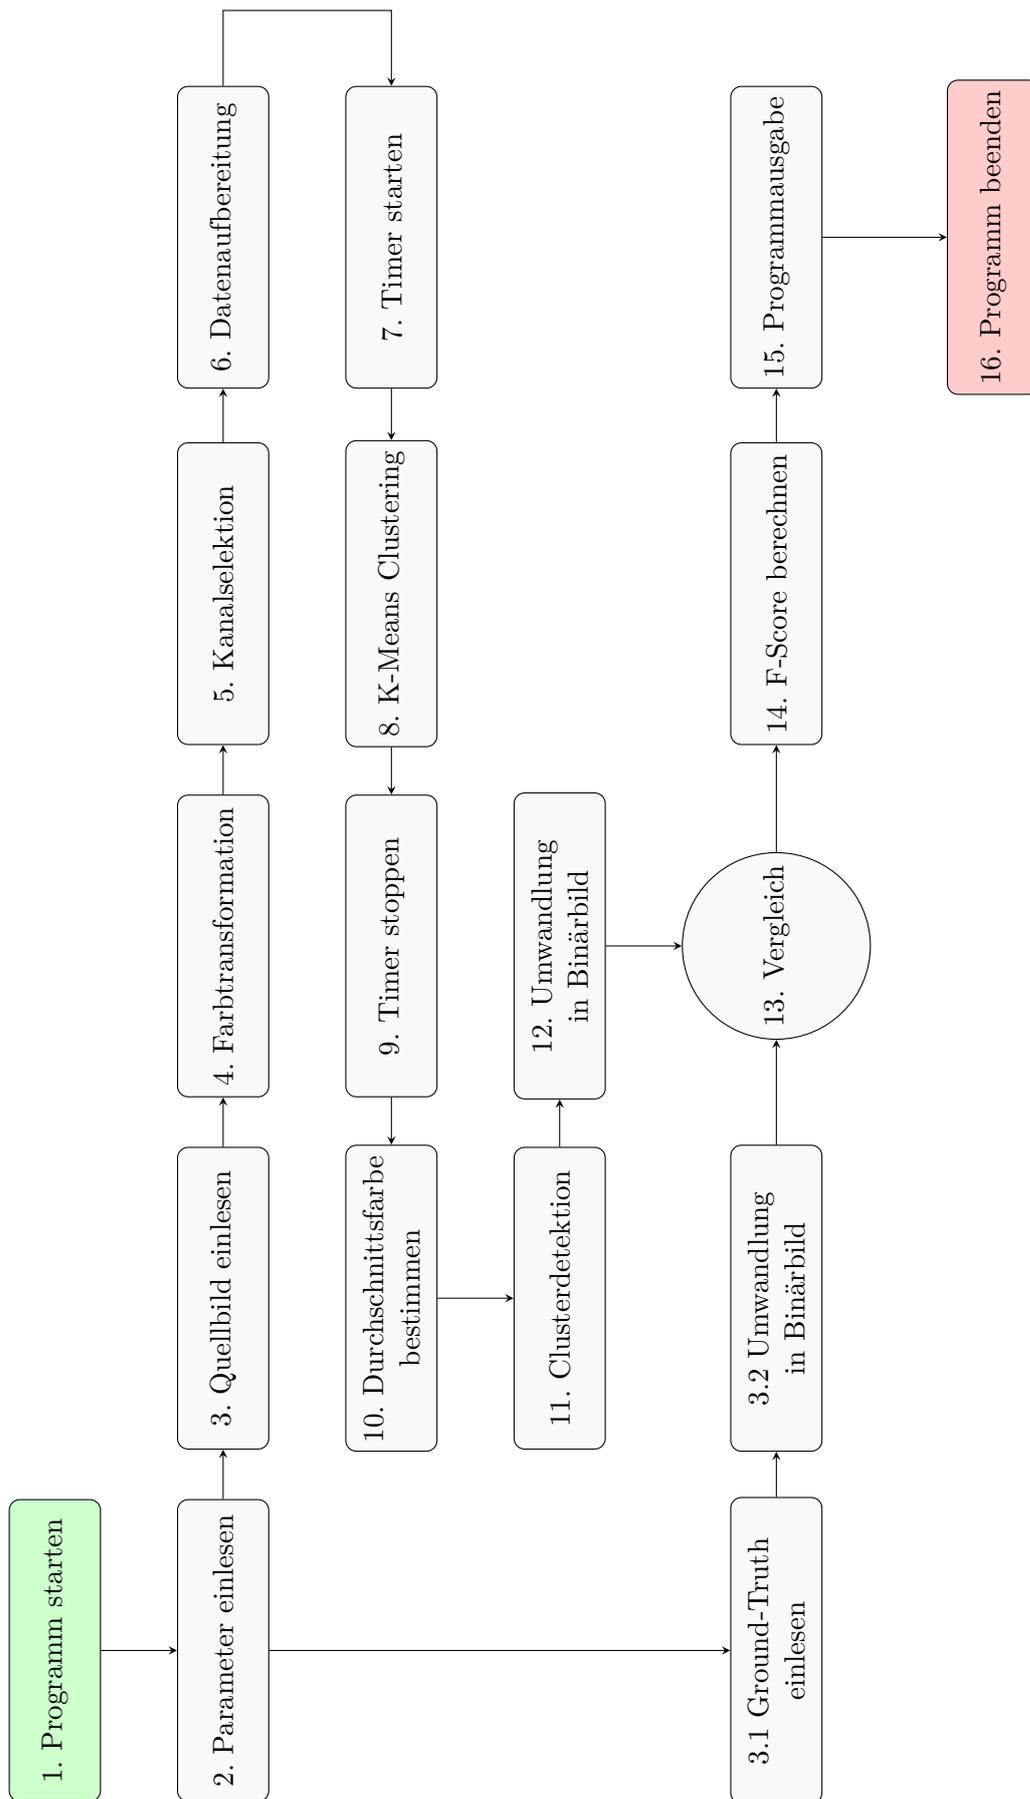


Abbildung 4.2: Programmablauf kmeans

## 4.2 Segmentierung: gmm

### Benötigte Bibliotheken:

- Boost
- openCV

### Programmparameter:

- --help: Parameterliste anzeigen
- --model: Farbraumauswahl: Lab = 1 (default), HSV = 2
- --visual: Ergebnisse auf Bildschirm darstellen
- --debug: Debug-Ausgabe aktivieren
- --src: Pfad zur zu segmentierenden Datei
- --mask: Pfad zur passenden Ground-Truth

Dieses Programm dient der Segmentierung der Daten mittels Gaussian Mixture Models aus Abschnitt 2.6.2. Der Flussplan des Programms ist in Abbildung 4.3 dargestellt. Der Grundaufbau der Programmes ist identisch mit dem Programm kmeans, weshalb hier auf eine weitere Erklärung verzichtet wird.

Der Unterschied liegt in der Wahl des Cluster-Algorithmus (8), die wie folgt implementiert wird:

---

```

1 CvEM model;
2 CvEMParams ps(n_cluster);
3
4 [...]
5
6 // reshape img and save it as samples, one line of values
7 img.reshape(1, img.rows*img.cols).convertTo(samples, CV_32FC1,
8         1.0/255.0);
9
10 // start performance test
11 // count cpu ticks and divide it through CLOCKS_PER_SEC
12 start = clock();
13
14 // do the EM thing
15 model.train(samples, Mat(), ps, &labels);
16
17 // end performance test
18 end = clock();

```

---

Aufbauend auf der aus OpenCV zur Verfügung gestellten Klasse *CvEM* werden die *samples* als Trainingssequenz übergeben. Die Anzahl der Cluster wird im Parametersatz *ps* definiert. Jedem Pixel wird in der Matrix *labels* eine ID zugewiesen. Sie dient der Schnittstelle zur weiteren Verarbeitung (Durchschnittsfarbe, Clusterdetektion etc.) und knüpft damit direkt an die Implementierung des kmeans-Programmes an.

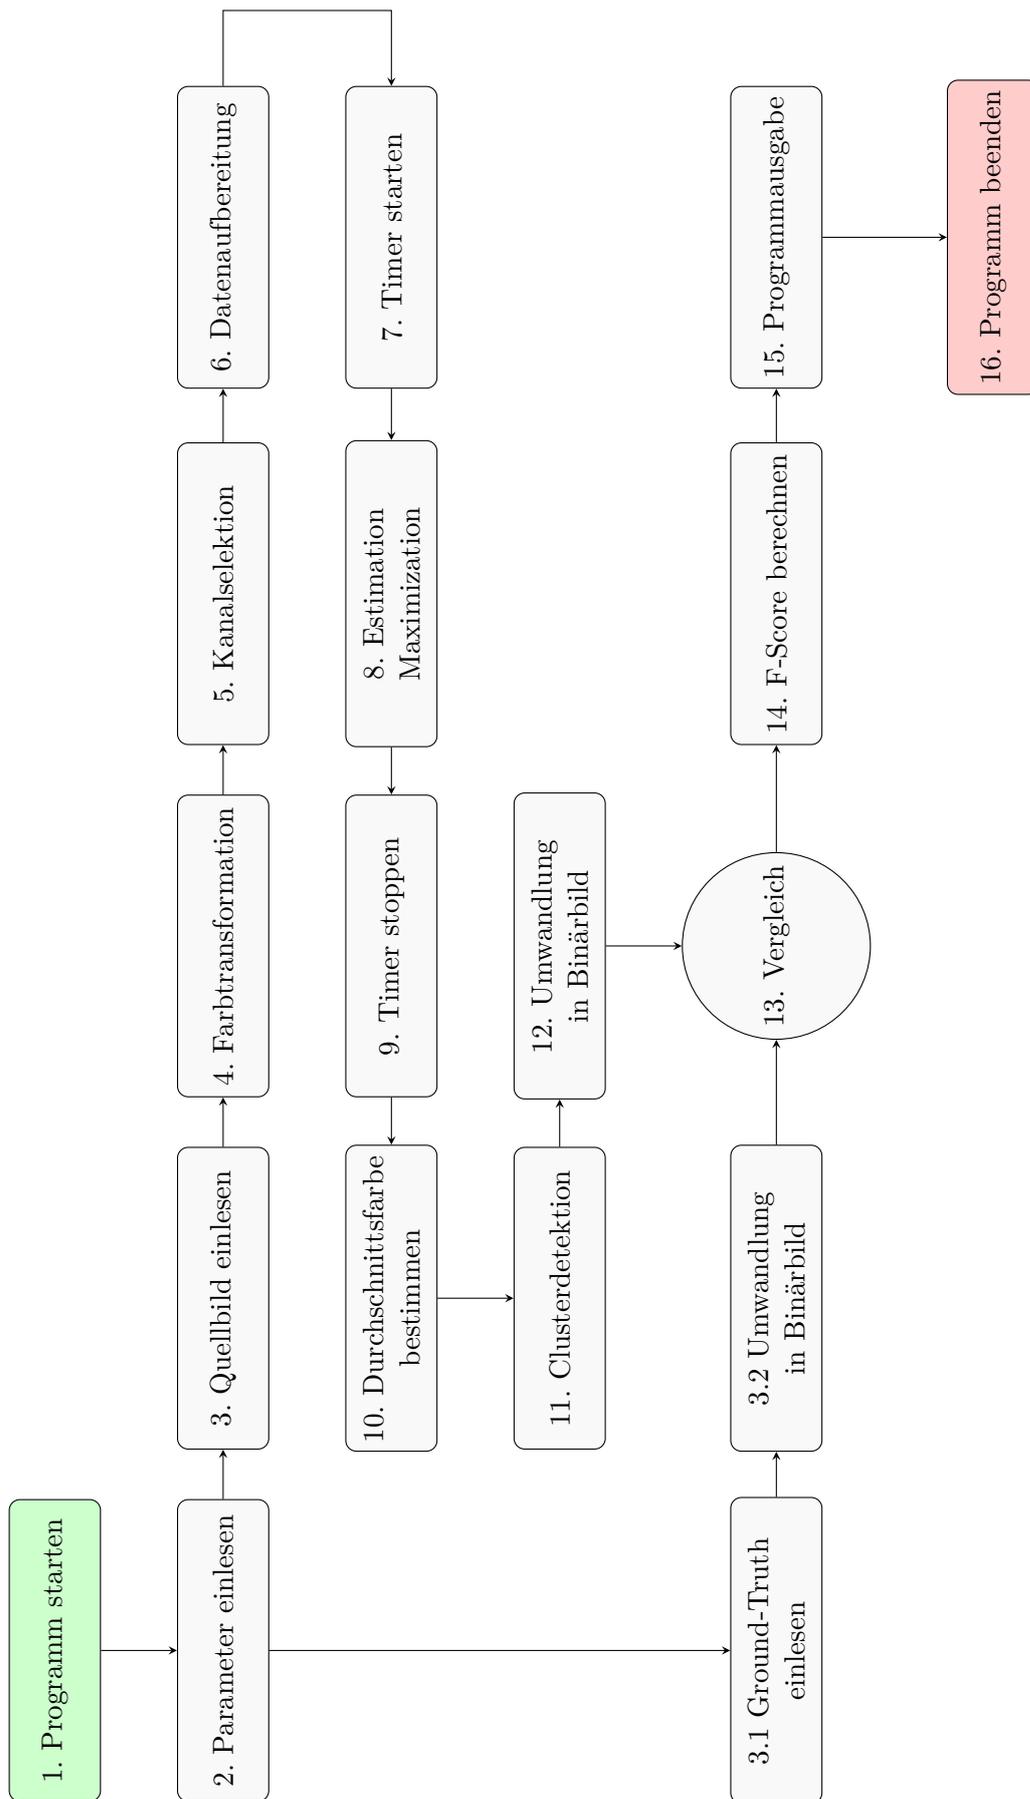


Abbildung 4.3: Programmablauf gmm

### 4.3 Berechnung: featureCalc

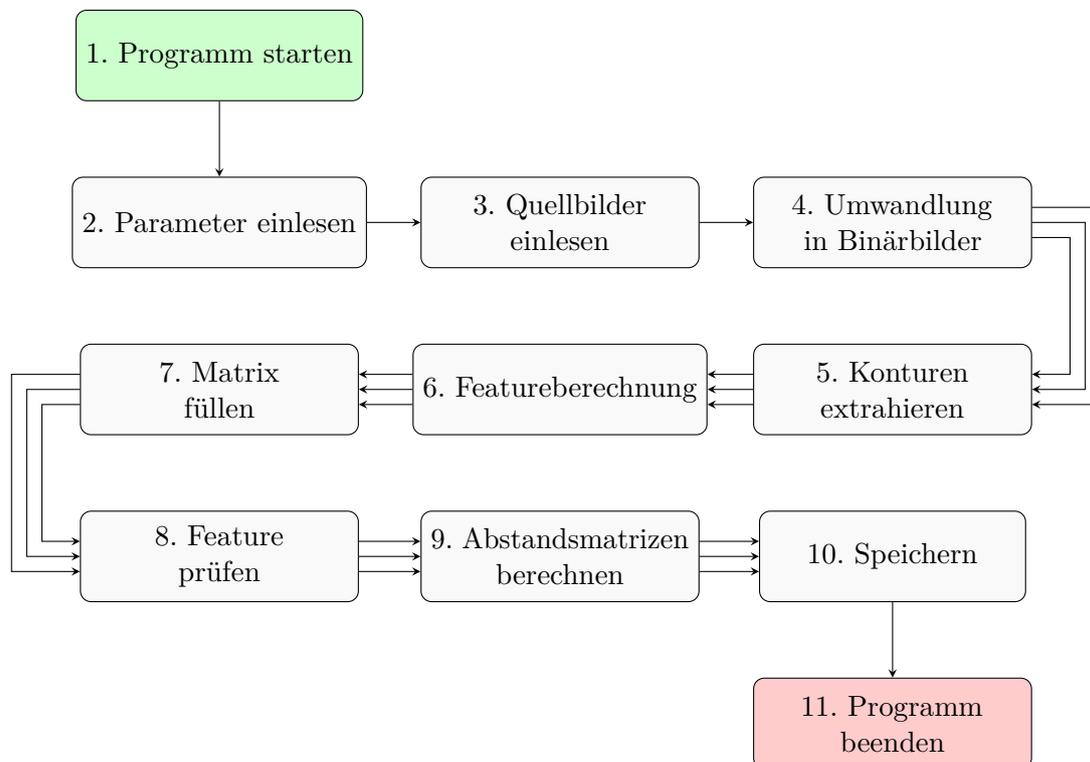
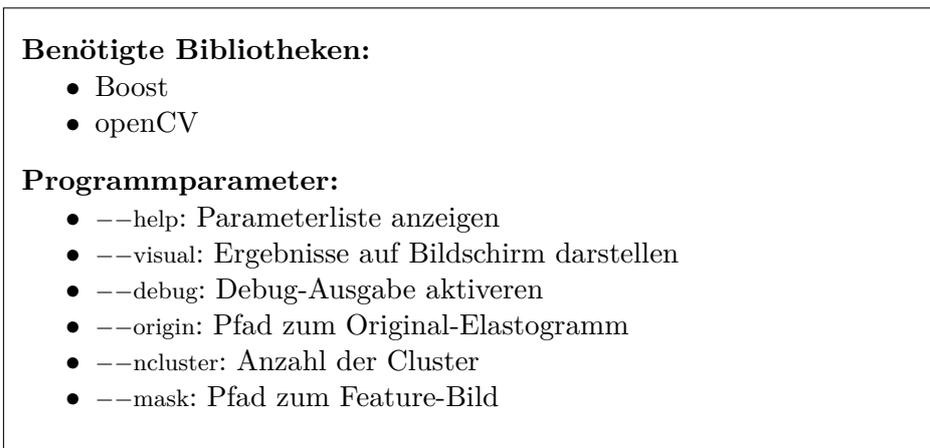


Abbildung 4.4: Programmablauf featureCalc

Im Anschluss an die Segmentierung findet die Berechnung der Bildfeatures statt. Im Folgenden werden die einzeln nummerierten Funktionsblöcke separat vorgestellt und ihre Funktionsweise erläutert.

Nach dem Starten des Programms featureCalc (1) werden wie gewohnt die Programmparameter eingelesen (2). Da nur die Segmentierungsmaske durch --mask zur Verfügung steht, im weiteren Verlauf allerdings auch Farbinformationen aus dem Ursprungsbild zur

Berechnung herangezogen werden, wird der Pfad zum Originalen Elastogramm via `--origin` ebenfalls angegeben.

Nach dem Laden der Eingangsbilder (3) wird die Segmentierungsmaske, die jedem Pixel eine eindeutige Cluster-ID zuweist, in `--ncluster` Bilder geteilt. Dies geschieht über eine einfache Schwellwertoperation, indem alle nicht auszuwählenden Cluster einfach durch zwei Schwellen zu Null gesetzt werden (4).

Nun werden iterativ für alle Cluster-Ebenen die Schritte (5)-(9) durchgeführt:

Die Konturen werden über die OpenCV-Funktion `findContours` lokalisiert, womit gleichzeitig eine Information über die Topologie des Bildes - also die Anzahl  $b$  der segmentierten Blobs<sup>4</sup> einhergeht. Für jede dieser Konturen werden nun die in Abschnitt 3.3 beschriebenen  $f$  Features berechnet. Es entstehen also pro Elastogramm  $n\_cluster$  Matrizen, mit  $b$  Spalten, sowie jeweils  $f$  Zeilen. Anders formuliert wird jede Segmentierungsebene durch eine Punktwolke in einem  $f$ -dimensionalen Raum charakterisiert.

Die Features werden größtenteils aus vordefinierten OpenCV-Funktionen generiert (`moments()`, `HuMoments()`, `contourArea()` etc.), das Verhältnis von innerer zu äußerer Elastizität bedarf allerdings einer näheren Betrachtung:

Anfangs wird um die aktuell betrachtete Kontur ein rotiertes Rechteck gelegt. Dies geschieht über Zeile 2 aus folgendem Codeabschnitt:

---

```

1 // get bounding Box
2 RotatedRect boundingBox = minAreaRect(contours[i][idx]);
3
4 // draw bounding box
5 // as rotated rectangle
6 Mat roiMask = Mat::zeros(orgImg.rows, orgImg.cols, CV_8UC3);
7
8 Point2f rect_points[4];
9 boundingBox.points(rect_points);
10 for(int j = 0; j < 4; j++) {
11     line(dst[i], rect_points[j], rect_points[(j+1)%4], color, 1,8);
12
13     // create mask from rotated Rect
14     line(roiMask, rect_points[j], rect_points[(j+1)%4], Scalar(255,
15         255, 255), 1, 8);
16 }
17 // fill rotated rectangle with white value
18 floodFill(roiMask, boundingBox.center, Scalar(255, 255, 255));

```

---

Durch die Erstellung des minimal nötigen Rechtecks, welches benötigt wird um die Kontur komplett einzuschließen, wird aus den Eckpunkten dieses Rechtecks in den Zeilen 10-15 ein weißes Rechteck in die `roiMask` gezeichnet. Diese wird anschließend via `floodfill()` komplett mit Weiß gefüllt. Abbildung 4.5 zeigt eine beispielhafte Anwendung auf ein Elastogramm, bestehend aus dem Originalbild (Abbildung 4.5(a)) und der Maske (Abbildung 4.5(b)).

Durch Verwendung der Funktionen `bitwise_and()` und `bitwise_not()`, sowie der aktuellen Kontur ist es nun möglich die einzelnen Gebiete zu isolieren.

Es ergeben sich die in Abbildung 4.5(e) und 4.5(f) dargestellten Gebiete. Aus diesen werden nun jeweils die mittleren Farbwerte gewonnen und in eine prozentuale Elastizität konvertiert. Dazu wurde die Funktion `getPercentageScore()` erstellt, in der die Elastizitätsskala (s. Punkt (3) in Abbildung 3.3) aus den Elastogrammen hinterlegt ist. Anhand der euklidischen

---

<sup>4</sup>Binary large object, zusammenhängendes Gebiet, hier: Druckgebiet

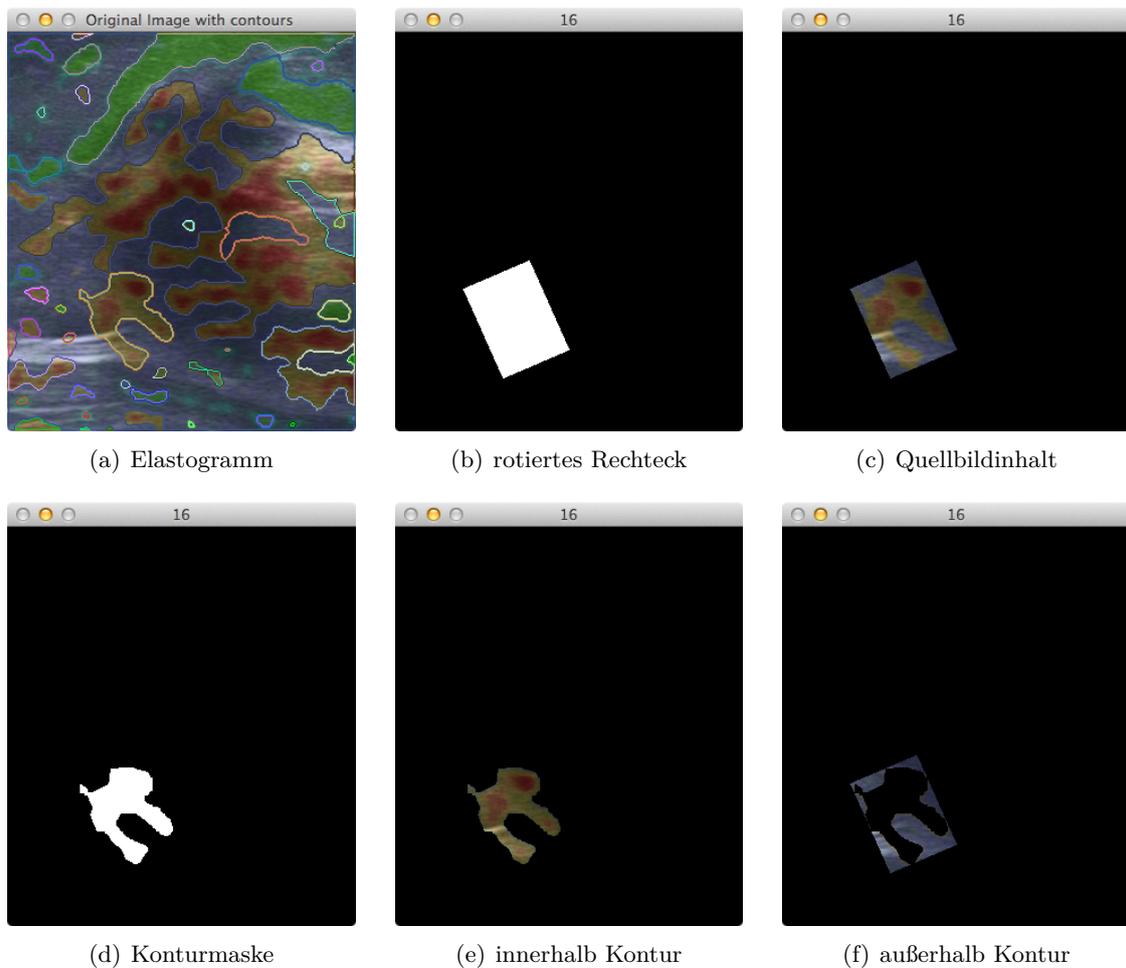


Abbildung 4.5: Konturmasken

Farbdistanz zwischen der Durchschnittsfarbe und der Elastizitätsskala wird die Farbe gewählt, die den kleinsten euklidischen Abstand zur Durchschnittsfarbe aufweist. Daraus lässt sich durch die Position der Farbe auf der Skala die prozentuale Angabe ermitteln. Dies wird sowohl für den inneren als auch den äußeren Elastizitätsbereich durchgeführt. Anschließend wird das Verhältnis beider Werte ermittelt.

Nach der Berechnung folgt in Schritt (8) die Prüfung der Features, denn sich selbst schneidende Konturen liefern keinen gültigen Schwerpunkt bzw. Flächeninhalt. Diese werden zwar in der Matrix beibehalten, jedoch wird eine Markierung in Form des Wertes  $-1$  in den Zeilen 17, 19 und 20 hinterlegt.

Damit ist die Featureberechnung abgeschlossen. Es folgt die Berechnung der Abstandsmatrizen (9) aus Abschnitt 3.3.1.

Die gewonnenen Matrizen werden abschließend im üblichen CSV-Format zur weiteren Verwendung abgespeichert (10), bevor das Programm beendet wird (11).

## 4.4 Training: trainSVM

### Benötigte Bibliotheken:

- Boost
- openCV

### Programmparameter:

- --help: Parameterliste anzeigen
- --debug: Debug-Ausgabe aktivieren
- --directory: Pfad zu den Feature-CSVs
- --mode: Reduktionsmodus der Feature-Zeilen: (0) Minimalwert, (1) Maximalwert, (2) Durchschnitt, (3) Summe
- --svmtyp: SVM-Kernel: (0) linear, (1) polynomiell, (2) radiale Basisfunktion, (3) sigmoid
- --targetlayer: Clusterebene zur Prädiktion auswählen
- --degree: Grad des Polynoms

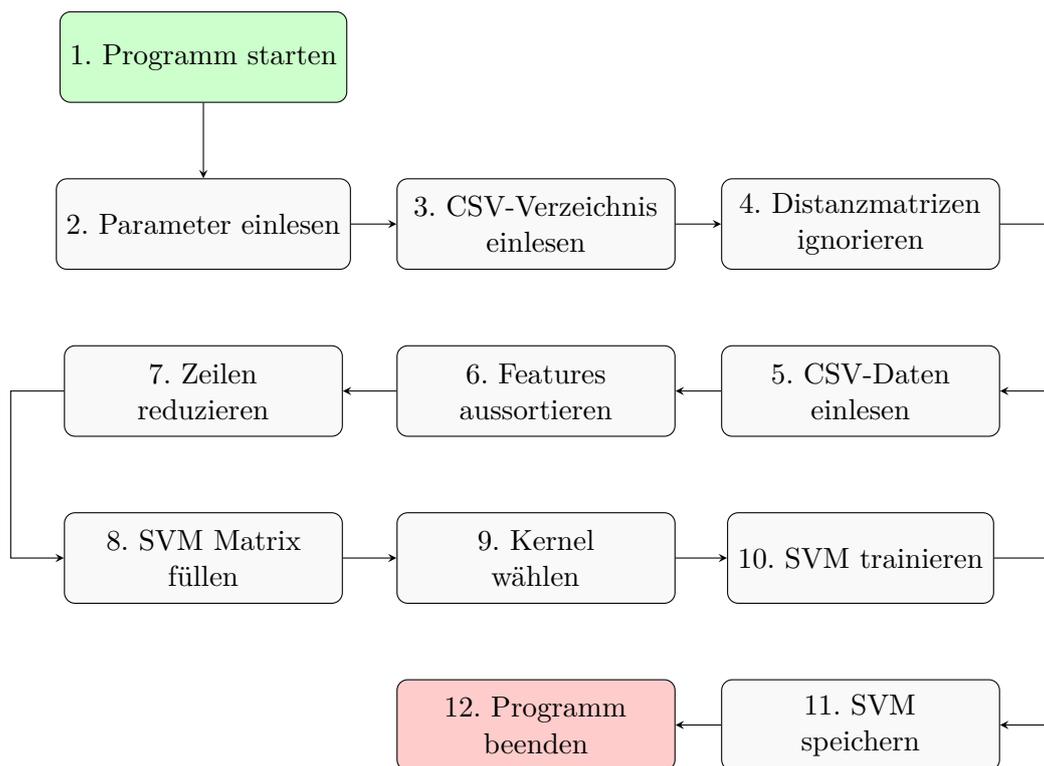


Abbildung 4.6: Programmablauf `trainSVM`

Die in der Konzeption vorgeschlagene Nutzung einer SVM zur automatischen Prädiktion des BIRAD-Scores bedarf einer Trainingssequenz, die mit dem Programm `trainSVM` durchgeführt wird. Im Folgenden werden die einzeln nummerierten Funktionsblöcke separat

vorgestellt und ihre Funktionsweise erläutert.

Nach Start **(1)** und Einlesen der Parameter **(2)** werden die in `--directory` verfügbaren CSV-Dateien gesichtet **(3)**.

Die Distanzmatrizen werden bis auf Weiteres ignoriert, sind aber in der Verzeichnisstruktur vorhanden und müssen deshalb aussortiert werden **(4)**.

Die übrig gebliebenen CSV-Dateien werden nun eingelesen **(5)** und sind somit wieder als Matrix zugänglich. Im Programm *featureCalc* wurden die ungültigen Features mit -1 markiert. Diese werden nun in Schritt **(6)** aussortiert, damit sie nicht in den Trainingsvorgang mit einbezogen werden.

Für die Trainingssequenz wird ein Repräsentativvektor pro Bild gesucht, weshalb die Feature-Matrix in geeigneter Form reduziert werden muss. Über den Parameter `--mode` werden vier unterschiedliche Modi angeboten:

1. Minimalwert der Zeile
2. Maximalwert der Zeile
3. Mittelwert der Zeile
4. Summe der Spalten.

Damit lässt sich nun ein Vektor pro Bild ableiten **(7)**, dessen Elemente wiederum in einer Matrix gesammelt werden **(8)**.

Vor dem eigentlichen Training wird noch der Kernel-Typ der SVM festgelegt **(9)**. Auch hier gibt es vier unterschiedliche Möglichkeiten, die über den Parameter `--svmtype` gewählt werden:

1. linear
2. polynomiell
3. radiale Basisfunktion
4. sigmoid.

Bei dem polynomiellen Kernel ist zudem noch der Grad des Polynoms als zusätzlicher Parameter `--degree` zu setzen.

Die Repräsentativvektoren werden nun in die Trainingsmethode der SVM eingespeist **(10)**. Nach erfolgtem Training werden die SVM-Parameter als XML<sup>5</sup>-Datei gespeichert **(11)**, bevor das Programm geschlossen wird **(12)**.

---

<sup>5</sup>Extensible Markup Language

## 4.5 Prädiktion: testSVM

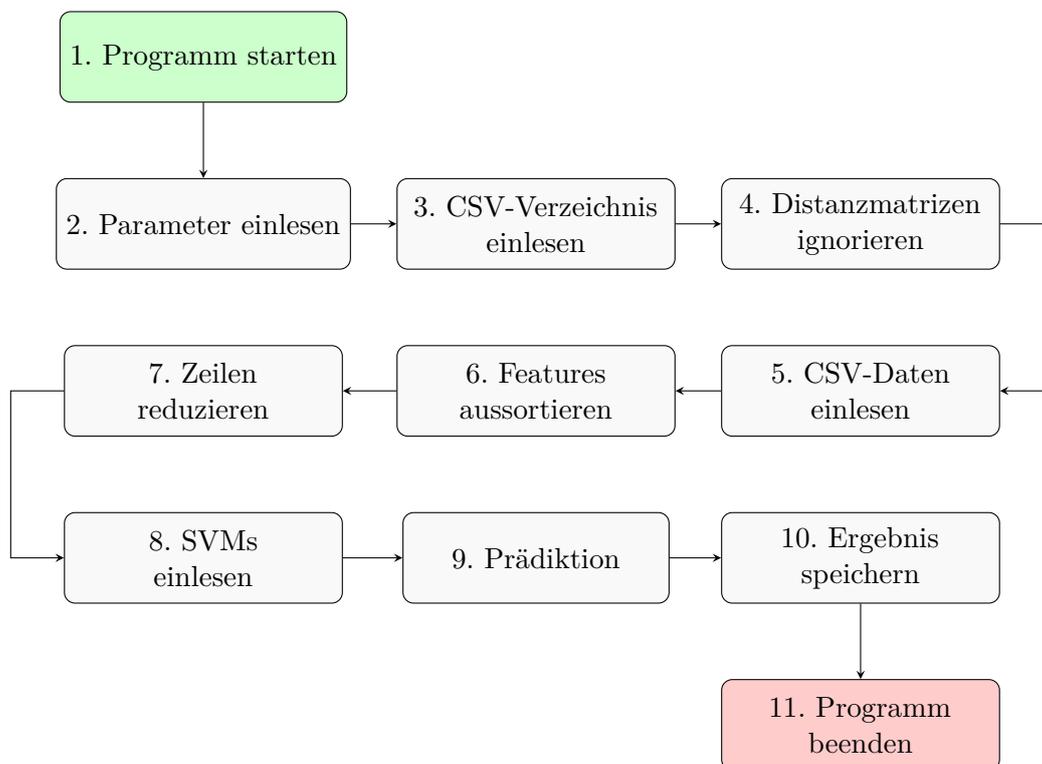
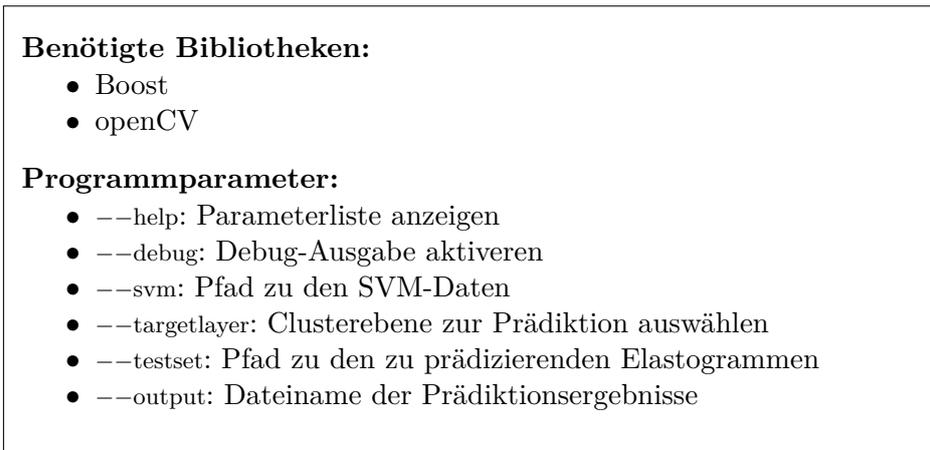


Abbildung 4.7: Programmablauf testSVM

Das Programm *testSVM* dient zur Evaluation der trainierten SVMs. Es besteht eine ähnliche Dualität zwischen *testSVM* und *trainSVM*, wie sie auch schon bei *kmeans* und *gmm* anzutreffen war. In diesem Fall beruhen die Funktionsblöcke (1)-(7) jeweils auf einer identischen Implementierung, nur dass hier die in Block (5) eingelesenen CSV-Daten aus ausgewählten Elastogrammen bestehen, die nicht Teil des Trainings gewesen sein sollten. Anknüpfend an die Vorarbeit werden in Punkt (8) die trainierten SVMs eingelesen und in

einer passenden Datenstruktur gespeichert.

Im Anschluss folgt die Prädiktion (9) der Test-Elastogramme. Dem Programm ist bekannt, mit welcher Reduktionsart die SVM trainiert wurde und führt jeweils die passende Operation auch bei den Test-Elastogrammen durch.

Abschließend werden die Ergebnisse der Prädiktionen ebenfalls in eine CSV-Datei gespeichert (10) und anschließend das Programm beendet (11).

## 4.6 Graphische Benutzeroberfläche

### Benötigte Bibliotheken:

- Qt
- openCV

Die graphische Benutzeroberfläche wird mithilfe des Model-View-Controll Modells implementiert. Jeder dieser drei Bestandteile wird in jeweils einer eigenen Klasse implementiert:

- **Model:** Elasto
- **View:** MainWindow
- **Controller:** Controller.

### 4.6.1 Model

Elasto
+ crop : Mat + image : Mat + segmentation : Mat + segmentationIDs : Mat
+ doCropping() : void + doSegmentation() : void + Elasto() - euclidianDist(point1 : Point, point2 : Point) : double + featureCalc() : void - getPercentageScore(b : uchar, g : uchar, r : uchar) : double - getMeanColor(src : Mat) : vector<double> + predictBirads() : void

Das Model beinhaltet die gesamte Programmlogik. Im Falle des Elastographie-Frameworks sind das die automatische Extraktion des Elastogramms, die anschließende Segmentierung, das Berechnen der Features, sowie Training der SVM und Prädiktion eines BI-RADS-Wertes. Die Implementierungen konnte aus den vorhergehend entwickelten Programmen übernommen werden. Im Gegensatz zu den Kommandozeilen-Programmen liegt in der GUI das Elastogramm dem Model als Variable image vor.

### 4.6.2 View

<b>MainWindow : public QMainWindow</b>
<ul style="list-style-type: none"> <li>– elastoController : Controller</li> <li>– [...] <i>GUI-Elemente</i></li> </ul>
<ul style="list-style-type: none"> <li>+ MainWindow()</li> <li># closeEvent(event : QCloseEvent*) : void</li> <li>– createActions() : void</li> <li>– createLayout() : void</li> <li>– createMenus() : void</li> <li>– createToolbars() : void</li> <li>– crop() : void</li> <li>– loadFile(fileName : const QString&amp;) : void</li> <li>– open() : void</li> <li>– Slot: about() : void</li> <li>– Slot: featureCalc() void</li> <li>– Slot: prediction() : void</li> <li>– Slot: save() : void</li> <li>– Slot: segmentate() : void</li> </ul>

Die graphische Ein- und Ausgabe wird als View bezeichnet. Sie dient der Darstellung der graphischen Elemente und stellt somit das Nutzer-Frontend dar. Sobald neue Daten vorhanden sind, werden diese dargestellt. Zudem werden Benutzeranfragen direkt an den Controller weitergeleitet.

Die dafür notwendigen *Signals* werden durch Buttons oder Menüleisteneinträge ausgelöst und an die dementsprechenden *Slots* weitergeleitet (siehe Abschnitt 3.5). Die *Slots* übernehmen anschließend die Kommunikation zum Controller.

### 4.6.3 Controller

<b>Controller</b>
<ul style="list-style-type: none"> <li>– elastoImage : Elasto*</li> </ul>
<ul style="list-style-type: none"> <li>+ Controller()</li> <li>+ ~Controller()</li> <li>+ setImage(qimg : QImage*) : void</li> <li>+ getImage() : QImage</li> <li>+ getCrop() : QImage</li> <li>+ getSegmentation() : QImage</li> <li>+ doCropping() : void</li> <li>+ doSegmentation() : void</li> <li>+ doFeatureCalc() : void</li> <li>+ predictBirads() : void</li> </ul>

Der Controller stellt das Bindeglied zwischen Model und View dar. Sobald die View eine Benutzeranfrage an den Controller stellt, führt dieser die damit verbundenen Methoden aus dem Model aus.

Um die zu erfüllen, besitzt der Controller eine Instanz des Models, hier elastoImage genannt. Dieses Objekt ist aufgrund seiner private-Eigenschaft nur durch die public-Methoden des

### Controllers veränderbar

Aufgrund dieser Struktur ist die View nun unabhängig von den anderen Komponenten austauschbar. Ebenso verhält es sich mit dem Model: Neue Funktionen können schnell eingebaut und müssen gegebenenfalls lediglich über den Controller verknüpft werden, womit die geforderte Trennung der Komponenten gewährleistet ist.

Ein Screenshot der fertigen Benutzeroberfläche ist in Abbildung 4.8 gezeigt. Es wurde besonders darauf geachtet eine einfache Benutzerführung zu realisieren. Die linksseitigen Buttons können nacheinander betätigt werden, sodass eine Berechnung ohne gültige Eingangsdaten nicht möglich ist.

Die Ergebnisse werden identisch zum Programm *featureCalc* aus Abschnitt 4.3 als CSV gespeichert und können somit ebenfalls zum Trainieren einer weiteren SVM benutzt werden.



Abbildung 4.8: Hauptfenster elastoGUI

## 5 Evaluation

Mithilfe der erstellten Ground-Truth-Daten werden die entstandenen Programme, sowie die vorgeschlagenen Algorithmen im Zusammenspiel mit Elastographie-Daten untersucht.

### 5.1 Segmentierungsverfahren

Die Segmentierungsprogramme *kmeans* aus Abschnitt 4.1 und *gmm* aus Abschnitt 4.2 werden mithilfe des Skriptes *testSegmentation.sh* auf die Elastogramme angewandt. Dabei wird die Segmentierung  $n$ -Mal durchgeführt und anschließend mit der Ground-Truth verglichen. Durch die Variation der Farbmodelle (HSV und Lab) entstehen vier unterschiedliche Segmentierungsarten.

In Tabelle 5.1 sind die Messergebnisse von F1-Score und Berechnungszeit repräsentiert durch Mittelwert und Varianz aufgetragen. Die vollständigen Messergebnisse befinden sich im Anhang A.5.

Tabelle 5.1: Messergebnisse der Segmentierungsverfahren

$n = 100$		<b>F1-Score</b>		<b>Berechnungszeit [s]</b>	
<b>Verfahren</b>	<b>Farbraum</b>	<b>Mittelwert</b>	<b>Varianz</b>	<b>Mittelwert</b>	<b>Varianz</b>
K-Means	HSV	0,8137	0,0141	0,1547	0,0090
K-Means	Lab	0,8714	0,0019	0,1068	0,0022
GMM	HSV	0,8827	0,0020	1,4744	0,7812
GMM	Lab	0,8530	0,0136	1,312	0,6740

Die Entscheidung für eine Kombination wird anhand einer Kombination von F1-Score und Berechnungszeit ermittelt. Bei Verfahren K-Means ist die Kombination K-Means/Lab zu wählen, da sowohl F1-Score höher als auch die Berechnungszeit niedriger ist. Auch die Varianz der beiden Werte ist geringer.

Bei der Segmentierung mittels GMM setzt sich klar die Kombination aus GMM/HSV durch.

Vergleicht man die vorselektierten Kombinationen K-Means/Lab und GMM/HSV miteinander, stößt man nur auf geringe Differenzen. Die F1-Scores variieren bei der hier gewählten Genauigkeit um 0,0113 zu Gunsten der Kombination GMM/HSV.

Die Latenzanalysen bieten klarere Differenzierungsmöglichkeiten: Mit einer 14-fach höheren Berechnungsdauer von GMM/HSV im Vergleich zu K-Means/Lab steht hier eine klare Präferenz der Kombination aus K-Means/Lab fest.

Unter Vernachlässigung der geringen Abweichung des F1-Scores überwiegt die schnelle Berechnungszeit bei der Kombination aus K-Means/Lab. Die Segmentierung dieser Kombination wird in den weiteren Tests als Referenz genommen, sowie in der graphischen Benutzeroberfläche eingebaut. Eine beispielhafte Segmentierung ist in Abbildung 5.1 dargestellt.

Die Messergebnisse der Kombination aus K-Means/Lab ausgeführt auf den kompletten Datensatz sind in Abbildung 5.2 aufgeführt.

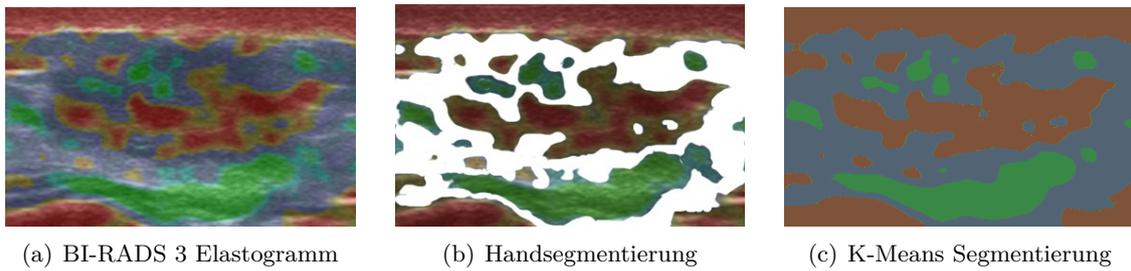
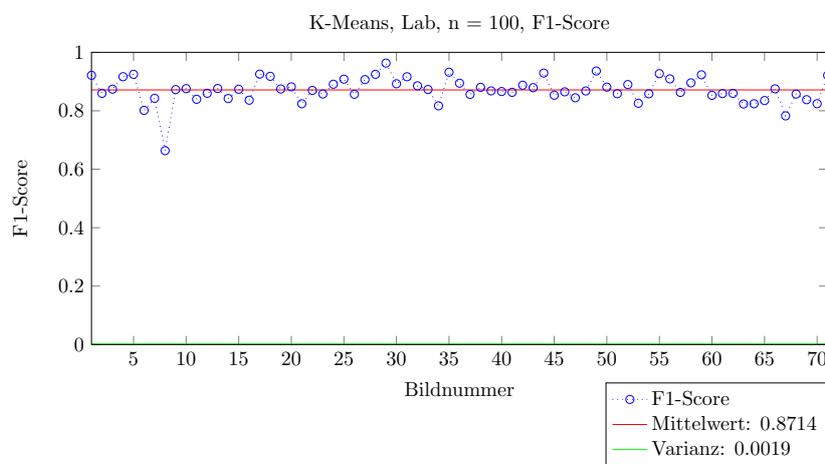
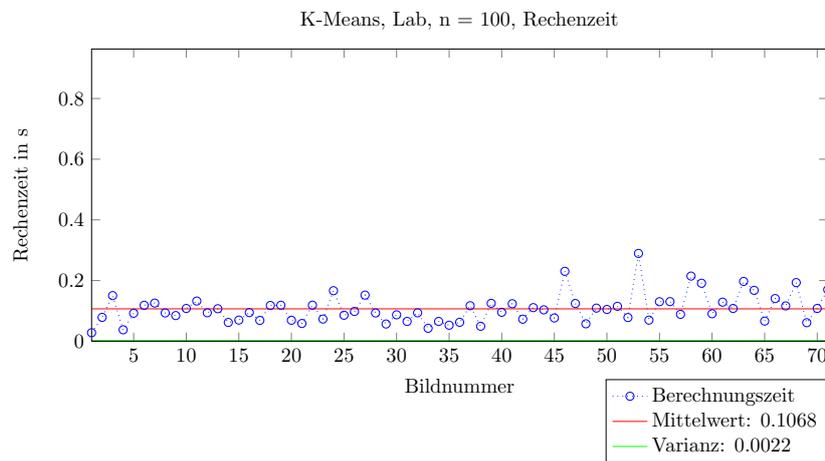


Abbildung 5.1: Segmentierung durch K-Means-Clustering



(a) F-Score



(b) Rechenzeit

Abbildung 5.2: Segmentierung der Testdaten mittels K-Means-Clusterings im Lab-Farbmodell

## 5.2 Verteilung der Features

Die graphische Ausgabe der berechneten Features lässt auf eine sehr breite Streuung schließen. In Abbildung 5.3 sind exemplarisch einige Feature-Verteilungen aufgetragen. Es wurden dabei auf der Abszisse die Werte der Features aufgetragen und auf der Ordinate die zum berechneten Feature zugehörige BI-RADS-Klasse.

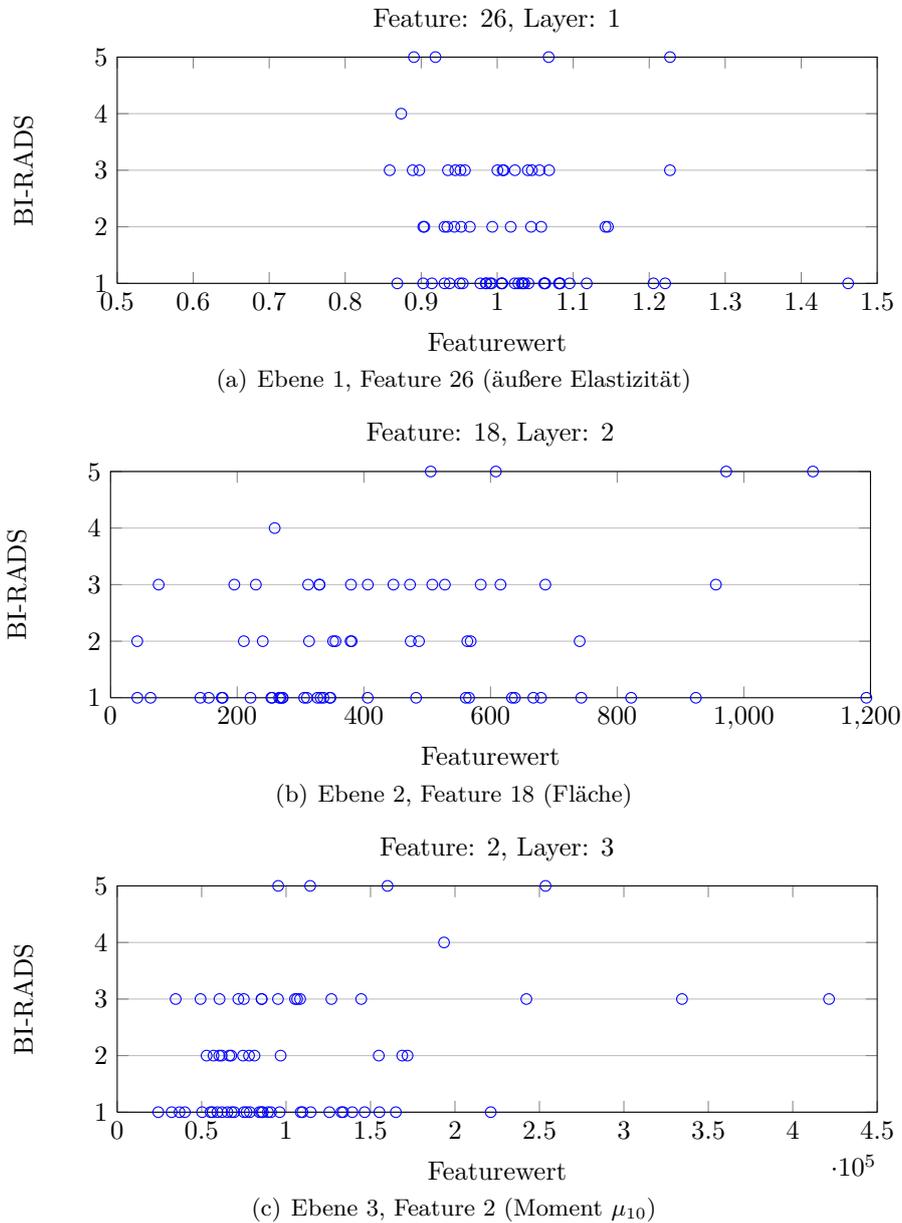


Abbildung 5.3: Werteverteilung beispielhafter Features

Auch wenn die Verteilung der Testdaten nicht optimal ist, so kann man sehen, dass eine einfache Trennung durch Wertebereiche keine gültige Prädiktion liefern kann.

### 5.3 Prädiktion durch SVM

Die Prädiktion wurde mithilfe des Programmes *testSVM* aus Abschnitt 4.5 durchgeführt. Die Testdaten bestehen aus 71 Elastogrammen, wobei je ein Elastogramm pro Klasse herausgenommen wird. Die Features der 66 verbleibenden Elastogramme werden dem Programm *trainSVM* aus Abschnitt 4.4 zum Trainieren der SVMs zugeführt. Es entstehen insgesamt 31 unterschiedliche SVMs, wobei der Typ linear und polynomiell erster Ordnung als identisch angesehen werden.

Im Anschluss nutzt das Programm *testSVM* die trainierten SVMs um die BI-RADS-Klassen der fünf gesonderten Elastogramme zu präzisieren. Das Ergebnis der Prädiktion ist in Tabelle A.6 aufgeführt.

In Tabelle 5.2 sind die Prädiktionstreffer der unterschiedlichen Trainingsverfahren pro Ebene zusammengefasst. Ersichtlich ist, dass in Ebene eins 16 (51,6%), in Ebene zwei sogar 17 (54,8%) der SVMs Klasse eins korrekt erkannt haben. Die Klassen zwei bis vier erfahren keine gute Prädiktion, wohingegen Klasse fünf mit bis zu 15 (48,4%) Treffern vergleichbar gut abschneidet.

Die Kernel Radial Basis Funcion (RBF), sowie Sigmoid liefern mit dieser verwendeten Konfiguration keinerlei verwendbare Prädiktion.

Die polynomiellen Kernel wurden bis zum Grad zehn simuliert, allerdings hier nur bis fünf aufgeführt, da bereits ab dem Grad vier ein Zusammenfall der Prädiktionsergebnisse ersichtlich ist.

Tabelle 5.2: Auswertung der korrekt präzisierenden 31 unterschiedlichen SVMs

<i>31 SVMs</i>	BI-RADS				
	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>
<b>Ebene 0</b>	16	2	1	0	14
<b>Ebene 1</b>	17	0	1	1	11
<b>Ebene 2</b>	11	5	2	0	15

Zusammenfassend lässt sich sagen, dass auf Basis der aktuellen Datenlage, wie sie in Abbildung 3.2 dargelegt ist, keine verlässliche Prädiktion durchführbar ist. Erst eine Wiederholung des Tests mit gleichverteilten Testdaten, sowie einer ausreichenden Anzahl an Verifikationsbildern könnte eine Entscheidung über die Auswahl des SVM-Trainings herbeiführen.

### 5.4 GUI-Workflow

Die in Abschnitt vorgestellte graphische Benutzeroberfläche dient der Erweiterung der Trainingsdatenbank. So könnten beispielsweise einfach Daten aus mehreren medizinischen Institutionen gesammelt werden. Zusammen mit einer Referenzdiagnose könnte somit die momentane Verteilung des Testdatensatzes aufgefüllt werden. Ein Vorteil dieser dezentralen Sammlung ist die ausbleibende depersonalisierung der Elastogramme, da jeder Teilnehmer die relevanten Trainingssätze selbst generieren kann.

Ein typischer Workflow zur Erstellung eines Featuresatzes ist in Abbildung 5.4 dargestellt. Nach dem Programmstart (siehe Abbildung 5.4(a)) wird ein Elastogramm eingelesen (siehe Abbildung 5.4(b)) und angezeigt (siehe Abbildung 5.4(c)). Mit der fortschreitenden

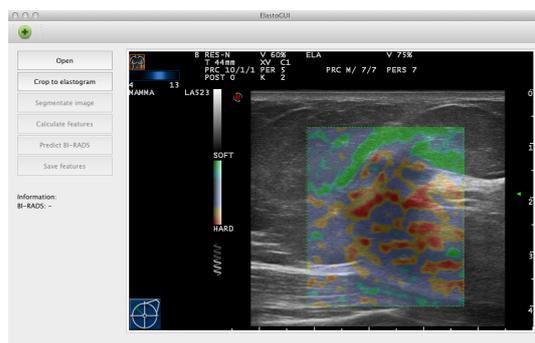
Benutzerinteraktion schalten sich die linksseitigen Buttons nacheinander zur Bedienung frei. Nach der Durchführung des automatischen Croppings in Abbildung 5.4(d) ist die Segmentierung ausführbar. Das Ergebnis wird anschließend im Hauptfenster angezeigt (siehe Abbildung 5.4(e)). Die Berechnung der Features erfolgt im Hintergrund und wird mit dem Freischalten des nächsten Buttons quittiert (siehe Abbildung 5.4(f)). Zur Prädiktion werden die berechneten Features der hinterlegten SVM zugeführt, die anschließend eine Prädiktion durchführt und das Ergebnis zum einen als Message Box (siehe Abbildung 5.4(g)) und zum anderen unter den Buttons darstellt. Die berechneten Features können abschließend als CSV gespeichert werden (siehe Abbildung 5.4(h)). Die Bedienung gestaltet sich somit sehr einfach und effizient.



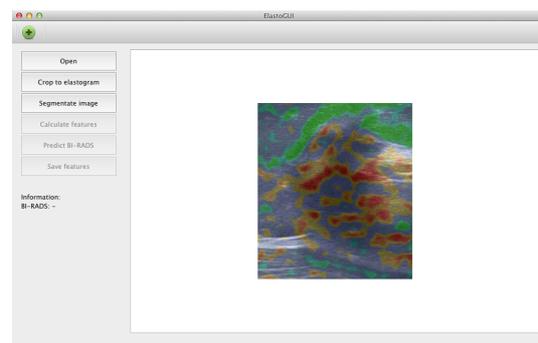
(a) Programmstart



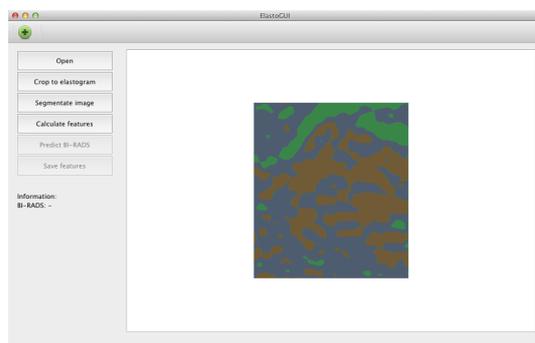
(b) Elastogramm öffnen



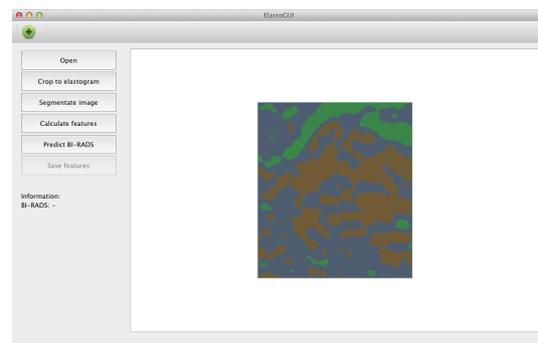
(c) Elastogramm



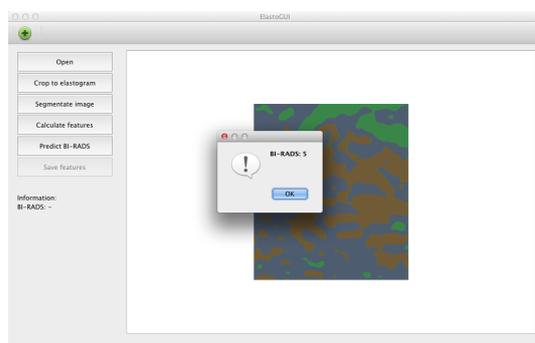
(d) Automatischer Crop



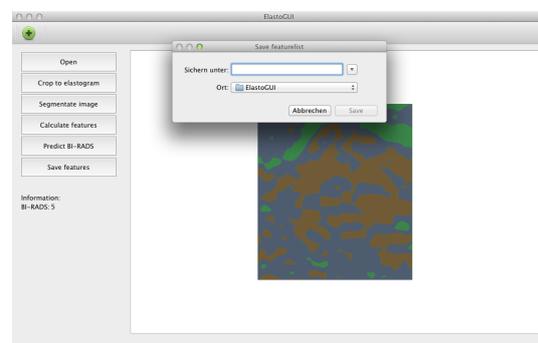
(e) Segmentierungsergebnis



(f) Featureberechnung



(g) BI-RAD Prädiktion



(h) Ergebnisse speichern

Abbildung 5.4: GUI-Workflow

## 6 Zusammenfassung

Diese Studienarbeit befasst sich mit der automatisierten Klassifizierung von Elastographie-Daten in der Mammadiagnostik. Entstanden ist ein Framework, das gestattet, anhand von medizinischen Befunden und deren zugrunde liegenden Elastogrammen ein Training eines Klassifikators zur Bewertung von Elastographie-Daten durchzuführen und dieses im Anschluss zu testen.

Im ersten Teil der Arbeit werden die technischen und medizinischen Grundlagen für den weiteren Verlauf vorgestellt.

Im medizinische Teil wird die anatomische Beschreibung der weiblichen Brust in Abschnitt 2.1.1, sowie deren Krankheitsbilder in Abschnitt 2.1.2 erläutert. Das BI-RAD-System wird in Abschnitt 2.1.3 vorgestellt, mit dem eine Klassifizierung der Erkrankung möglich ist. Zudem wird die Elastographie hinsichtlich Standardisierung und Verbreitung in der Ärzteschaft in Abschnitt 2.3.2 untersucht.

Die technischen Grundlagen fokussieren sich zum einen auf die Bildgebung via Ultraschallwellen und zum anderen auf ausgewählte Themen aus dem Bereich Computer Vision. Hier wird auf die unterschiedlichen Farbmodelle eingegangen, sowie verschiedene notwendige Operatoren der Bildverarbeitung erläutert. Abschnitt 2.6 stellt den K-Means-Algorithmus und die Gaussian Mixture Models als Segmentierungsverfahren vor. Der technische Abschnitt endet mit der Einführung von Support Vector Machines.

Das sich anschließende Kapitel 3 widmet sich der Konzeption eines Software-Frameworks zur automatischen Klassifizierung. Angefangen mit der Segmentierung der Elastogramme (Abschnitt 3.2), über die Berechnung von repräsentativen Features (Abschnitt 3.3), bis hin zur plattformunabhängigen, graphischen Benutzeroberfläche (Abschnitt 3.5) werden alle Konzeptschritte erläutert. Um den Konzeptansatz zu prüfen, wurde im Rahmen der Studienarbeit ein aus 71 Elastogrammen bestehender Testdatensatz erstellt, der neben einer medizinischen Fachdiagnose eine vollständige Handsegmentierung enthält und somit als Referenzdatensatz nutzbar ist.

Der folgende Implementierungsteil in Kapitel 4 stellt die einzelnen, elementaren Programmteile des Frameworks vor. Neben den Segmentierungsprogrammen werden die Featureberechnung, das Trainingsprogramm sowie ein Prädiktionsprogramm vorgestellt. Diese Programme sind im Zuge einer framework-orientierten Konzeption auf Stapelverarbeitung ausgelegt. Die benötigten Skripte werden im Anhang A.4 erläutert und sind Teil der Studienarbeit. Der Zeitaufwand zur Analyse eines neuen Testsatzes von Elastogrammen wird damit erheblich reduziert.

In der abschließenden Evaluation wird anhand von Qualitäts- und Latenzanalysen gezeigt, dass das Segmentierungsverfahren K-Means-Clustering für die Segmentierung am besten geeignet ist.

Die Auswertung der extrahierten Featuredaten wird durchgeführt und für exemplarische Features graphisch dargestellt.

Abschließend wird im Abschnitt 5.3 eine Support Vector Machine trainiert und mit verschiedenen Elastogrammen getestet. Mit dem momentan Referenzdatensatz ist es aufgrund der zu geringen Anzahl an Trainingsdaten nicht möglich, eine verlässliche Klassifizierung

---

vorzunehmen. Durch die Vorstellung des GUI-Workflows in Abschnitt 5.4 wird versucht, diese Lücke durch eine einfache Möglichkeit der Datensammlung zeitnah zu schließen. Im abschließenden Ausblick werden mögliche Lösungsansätze und weitere Forschungsthemen vorgestellt, um die Klassifizierung und automatisierte Bewertung von Elastographie-Daten verlässlich zu machen.

## 7 Ausblick

Die vorliegende Arbeit schafft einen Überblick über die Elastographie, lässt aber noch keine zuverlässige Klassifizierung zu. Um dies zu erreichen, müssen verschiedene Teilbereiche erweitert werden: Am Anfang ist die Komplettierung der Ground-Truth zu nennen. Mit der momentanen Datenlage ist kein faires Training der SVMs möglich. Ferner ist eine tiefgreifende statistische Analyse der berechneten Features durchzuführen, um relevante Features herauszustellen. Ein anderer Ansatz könnte eine Leave-one-out-Analyse der Features mit dem gleichen Ziel sein.

Eine Auswahl der Features unter medizinischen Gesichtspunkten sollte ebenfalls geprüft werden. Durch die fehlende Verbreitung und Standardisierung ist es allerdings schwierig, erfahrene Diagnostiker zu finden. Mithilfe derer könnten Läsionen mit Formen auf dem Elastogramm in Verbindung gebracht werden. Der Nutzen einer solchen Datenbank könnte z.B. via eines Shape-Matchings genutzt werden, um weitere Befunde zu lokalisieren.

Im Bereich des Trainings der SVM ist zu untersuchen, ob ein binäres Training eine bessere Klassifizierung bieten kann. Dazu wird für jede BI-RADS-Klasse eine eigene SVM trainiert, die im Anschluss jeweils eine eigene Prädiktion der Eingangsfeatures vornehmen kann.

Je nach Nutzungsgrad der Testroutinen und der graphischen Benutzeroberfläche könnte eine komplette graphische Implementierung des Trainingsvorgangs, also der gesamten Stapelverarbeitung, einen weiteren Schritt in Richtung verlässlicher Klassifikation bieten.

Die Möglichkeit ein bildgebendes Verfahren zu entwickeln, welches ohne ionisierende Strahlen auskommt, ist es wert, weiter erforscht zu werden. Augenscheinlich gibt es laut den verschiedenen Studien einen erfolgreichen medizinischen Nutzen in der Mammadiagnostik. Es mangelt allerdings an der Schulung der Ärzte. Mit einem verlässlichen System zur automatischen Klassifizierung kann ihnen zwar nicht die Diagnostik abgenommen, zumindest aber eine Hilfe geboten werden.

Diese Studienarbeit trägt einen nötigen Teil dazu bei, dem Verfahren der Elastographie zu mehr Beachtung und einfacherer Benutzung zu verhelfen. Mithilfe von ausführlichen medizinischen Studien ist nun zu prüfen, wie und in welchem Umfang diese hier vorgestellten Ansätze zu verwenden und zu erweitern sind.

# Anhang

## A.1 Telefonprotokoll

Dem Telefonat vorhergehende E-Mail:

**Von:** Balke, Stefan  
**An:** Brustkrebs Info e.V.  
**Gesendet:** Mittwoch, 13. März 2012  
**Betreff:** Kontaktanfrage  
Sehr geehrte Damen und Herren,

im Rahmen meiner Studienarbeit untersuche ich Elastogramme.  
Für mein Grundlagenkapitel möchte ich die unterschiedlichen Sonographiebefunde der Brust darstellen.

Auf Ihrer Seite:

<http://www.brustkrebs-info.de/patienten-info/index.php?id=5.3.1&stat=open&substat=open>

Stellen Sie das sehr gut und bündig dar.

Ich würde das gerne verwenden und fragen, ob Sie das verwendete Bildmaterial zur Verfügung stellen, falls möglich auch gerne hochauflösend. Natürlich unter Angabe der Quelle.

Drei fachliche Fragen habe ich noch:

- Warum wird die Sonographie nur bis zur Menopause durchgeführt?
- Wie sieht eine Mastopathie auf einem Ultraschallbild aus? Ist es immer differenzierbar von einem Karzinom? Hätten Sie dafür ein Beispielbild?
- Eine Form der PMS ist die Verhärtung der Brust durch Wassereinlagerungen, als Symptom Mastodynie, korrekt?  
Ist das sonographisch zur Mastopathie unterscheidbar?

Abschließend: Inwiefern wird die Elastographie zur Diagnostik angewendet?  
Wie schätzen Sie die Chancen dieses Verfahrens ein?

Herzlichen Dank für Ihre Antworten und danke für Ihre informativen Seiten.

Freundliche Grüße  
Stefan Balke

**Anschließendes Telefonat vom 15.03.2012 mit Herrn Dr. med. H.-J. Koubenec,  
Gynäkologe:**

*Verbreitung Elastographie:*

- keine Verbreitung
- selbst Doppler-Sonographie setzt sich nicht richtig durch
- Ärzte können oftmals schlecht deuten

*Sonographie bis zur Menopause:*

- wird danach weitergeführt, kein Stopp nach Menopause
- Mammographie bei jungen Patienten undurchsichtig
- mit zunehmenden Alter durch normale Fettzunahme wird die Brust fett-transparent (gut durchsichtig)

*Standarduntersuchung:*

- Abtastung der Brust
- Ultraschall-Tastkopf über Brust lenken
- Bei Befund Schallkopf über Befund positionieren, anschließend mit dem Finger über Rand des Befundes streichen um somit Einbettung im Gewebe festzustellen

## A.2 E-Mail der DEGUM

**Von:** Balke, Stefan  
**An:** Degenhardt, Prof. Dr. med. Dr. h. c. Friedrich  
**Gesendet:** Mittwoch, 12. Oktober 2011 12:24  
**Betreff:** Guideline Elastographie

Sehr geehrter Dr. Degenhardt,

im Rahmen einer Studienarbeit im Bereich der Nachrichtentechnik evaluiere ich gerade Möglichkeiten zur Hilfestellungen durch Bildverarbeitungsalgorithmik für den untersuchenden Arzt.

Gibt es von der DEGUM schon eine Richtlinie bezgl. des Einsatzes von Elastogrammen zur Brustkrebsprävention?

Freundliche Grüße  
Stefan Balke

---

**Von:** Degenhardt, Prof. Dr. med. Dr. h. c. Friedrich  
**An:** Balke, Stefan  
**Empfangen:** Mittwoch, 22. Oktober 2011 12:51  
**Betreff:** RE: Guideline Elastographie  
Sehr geehrter Herr Balke,

vielen Dank für die Anfragen. Es gibt noch keine Richtlinien der DEGUM, da die Elastographie noch nicht ausreichend im Rahmen der Brustdiagnostik überprüft worden ist.

Viele Grüße  
F. Degenhardt

### A.3 E-Mail der AGO-Kommission-Mamma

**Von:** Balke, Stefan  
**An:** Scharl, Prof. Dr. Anton  
**Gesendet:** Mittwoch, 12. Oktober 2011 12:02  
**Betreff:** Guideline Elastographie

Sehr geehrter Prof. Scharl,

im Rahmen einer Studienarbeit im Bereich der Nachrichtentechnik evaluiere ich gerade Möglichkeiten zur Hilfestellungen durch Bildverarbeitungsalgorithmik für den untersuchenden Arzt.

Gibt es von der AGO-Kommission-Mamma schon eine Richtlinie bezgl. des Einsatzes von Elastogrammen zur Brustkrebsprävention?

Freundliche Grüße  
Stefan Balke

---

**Von:** Scharl, Prof. Dr. Anton  
**An:** Balke, Stefan  
**Empfangen:** Mittwoch, 12. Oktober 2011 12:31  
**Betreff:** RE: Guideline Elastographie  
Nein, Herr Balke, bisher nicht.

Elastogramme sind keine etablierte Diagnostik.

Beste Grüsse  
A. Scharl

## A.4 Verwendung der Testroutinen

Zur Automatisierung der Programme sind einige BASH<sup>1</sup>-Skripte entstanden. Um Missverständnisse bei der Bedienung vorzubeugen, ist diese hier kurz erläutert:

- **testSegmentation.sh:**

*Benutzte Programme:*

- kmeans
- gmm

*Parameter:*

- h: Hilfe
- a: Algorithmus wählen (kmeans oder gmm)
- i: Anzahl der Iterationen
- l: Pfad zum CSV-Logfile
- m: Farbmodell wählen (1 = Lab, 2 = HSV)

*Optionen im Skript Quelltext:*

- truth=GroundTruth/01\_Crops, Pfad zu den ausgeschnittenen Elastogrammen
- dmask=GroundTruth/02\_Segmentation, Pfad zu den handsegmentierten Elastogrammen

Dieses Skript ermöglicht die mehrfache Ausführung der Segmentierungsalgorithmen anhand einer gegebenen Ground-Truth. Es öffnet alle sich im Ordner *truth* befindlichen Elastogramme und lässt sie segmentieren. Danach speichert es die arithmetisch gemittelte Zeit, sowie den F1-Score in einer CSV-Logfile. Die Auswertung kann mit dem Matlab-Skript *plotSegmentationData.m* erfolgen, welches ebenfalls auf der CD beiliegt.

*Beispiel:*

---

```
./testSegmentation.sh -a kmeans -i 100 ...  
-l kmeans_100_lab.csv -m 1
```

---

- **doWholeSegmentation.sh:**

*Benutzte Programme:*

- kmeans
- gmm

*Parameter:*

- h: Hilfe
- a: Algorithmus wählen (kmeans oder gmm)
- w: Speicherort der Segmentierung

---

<sup>1</sup><http://tiswww.case.edu/php/chet/bash/bashtop.html>

- m: Farbmodell wählen (1 = Lab, 2 = HSV)

*Optionen im Skript Quelltext:*

- truth=GroundTruth/01\_Crops, Pfad zu den ausgeschnittenen Elastogrammen

Dieses Skript segmentiert einen kompletten Testsatz an Elastogrammen aus dem Ordner *truth* und speichert sie anschließend in einem Ordner zur Weiterverarbeitung ab.

*Beispiel:*

---

```
./doWholeSegmentation.sh -a kmeans ...
-w kmeans_segmentations/ -m 1
```

---

- **doAllFeatures.sh:**

*Benutzte Programme:*

- featureCalc

*Parameter:*

- h: Hilfe
- m: Pfad zu den segmentierten Dateien
- n: Anzahl der Cluster
- o: Pfad zu den unsegmentierten Dateien

Dieses Skript führt die Featureberechnung für einen Satz an segmentierten Elastogrammen aus und speichert diese als CSV-Datei ab.

*Beispiel:*

---

```
./doAllFeatures.sh -m kmeans_segmentations ...
-n 3 -o GroundTruth/01_Crops
```

---

- **createSVMs.sh:**

*Benutzte Programme:*

- trainSVM

*Parameter:*

- 1. Parameter setzt zu benutzenden Layer

Dieses Skript erstellt einen Satz von Support Vector Machines mit verschiedenen Kernen: Linear, Radial Basis function und Sigmoid. Für jeden Kernel wird das Programm mit den drei unterschiedlichen Reduktionsarten der Feature-Tabellen ausgeführt: Min-, Max- und Durchschnittsbildung. Die Ergebnisse werden im ausgeführten Verzeichnis als XML-Dateien gespeichert.

*Beispiel:*

---

```
./createSVMs.sh 1
```

---

- **createPolynomialSVMs.sh:**

*Benutzte Programme:*

- trainSVM

*Parameter:*

- 1. Parameter setzt zu benutzenden Layer

Dieses Skript erstellt einen Satz von Support Vector Machines mit einem polynomialen Kernel. Der Grad des Polynoms wird dabei bei jedem Aufruf inkrementiert und ist skriptseitig bis 10 limitiert. Für jeden Grad wird das Programm mit den drei unterschiedlichen Reduktionsarten der Feature-Tabellen ausgeführt: Min-, Max- und Durchschnittsbildung. Die Ergebnisse werden im ausgeführten Verzeichnis als XML-Dateien gespeichert.

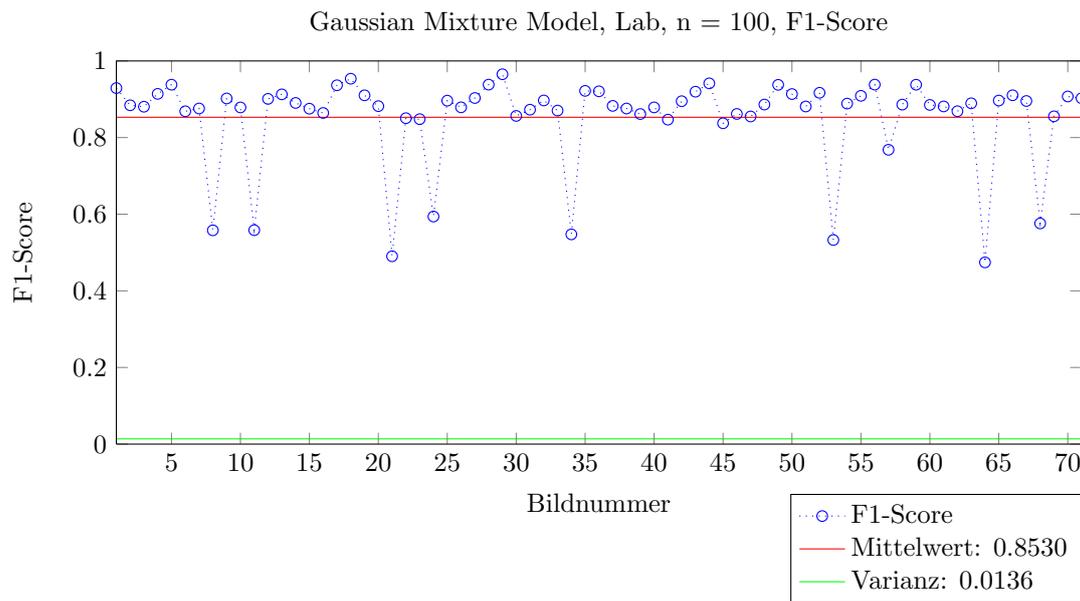
*Beispiel:*

---

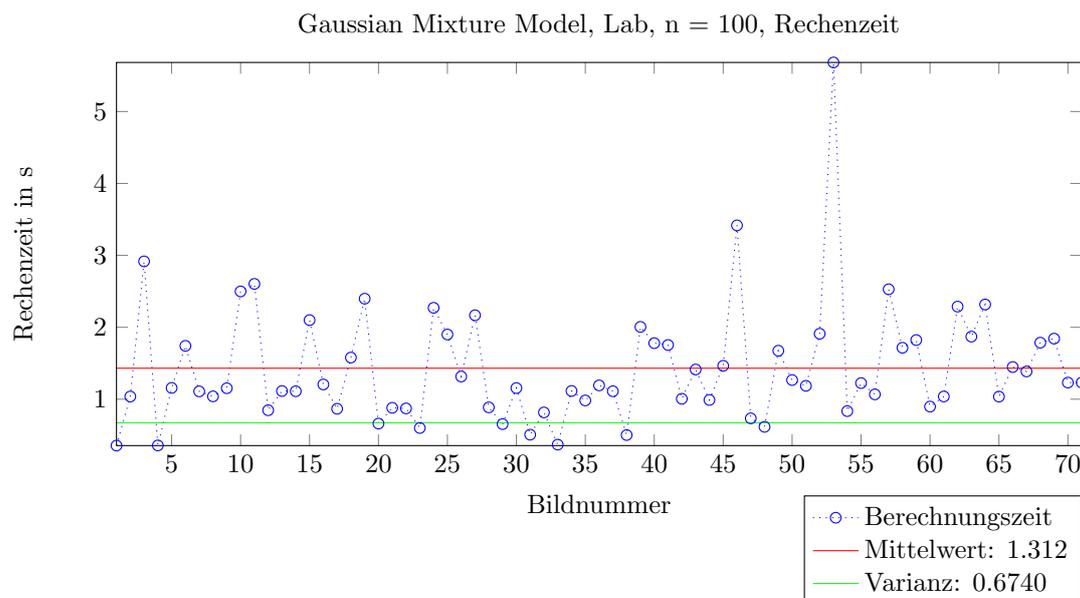
```
./createPolynomialSVMs.sh 1
```

---

## A.5 Vergleichende Segmentierungs-Messergebnisse

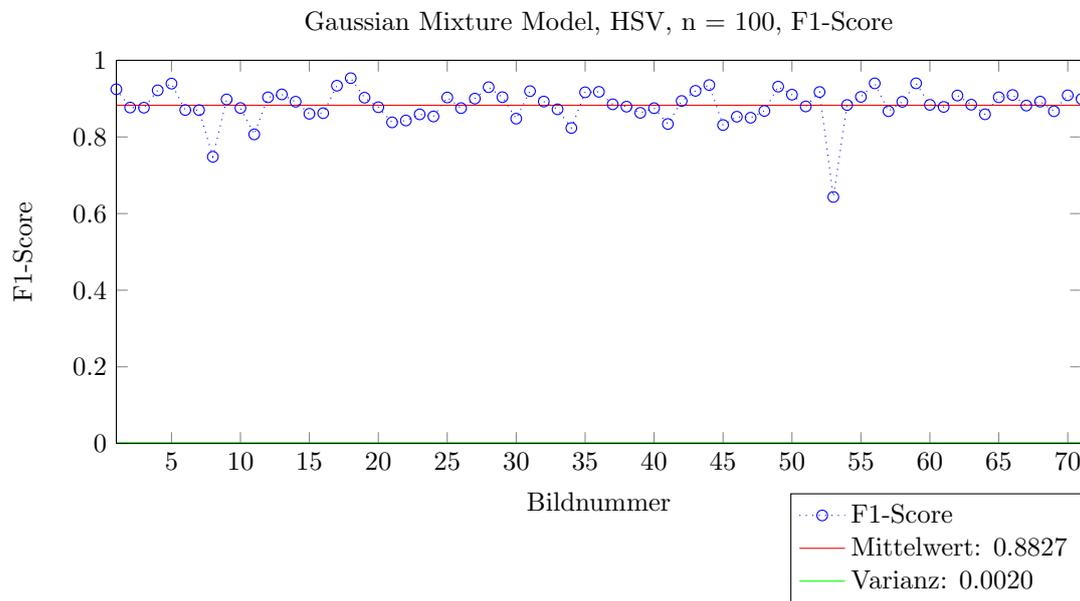


(a) F-Score

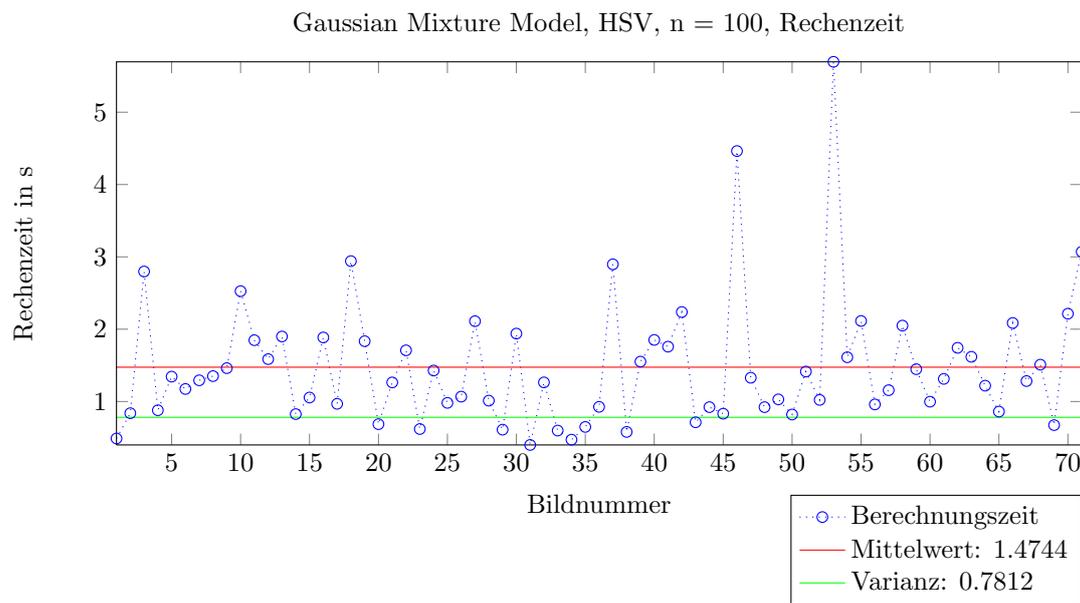


(b) Rechenzeit

Abbildung A.1: Segmentierung der Testdaten mittels Gaussian Mixture Models im Lab-Farbmodell

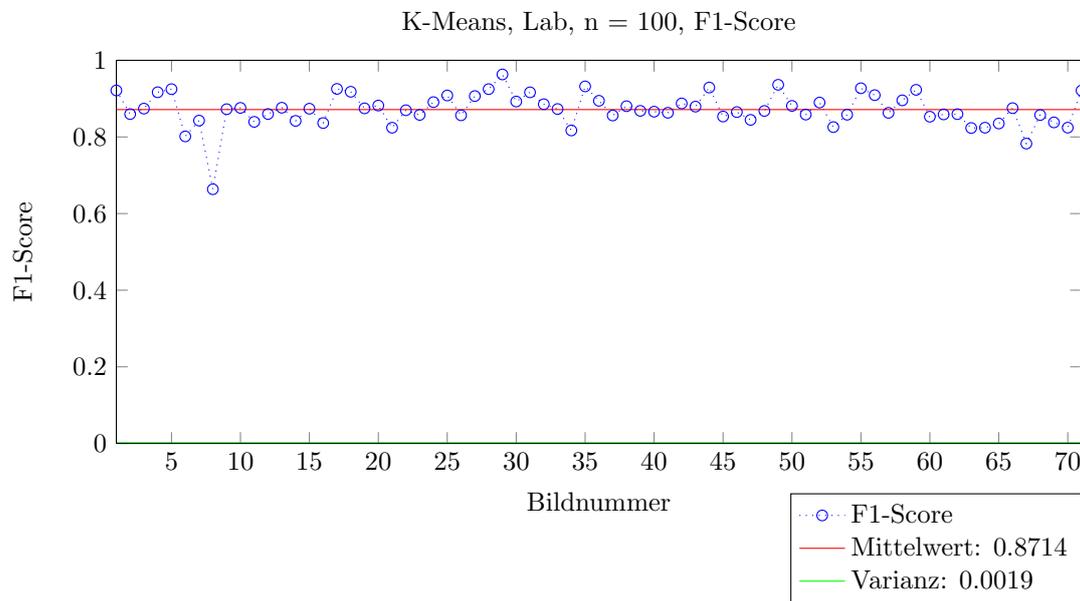


(a) F-Score

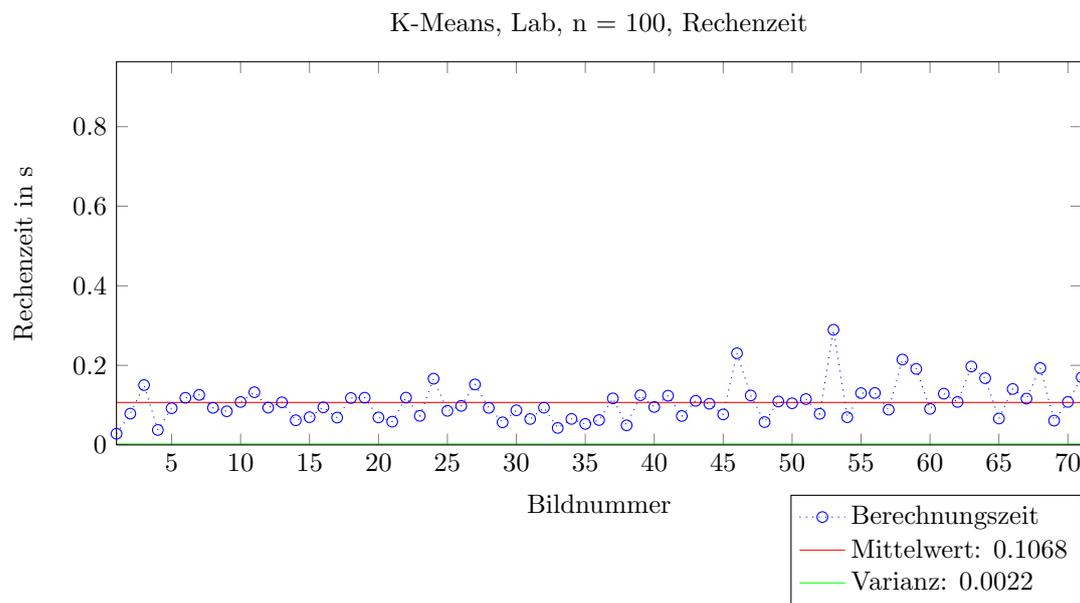


(b) Rechenzeit

Abbildung A.2: Segmentierung der Testdaten mittels Gaussian Mixture Models im HSV-Farbmodell

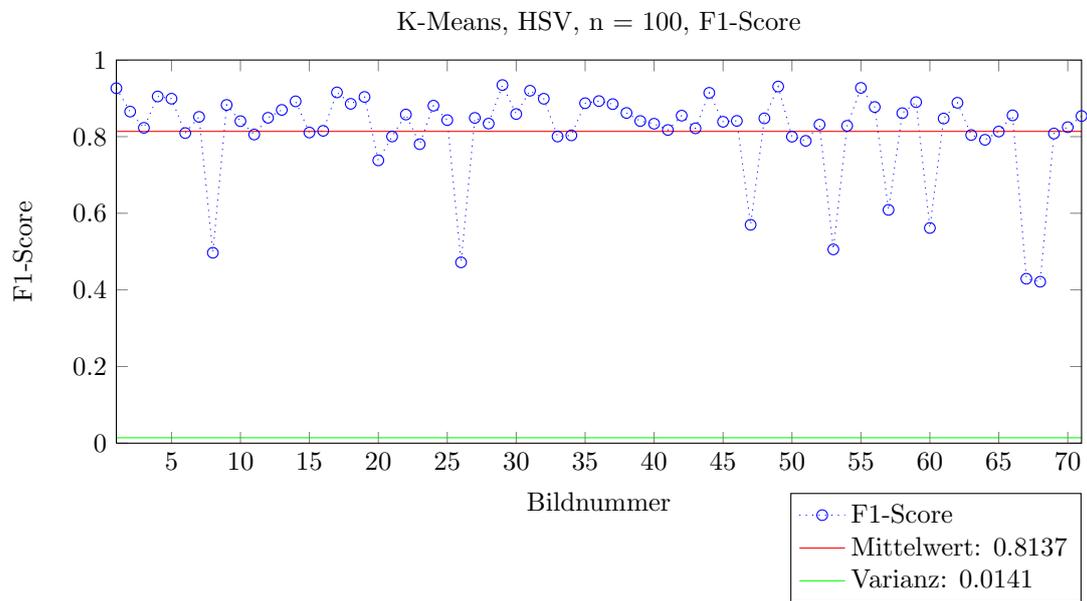


(a) F-Score

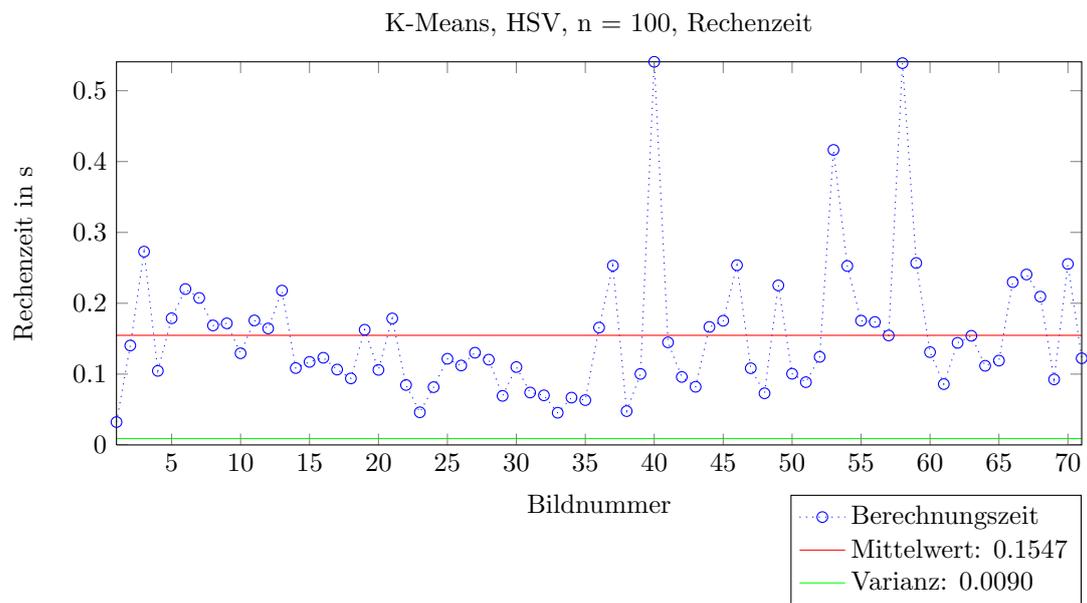


(b) Rechenzeit

Abbildung A.3: Segmentierung der Testdaten mittels K-Means-Clusterings im Lab-Farbmodell



(a) F-Score



(b) Rechenzeit

Abbildung A.4: Segmentierung der Testdaten mittels K-Means-Clusterings im HSV-Farbmodell

## A.6 SVM Prädiktion

Tabelle A.1: Ebene 0

Layer 0		1	2	3	4	5
LINEAR	Min	1	2	3	3	1
	Max	1	3	1	2	2
	Average	1	3	2	2	4
	Sum	1	3	2	1	3
POLYNOMIELL 1	Min	1	2	3	3	1
	Max	1	3	1	2	2
	Average	1	3	2	2	4
	Sum	1	3	2	1	3
POLYNOMIELL 2	Min	2	1	1	5	2
	Max	5	5	5	5	5
	Average	5	5	5	5	5
	Sum	5	5	5	5	5
POLYNOMIELL 3	Min	1	5	1	2	1
	Max	5	5	5	5	5
	Average	5	5	5	5	5
	Sum	5	5	5	5	5
POLYNOMIELL 4	Min	5	2	2	2	5
	Max	5	5	5	5	5
	Average	5	5	5	5	5
	Sum	5	5	5	5	5
POLYNOMIELL 5	Min	5	1	1	1	5
	Max	5	5	5	5	5
	Average	5	5	5	5	5
	Sum	5	5	5	5	5
RBF	Min	1	1	1	1	1
	Max	1	1	1	1	1
	Average	1	1	1	1	1
	Sum	1	1	1	1	1
SIGMOID	Min	1	1	1	1	1
	Max	1	1	1	1	1
	Average	1	1	1	1	1
	Sum	1	1	1	1	1

Tabelle A.2: Ebene 1

Layer 1		1	2	3	4	5
LINEAR	Min	3	1	3	1	2
	Max	1	1	1	3	2
	Average	1	2	1	2	3
	Sum	1	1	1	1	2
POLYNOMIELL 1	Min	3	1	3	1	2
	Max	1	1	3	3	2
	Average	1	2	1	2	3
	Sum	1	1	1	1	2
POLYNOMIELL 2	Min	1	1	1	1	1
	Max	5	5	5	5	5
	Average	5	1	1	1	1
	Sum	5	5	5	5	5
POLYNOMIELL 3	Min	1	1	1	1	1
	Max	5	5	5	5	5
	Average	5	5	5	5	5
	Sum	5	5	5	5	5
POLYNOMIELL 4	Min	1	3	1	3	3
	Max	5	5	5	5	5
	Average	5	5	5	5	5
	Sum	5	5	5	5	5
POLYNOMIELL 5	Min	5	4	4	4	4
	Max	5	5	5	5	5
	Average	5	5	5	5	5
	Sum	5	5	5	5	5
RBF	Min	1	1	1	1	1
	Max	1	1	1	1	1
	Average	1	1	1	1	1
	Sum	1	1	1	1	1
SIGMOID	Min	1	1	1	1	1
	Max	1	1	1	1	1
	Average	1	1	1	1	1
	Sum	1	1	1	1	1

Tabelle A.3: Ebene 2

<b>Layer 2</b>		1	2	3	4	5
LINEAR	Min	3	3	3	3	3
	Max	3	3	1	1	5
	Average	1	2	2	3	3
	Sum	2	2	1	1	3
POLYNOMIELL 1	Min	3	3	3	3	3
	Max	3	3	1	1	5
	Average	1	2	2	3	3
	Sum	2	2	1	1	3
POLYNOMIELL 2	Min	1	4	1	2	1
	Max	5	5	5	5	5
	Average	5	5	5	5	5
	Sum	5	5	5	5	5
POLYNOMIELL 3	Min	4	3	3	4	1
	Max	5	5	5	5	5
	Average	5	5	5	5	5
	Sum	5	5	5	5	5
POLYNOMIELL 4	Min	3	2	2	2	1
	Max	5	5	5	5	5
	Average	5	5	5	5	5
	Sum	5	5	5	5	5
POLYNOMIELL 5	Min	5	5	5	5	5
	Max	5	5	5	5	5
	Average	5	5	5	5	5
	Sum	5	5	5	5	5
RBF	Min	1	1	1	1	1
	Max	1	1	1	1	1
	Average	1	1	1	1	1
	Sum	1	1	1	1	1
SIGMOID	Min	1	1	1	1	1
	Max	1	1	1	1	1
	Average	1	1	1	1	1
	Sum	1	1	1	1	1

## Literaturverzeichnis

- [BIR03] *BI-RADS® – Ultrasound*. 1. American College of Radiology, 2003
- [Bra00] BRADSKI, G.: The OpenCV Library. In: *Dr. Dobb's Journal of Software Tools* (2000)
- [BS06] BLANCHETTE, Jasmin ; SUMMERFIELD, Mark: *C++ GUI Programming with Qt 4*. 1. Prentice Hall, 2006
- [Chi92] CHINCHOR, Nancy: MUC-4 Evaluation Metrics. In: *Fourth Message Understanding Conference* (1992), S. 22–29
- [COPM93] CESPEDES, I. ; OPHIR, J. ; PONNEKANTI, H. ; MAKLAD, N.: Elastography: Elasticity Imaging Using Ultrasound with Application to Muscle and Breast In Vivo. In: *Ultrasonic Imaging* 15 (1993), Nr. 2, S. 73 – 88
- [Cov65] COVER, T.M.: Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. In: *Electronic Computers, IEEE Transactions on* (1965), Nr. 3, S. 326–334
- [CY11] CAMPBELL, Colin ; YING, Yiming: *Learning with Support Vector Machines*. Morgan Claypool, 2011
- [DHJK] DR. H.-J. KOUBENEC, Brustkrebs I.: *Brustkrebs-Lexikon*. <http://www.brustkrebs-info.de/brustkrebs-lexikon/lexikon.php>, Abruf: 14.03.2012
- [DHJK10] DR. H.-J. KOUBENEC, Brustkrebs I.: *Brustkrebs: Diagnostik und Früherkennung (Sonographie, Ultraschall)*. <http://www.brustkrebs-info.de/patienten-info/index.php?id=5.3.1>. Version: 04 2010, Abruf: 13.03.2012
- [DLR77] DEMPSTER, A.P. ; LAIRD, N.M. ; RUBIN, D.B.: Maximum likelihood from incomplete data via the EM algorithm. In: *Journal of the Royal Statistical Society. Series B (Methodological)* (1977), S. 1–38
- [Doh09] DOHLUS, R.: *Photonik*. Oldenbourg Wissenschaftsverlag, 2009
- [Dös00] DÖSSEL, Olaf: *Bildgebende Verfahren in der Medizin: von der Technik zur medizinischen Anwendung*. Springer Berlin Heidelberg New York, 2000
- [FHN03] FRANK H. NETTER, M.D.: *Atlas der Anatomie des Menschen Gesamtausgabe Band 1-3*. 3. Elsevier, 2003
- [FMS03] FEAR, E.C. ; MEANEY, P.M. ; STUCHLY, M.A.: Microwaves for breast cancer detection? In: *Potentials, IEEE* 22 (2003), feb/mar, Nr. 1, S. 12 – 18. <http://dx.doi.org/10.1109/MP.2003.1180933>. – DOI 10.1109/MP.2003.1180933. – ISSN 0278–6648

- [FSZE09] FLUSSER, J. ; SUK, T. ; ZITOV, B. ; EBRARY, Inc: *Moments and moment invariants in pattern recognition*. Wiley Online Library, 2009
- [FVDF<sup>+</sup>94] FOLEY, J.D. ; VAN DAM, A. ; FEINER, S.K. ; HUGHES, J.F. ; PHILLIPS, R.L.: *Introduction to computer graphics*. Bd. 55. Addison-Wesley, 1994
- [Gar11] GARRA, B.S.: Tissue elasticity imaging using ultrasound. In: *Applied Radiology* 40 (2011), Nr. 4, S. 24
- [GCO<sup>+</sup>97] GARRA, B.S. ; CÉSPEDES, I. ; OPHIR, J. ; SPRATT, S. ; ZUURBIER, R. A. ; MAGNANT, C. M. ; PENNANEN, M. F.: Elastography of Breast lesions: initial clinical results. In: *Radiology* 202 (1997), S. 79–86
- [Ges] GESELLSCHAFT EPIDEMIOLOGISCHER KREBSREGISTER IN DEUTSCHLAND E.V.: *GEKID-Atlas*. <http://www.gekid.de/>, Abruf: 07.06.2012
- [HA07] HARDER, U. ; AHRENDT, C.: *Hebammenkunde: Lehrbuch für Schwangerschaft, Geburt, Wochenbett und Beruf*. Georg Thieme Verlag, 2007
- [HKS<sup>+</sup>01] HILTAWSKY, K.M. ; KRÜGER, M. ; STARKE, C. ; HEUSER, L. ; ERMERT, H. ; JENSEN, A.: Freehand ultrasound elastography of breast lesions: clinical results. In: *Ultrasound in medicine & biology* 27 (2001), Nr. 11, S. 1461–1469
- [Hof06] HOFFMANN, Gernot: *Graphics for Color Science*. <http://www.fho-empden.de/~hoffmann/ciegraph17052004.pdf>. Version: 06 2006, Abruf: 17.01.2012
- [Hu62] HU, M.K.: Visual pattern recognition by moment invariants. In: *Information Theory, IRE Transactions on* 8 (1962), Nr. 2, S. 179–187
- [HW79] HARTIGAN, J.A. ; WONG, M.A.: Algorithm AS 136: A k-means clustering algorithm. In: *Journal of the Royal Statistical Society. Series C (Applied Statistics)* 28 (1979), Nr. 1, S. 100–108
- [Int] INTERNATIONAL AGENCY FOR RESEARCH ON CANCER - WORLD HEALTH ORGANISATION: *European Cancer Observatory*. <http://eu-cancer.iarc.fr>, Abruf: 08.06.2012
- [IUT<sup>+</sup>06] ITOH, A. ; UENO, E. ; TOHNO, E. ; KAMMA, H. ; TAKAHASHI, H. ; SHIINA, T. ; YAMAKAWA, M. ; MATSUMURA, T.: Breast Disease: Clinical Application of US Elastography for Diagnosis1. In: *Radiology* 239 (2006), Nr. 2, S. 341
- [Jäh05] JÄHNE, Bernd: *Digitale Bildverarbeitung*. Springer, 2005
- [KCL<sup>+</sup>08] KLEMM, M. ; CRADDOCK, I. ; LEENDERTZ, J. ; PREECE, A. ; BENJAMIN, R.: Experimental and clinical results of breast cancer detection using UWB microwave radar. In: *Antennas and Propagation Society International Symposium, 2008. AP-S 2008. IEEE* IEEE, 2008, S. 1–4
- [KCL<sup>+</sup>09] KLEMM, M. ; CRADDOCK, I.J. ; LEENDERTZ, J.A. ; PREECE, A. ; BENJAMIN, R.: Radar-Based Breast Cancer Detection Using a Hemispherical Antenna Array x2014;Experimental Results. In: *Antennas and Propagation, IEEE Transactions on* 57 (2009), june , Nr. 6, S. 1692 –1704. <http://dx.doi.org/10.1109/TAP.2009.2019856>. – DOI 10.1109/TAP.2009.2019856. – ISSN 0018–926X

- [KN09] KADOUR, M. ; NOBLE, J.A.: Assisted-freehand ultrasound elasticity imaging. In: *Ultrasonics, Ferroelectrics and Frequency Control, IEEE Transactions on* 56 (2009), Nr. 1, S. 36–43
- [Kra11] KRAMME, R.: *Medizintechnik: Verfahren-Systeme-Informationsverarbeitung*. Springer, 2011
- [Kre12] KREYWINKEL, Klaus: Krebsregister liefern Fakten. In: *Frankfurter Allgemeine Zeitung* (2012), 02, Nr. 41
- [KS10] KUMM, T.R. ; SZABUNIO, M.M.: Elastography for the characterization of breast lesions: initial clinical experience. In: *Cancer Control* 17 (2010), Nr. 3, S. 156–161
- [KWT88] KASS, M. ; WITKIN, A. ; TERZOPOULOS, D.: Snakes: Active Contour Models. In: *International Journal of Computer Vision* (1988), S. 321–331
- [Lag11] LAGANIÈRE, Robert: *OpenCV 2 Computer Vision Application Programming Cookbook*. 1. Packt Publishing, 2011
- [Lin] LINDBLOOM, Bruce: *XYZ to Lab*. <http://www.brucelindbloom.com/>, Abruf: 16.03.20012
- [Mac03] MACKAY, D.J.C.: *Information theory, inference, and learning algorithms*. Cambridge Univ Pr, 2003
- [MGK00] MATAS, J. ; GALAMBOS, C. ; KITTLER, J.: Robust detection of lines using the progressive probabilistic hough transform. In: *Computer Vision and Image Understanding* 78 (2000), Nr. 1, S. 119–137
- [Moo01] MOORE, S.K.: Better breast cancer detection. In: *Spectrum, IEEE* 38 (2001), may, Nr. 5, S. 50 –54. <http://dx.doi.org/10.1109/6.920031>. – DOI 10.1109/6.920031. – ISSN 0018–9235
- [Mös07] MÖSER, Michael: *Technische Akustik*. 7. Springer Berlin Heidelberg New York, 2007
- [Mus02] MUSMANN, Prof. Dr.-Ing. H.: *Vorlesungsskript: Quellencodierung*. Institut für Informationsverarbeitung der Leibniz Universität Hannover, 2002
- [Mus05] MUSMANN, Prof. Dr.-Ing. H.: *Vorlesungsskript: Statistische Methoden der Nachrichtentechnik*. Institut für Informationsverarbeitung der Leibniz Universität Hannover, 2005
- [OCP91a] OPHIR, J. ; CESPEDES, I. ; PONNEKANTI, H.: *Method and apparatus for elastographic measurement and imaging*. United States Patent No. 5,178,147, May 1991
- [OCP+91b] OPHIR, J. ; CESPEDES, I. ; PONNEKANTI, H. ; YAZDI, Y. ; LI, X.: Elastography: a quantitative method for imaging the elasticity of biological tissues. In: *Ultrasonic imaging* 13 (1991), Nr. 2, S. 111–134
- [OD08] OLSON, David L. ; DELEN, Dursun: *Advanced Data Mining Techniques*. Springer Berlin Heidelberg New York, 2008
- [Psc04] PSCHYREMBEL, Willibald: *Klinisches Wörterbuch*. 260. de Gruyter, 2004

- [SMW04] SCHMIDT-MATTHIESEN, H. ; WALLWIENER, D.: *Gynäkologie und Geburtshilfe*. 10. Schattauer, 2004
- [SSL<sup>+</sup>91] SIEBERS, S. ; SCHEIPERS, U. ; LORENZ, A. ; PESAVENTO, A. ; ERMERT, H. ; LORENZ, I. ; PESAVENTO, B.: Echtzeit-Elastographie und Vibrographie: Abbildung elastischer Gewebeeigenschaften mit Ultraschall. In: *Imaging 13* (1991), S. 111–134
- [TMKC<sup>+</sup>08] THITAIKUMAR, A. ; MOBBS, L.M. ; KRAEMER-CHANT, C.M. ; GARRA, B.S. ; OPHIR, J.: Breast tumor classification using axial shear strain elastography: a feasibility study. In: *Physics in medicine and biology* 53 (2008), S. 4809
- [TYM<sup>+</sup>11] THITTAI, A.K. ; YAMAL, J.M. ; MOBBS, L.M. ; KRAEMER-CHANT, C.M. ; CHEKURI, S. ; GARRA, B.S. ; OPHIR, J.: Axial-Shear Strain Elastography for Breast Lesion Classification: Further Results from In Vivo Data. In: *Ultrasound in Medicine & Biology* (2011)
- [VW02] VIOLA, F. ; WALKER, W.F.: Shear strain elastography. In: *Ultrasonics Symposium, 2002. Proceedings. 2002 IEEE* Bd. 2, 2002. – ISSN 1051–0117, S. 1907 – 1911 vol.2